

MODELAGEM DE SENSORES VIRTUAIS VIA REDES NEURAIIS ARTIFICIAIS

Priscylla A. S. Oliveira

Instituto Federal de São Paulo (IFSP), Cubatão, SP, Brasil

Marcelo Saraiva Coelho

Instituto Federal de São Paulo (IFSP), Cubatão, SP, Brasil

Italo Pinto Rodrigues

Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, SP, Brasil

Jefferson Souza de Paula

Centro Universitário de Barra Mansa (UBM), Barra Mansa, RJ, Brasil

Lucas Rocha Martins

Centro Universitário de Barra Mansa (UBM), Barra Mansa, RJ, Brasil

Resumo: O desenvolvimento de sensores virtuais tem recebido grande atenção de pesquisadores como uma aplicação prática da inteligência artificial para identificação de sistemas. Deste modo, este trabalho modelou sensores de fumaça e de monóxido de carbono (CO) instalados em um protótipo de forno industrial através da utilização das redes neurais artificiais do tipo Perceptron Multicamadas (MLP). Para a aquisição das medidas reais foi usada uma plataforma de baixo custo e para o processamento e implementação da rede neural foram utilizados os softwares MATLAB e Simulink. Os resultados são quantificados e analisados por meio do índice Erro Médio Quadrático. Os resultados do treinamento e generalização foram satisfatórios, tendo em vista a grande quantidade de ruídos inerentes ao sistema e a simplicidade da rede neural implementada.

Palavras-chave: Sensores virtuais, Redes Neurais, MLP, Regressão

Abstract: The development of virtual sensors has been a major attention of researchers as an artificial intelligence practice for systems identification. Thus, this work modeled the smoke and carbon monoxide (CO) sensors in an industrial furnace prototype through Multilayer Perceptron (MLP). For the acquisition of the actual measurements, a low cost platform was used and the neural network was processed and implemented with MATLAB and Simulink software. The results are quantified and analyzed using the Mean Square Error index. The results of training and generalization were satisfactory, due to the large amount of noise inherent to the system and the simplicity of the neural network implemented.

Keywords: Soft sensor, Neural Networks, MLP, Regression.

Introdução

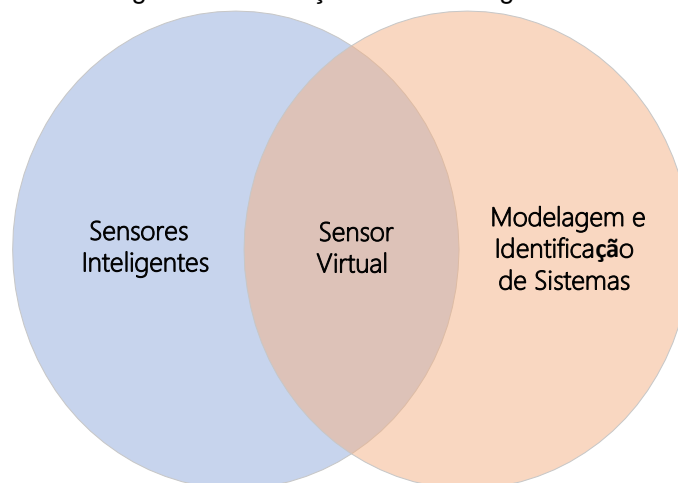
Diante de um cenário globalizado, organizações de diversos setores industriais são geradoras de impactos ambientais e lidam com aspectos poluentes que podem ser mal monitorados, afetando o meio ambiente, a economia e, principalmente, a sociedade. Em consequência disso, têm sido registrados nas últimas décadas um agravamento do aquecimento global e consequências desastrosas para o planeta.

Tendo em vista essa problemática, a utilização de sensores virtuais para o monitoramento de áreas críticas pode ser considerada uma alternativa, a fim de substituir os instrumentos que apresentam um alto investimento e, conseqüente, diminuir os custos de manutenção e calibração. Castell et al. (2016) afirma que em um processo industrial pode contemplar diversos analisadores (sensores), além disso, estes sensores podem ter um custo elevado.

Os sensores virtuais consistem em um modelo, que utiliza como dados de entrada as variáveis secundárias que podem ser medidas com maior facilidade por instrumentos de baixo custo, e então, as variáveis de interesse do processo são estimadas a partir das variáveis secundárias (Lotufo e Garcia. 2008). Segundo Mota et al. (2016), a sua premissa é associar simplicidade com precisão.

De acordo com Lotufo e Garcia (2008), o sensor virtual, também chamado de *soft-sensor* (*Software based sensors*) por Tham, et al. (1990), está na interseção de duas grandes áreas, sendo elas: sensores inteligentes e modelagem e identificação de sistemas, como indica a Figura 1.

Figura 1 - Interseção das tecnologias.



Fonte - Lotufo e Garcia (2008)

De acordo com Fortuna et al. (2007), os sensores virtuais apresentam características vantajosas em relação aos sensores físicos. Dentre as vantagens pode-se destacar: (i) o fato de eles representarem uma alternativa de baixo custo; (ii) serem utilizados paralelamente aos sensores físicos, podendo gerar informações relacionadas à detecção de falhas e assim denotar mais confiabilidade ao processo; (iii) na maioria dos casos é de fácil manutenção, ou seja, ajuste de parâmetros, enquanto sensores físicos dependem da troca do dispositivo.

No trabalho de Tham, et al. (1990) são apresentados dois estimadores adaptativos (*soft-sensor*) para inferir as saídas de processos sujeitos à grande quantidade de atrasos. Os algoritmos, referidos como *soft-sensors*, foram aplicados com sucesso em várias plantas industriais, tais como: (i) concentração de fermentação em biomassa; (ii) composição de coluna de desmetanizador e (iii) índice de fluidez do polímero. Os resultados mostram o potencial da proposta de estimador de solucionar problemas de controle causados por limitações na instrumentação de processos industriais.

No trabalho de McAvoy (2002) é discutido a aplicação de controle inteligente em indústrias. Técnicas estatísticas e modelo de controle preditivo são apresentados com aplicações em sensores virtuais, processo de otimização em *batch* e detecção de falhas. O monitoramento tradicional contínuo de emissões é feito através de sensores analíticos, os quais podem ser caros e de difícil manutenção.

De acordo com Lin, et al (2007), um sensor virtual é um modelo desenvolvido a partir de observações de um processo e tem o objetivo de complementar medidas de instrumentação online para monitoramento e controle de processos industriais. No artigo do mesmo autor é apresentado uma sistemática para o projeto de um sensor virtual orientado por dados. A metodologia proposta é aplicada para prever óxidos de nitrogênio (NO_x) na indústria de cimento. Os sensores virtuais desenvolvidos mostraram uma capacidade razoavelmente acurada para a predição e forneceram informações complementares para analisadores online de gases e medidas laboratoriais.

Em Lotufo e Garcia (2008) também pode ser visto uma revisão de literatura de trabalhos sobre sensores virtuais, bem como os modelos mais utilizados para representa-los, tais como, os modelos entrada-saída ARMA, ARX, NARX, ARMAX e

NARMAX, modelos do tipo espaço de estados, modelo baseado em redes neurais artificiais, as quais têm-se tornado bastante populares pela sua característica de aprendizagem e adaptação, sistemas especialistas, métodos baseados em lógica nebulosa e algoritmos genéticos.

Casos onde o processo não é bem compreendido, modelos empíricos, tais como métodos estatísticos e redes neurais são usados para obtenção dos modelos de regressão (Lin, et al., 2007). As redes neurais artificiais (RNA) se mostram como uma solução atrativa para esse tipo de problema de modelagem, uma vez que são capazes de adquirir conhecimento através de um processo de aprendizado e treinamento sem que seja necessário explicitar os modelos matemáticos (Haykin, 2001).

O trabalho de Zanata (2005) teve como objetivo obter um sensor virtual para estimar instantaneamente a composição de produtos no topo de uma coluna de destilação empregando redes neurais artificiais. As arquiteturas de redes empregadas foram a rede *multilayer perceptron* com o algoritmo *backpropagation* e a rede recorrente de Elman. Uma contribuição importante desse trabalho foi a proposta de metodologia para detecção e correção de erros baseado em medidas laboratoriais mais precisas, uma vez que não foram encontrados trabalhos que se dedicasse a propor ou analisar técnicas de correção de erro do valor fornecido pelo sensor.

No trabalho de Kadlec et al. (2009) é discutido as características dos processos industriais críticos para o desenvolvimento de sensores virtuais. É feito um estudo de caso de três importantes aplicações, uma introdução sobre as mais populares técnicas de modelagem, incluindo as redes neurais artificiais mais adequadas para a indústria e suas variações tais como *Multi-layer perceptron*, *Radial Basis Function Network*, *Recursive Neural Network* e *Self-organizing Maps*, uma explanação sobre as dificuldades de projeto e manutenção de sensores virtuais, bem como possíveis soluções para esses problemas.

Rani et al. (2013) fizeram um projeto de sensor virtual usando a rede neural adaptativa ADALINE para estimar a composição no processo de destilação baseado nas medidas de temperatura de um processo de destilação. A partir desses sensores projetados, foi desenvolvido dois controladores inferenciais (*Levenberg-Marquardt inferential controller* (LMIC) e *ADALINE inferential controller* (ADIC)) para controlar a

destilação de multicomponentes. O desempenho do controlador é analisado para diferentes entradas e taxas de amostragem. Os resultados mostraram que a rede ADALINE necessitou de menor tempo de treinamento e foi mais precisa.

Em Lima (2018) é proposto um sensor virtual, baseado em redes neurais artificiais, para estimar a composição do Gás Liquefeito de Petróleo (GLP). Também é proposto um sistema de correção do erro em tempo real do sensor virtual a partir da leitura de GLP feita por cromatógrafos presentes no processo. Os resultados obtidos foram promissores.

O objetivo principal deste artigo foi obter o modelo, baseado em rede neural artificial, de um sensor virtual de gás monóxido de carbono (CO) e concentração de fumaça no interior de um protótipo de forno industrial.

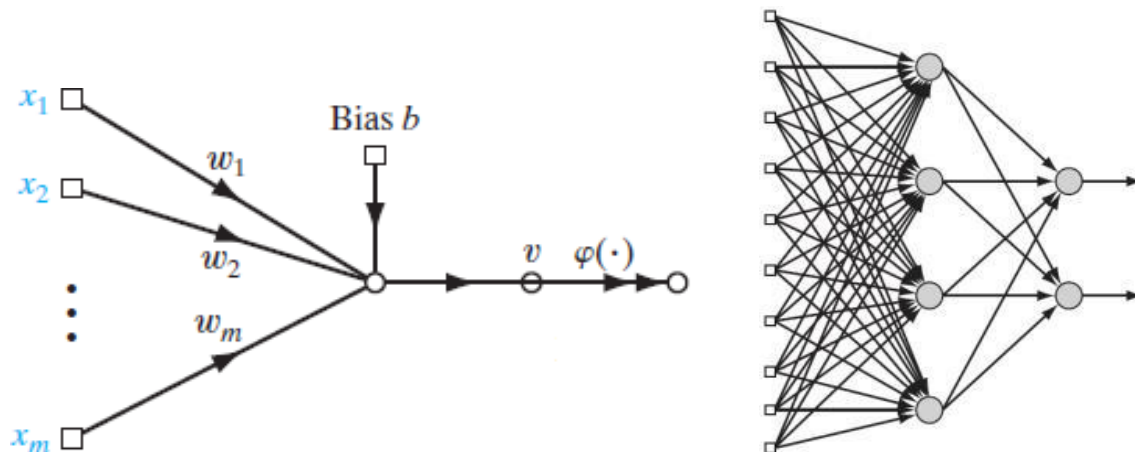
O artigo está organizado da seguinte forma: na Seção 2, tem-se a Fundamentação Teórica de rede neural artificial multicamadas. Na Seção 3, é apresentada a Metodologia proposta para a construção do protótipo de forno industrial, para a aquisição dos dados, comunicação do Arduino com o Matlab e definição das estruturas das redes neurais usadas para a identificação dos sensores. Os resultados experimentais são analisados na Seção 4. E, finalmente, na Seção 5, as conclusões finais do trabalho são apresentadas.

Redes Neurais Artificiais

De acordo com Haykin (2008), uma rede neural é um processador paralelamente massivamente distribuído composto por unidades simples com grande capacidade de aprendizagem.

A rede neural perceptron ocupa um papel importante no desenvolvimento das redes neurais, uma vez que, foi a primeira rede a ser descrita via algoritmo (Haykin, 2008). A Figura 2(a) mostra uma representação diagramática do perceptron proposto por Rosenblatt (1957), onde (x_1, x_2, \dots, x_m) são as entradas, (w_1, w_2, \dots, w_m) são os pesos sinápticos, o bias b , $\varphi(\cdot)$ é a função de ativação e v é o campo local induzido. A partir da equação (1), o campo local induzido do neurônio pode ser encontrado.

Figura 2 - (a) Perceptron; (b) Arquitetura MLP



Fonte. Haykin (2008)

$$v = \sum_{i=1}^M w_i x_i + b \quad (1)$$

A função de ativação representa o efeito que a entrada e o estado atual da ativação exercem no próximo estado do neurônio.

Von Zuben (2008) indica que Rosenblatt propôs um algoritmo para ajustar os pesos sinápticos do perceptron e provou sua convergência para dados linearmente separáveis. No entanto, foi o algoritmo de aprendizado denominado retro-propagação que colocou a área de rede neurais em foco. Este método ficou largamente conhecido após o trabalho de McClelland e Rumelhart (1986a-1986b).

A arquitetura MLP (*MultiLayer Perceptron*) é uma generalização do perceptron. Consiste de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como mostra a Fig2(b). Os sinais de entrada são propagados pela rede, camada a camada, da entrada para a saída (Von Zuben, 2008).

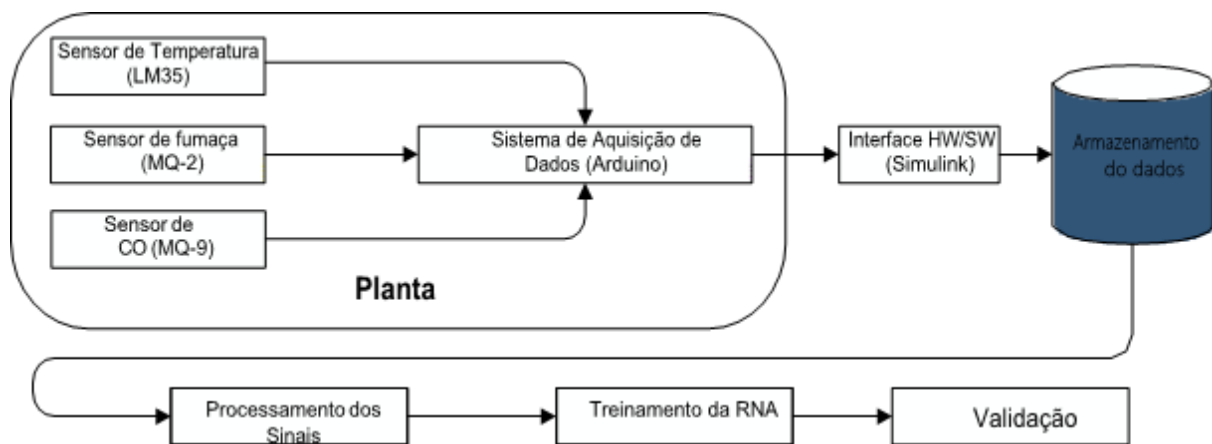
De acordo com Von Zuben (2008), as unidades intermediárias de uma rede MLP são responsáveis por duas tarefas: (i) calcular o campo local induzido e (ii) calcular a estimativa instantânea do vetor gradiente para a retro-propagação do erro através da rede.

Metodologia

Nesta seção apresenta-se a metodologia utilizada neste trabalho para a modelagem do sensor de CO e fumaça, conforme mostra a Figura 3. Uma breve descrição da metodologia abrange diversas etapas, sendo elas: construção e

montagem do protótipo do forno industrial, aquisição dos dados reais, processamento, projeto da rede neural e treinamento/generalização. A Figura 3 sumariza as etapas da metodologia aplicada neste trabalho. Vale ressaltar que a viabilidade de um sistema deste tipo está relacionada a dois fatores: sua precisão e baixo custo. Conhecendo o alto custo da interface hardware/software, foram utilizados componentes baratos e acessíveis para a validação dos conceitos empregados.

Figura 3 – Metodologia Aplicada



Protótipo de Forno Industrial

Para a realização dos testes e aquisição de dados reais, foi construído um protótipo de forno para simular o ambiente industrial, como pode ser visto na Figura 4. O uso deste forno permite a geração dos gases que estão no foco deste estudo. Todavia para realizar as medições são necessários os elementos sensores, bem como, um sistema de aquisição de dados.

Figura 4 - Planta didática de um Forno Industrial.



Sistema de Aquisição

As variáveis observadas neste trabalho são: (i) temperatura no interior do forno; (ii) concentração de fumaça, consequência da queima de pó de madeira; (iii) concentração do monóxido de carbono, que é gerada pela queima de pó de madeira.

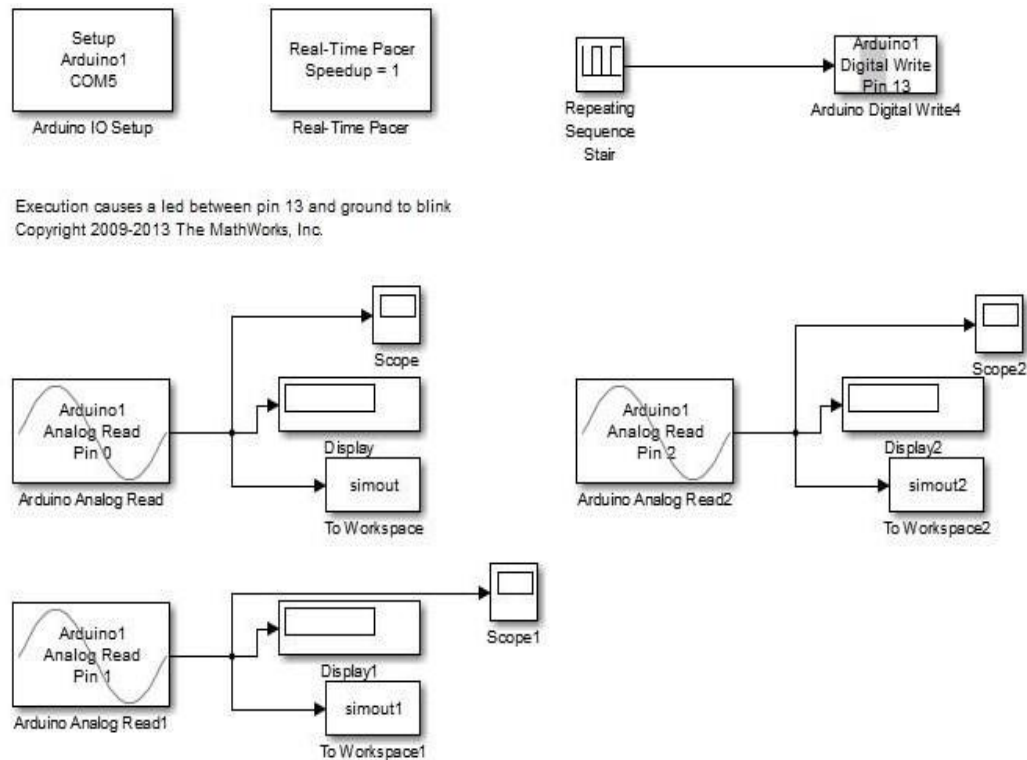
Para realizar a medição de temperatura no interior do protótipo de forno foi utilizado um circuito integrado denominado LM35. Este circuito é comumente utilizado pela sua precisão, além de possuir baixo custo para aquisição e permitir fácil instalação. O sensor LM 35 produz um sinal de saída de 10mV para cada grau Celsius ($^{\circ}\text{C}$) de temperatura e possui um range de medição de -55°C a $+150^{\circ}\text{C}$.

Para medir as concentrações de gases combustíveis e detecção de fumaça no protótipo utilizou-se o sensor MQ-2. O MQ-2 é considerado confiável e é de simples instalação em projetos de automação. Possui um range de detecção de 300 a 10.000 ppm, tensão de alimentação de 5 VDC e saída digital e analógica que possibilita melhor resolução e ajuste de sensibilidade.

Para medir a concentração de gás Monóxido de carbono (CO) utilizou-se o sensor MQ-9, útil para instalação em projetos de automação simples. Para realizar a detecção de monóxido de carbono o sensor deve ser alimentado com a tensão de 1,5 VDC. O MQ-9 também permite a detecção de outros gases como Metano (CH_4) e Propano (C_3H_8).

Todos os sensores foram conectados a uma plataforma de aquisição de dados. Neste trabalho utilizou-se um Arduino Uno para realizar a leitura das grandezas físicas e transferi-las para o computador. A Figura 5 apresenta o diagrama de ligação dos sensores. Para que a comunicação entre o Arduino e o computador fosse realizada foi necessário cumprir duas etapas: (i) embarcar no Arduino o código disponibilizado pela *MathWorks*, que permite a aquisição dos dados lidos pelo Arduino pelo computador em tempo quase real; (ii) desenvolvimento de um software para realizar a interface entre hardware (HW), neste caso o Arduino, e software (SW), Simulink, para reconhecimento e gravação dos dados lidos pelo Arduino na memória do computador, como indica a Figura 5.

Figura 5 - Diagrama de Blocos



Processamento dos Sinais

Após estabelecer a comunicação Simulink/Arduino, conforme Figura 5, o experimento da queima foi realizado com uma taxa de amostragem de 0,1 s, gerando 600 dados de temperatura, CO e concentração de fumaça.

Realizou-se a normalização das leituras de modo que as variáveis de entrada apresentassem a mesma ordem de grandeza evitando que a rede atribuisse maior importância à determinada variável devido apenas à sua magnitude (Silva et al., 2017), e o vetor de padrões foi preparado para a utilização na rede neural.

Perceptron Multicamadas

O projeto da rede neural foi feito baseado em Haykin (2001), como pode ser visto na Figura 6. O objetivo foi implementar uma rede neural simples e com resultados satisfatórios. Dessa forma, a topologia utilizada foi simples e, os parâmetros do algoritmo de aprendizagem supervisionada, foram obtidos empiricamente.

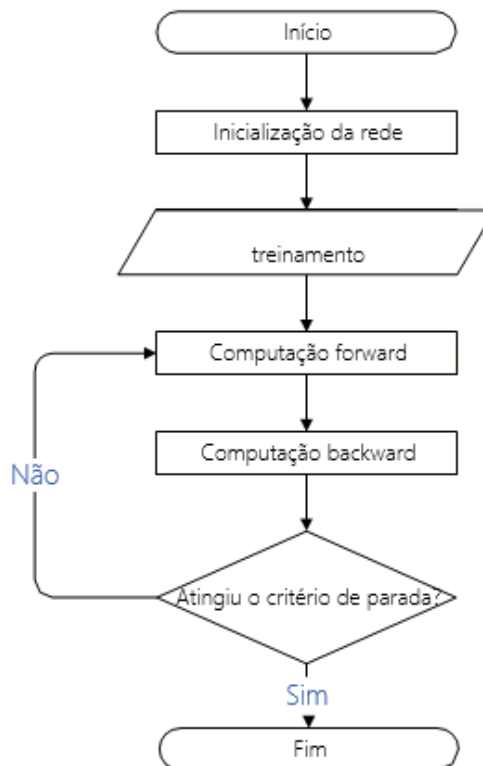
Foram implementadas duas redes neurais para estimar a dinâmica dos sensores de CO e de fumaça de acordo com o fluxograma mostrado na Figura 6.

De acordo com Haykin (2008), na primeira etapa de Inicialização, assumindo que informações iniciais estão disponíveis, define-se os pesos sinápticos como sendo aleatórios e pequenos.

Na segunda etapa é apresentada para a rede o número de épocas de treinamento e os vetores de entrada.

A terceira etapa é composta da computação dos campos locais induzidos e da saída da rede, começando da primeira camada oculta até a camada de saída. Ainda na fase *forward*, é realizado o cálculo do erro entre a saída da rede e a saída desejada.

Figura 6 - Fluxograma do algoritmo de treinamento backpropagation.



Na etapa de computação *backward*, são calculados os gradientes da rede e a atualização dos pesos sinápticos, começando da camada de saída até a camada de entrada, de acordo com a regra delta. Essa atualização dos pesos acontecerá até que o erro esteja abaixo de um critério de parada, no caso deste trabalho, o erro quadrático médio (MSE).

A rede MLP, implementada na linguagem Matlab, foi treinada com o algoritmo de retro propagação do erro, onde os pesos iniciais, definidos empiricamente, são ajustados de acordo com a saída da rede.

Os parâmetros da rede neural foram obtidos de forma empírica, tendo como base o menor erro quadrático médio. A arquitetura da rede foi definida inicialmente de acordo com a dimensão dos padrões e das classes de saída.

Como pode ser visto na Tabela 1, o critério de parada estabelecido foi um valor pequeno do erro quadrático médio (MSE).

O aprendizado é processado por algumas épocas até os pesos sinápticos e bias se tornarem aproximadamente constantes e o erro quadrático médio, mostrado na equação (2), convergir para um mínimo valor pré-definido, onde $y(i)$ é a saída desejada, $\hat{y}(i)$ é a saída estimada pela rede neural e N é o número de épocas

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

Tabela 1. Descrição da RNA1 e RNA2

	Dinâmica do Sensor de CO (RNA1)	Dinâmica do Sensor de Fumaça (RNA2)
Entrada 1:	Temperatura	
Entrada 2:	Fumaça	Monóxido de Carbono
Desejado:	Monóxido de Carbono	Fumaça
Camadas ocultas:	1	
Neurônios ocultos:	2	10
Pesos iniciais camada oculta:	Valores pequenos e aleatórios	
Função de ativação camada oculta:	Tangente Hiperbólica	
Taxa de aprendizagem Camada oculta:	0.75	0.5
Pesos iniciais camada saída:	Valores pequenos e aleatórios	
Função de ativação camada saída:	Linear	Linear
Termo momentum:	0.12	
Taxa de aprendizagem Camada saída:	0.2	
Critério de parada:	Convergência do MSE	
Épocas para convergência:	7	8

Conforme Godoy et al. (2014), observa-se que a função de ativação tangente hiperbólica na camada intermediária e função de ativação linear na camada de saída apresentaram os melhores resultados. O parâmetro taxa de aprendizado (η), neste trabalho, foi definido como fixo durante todo o treinamento e seus valores podem ser vistos na Tabela 1.

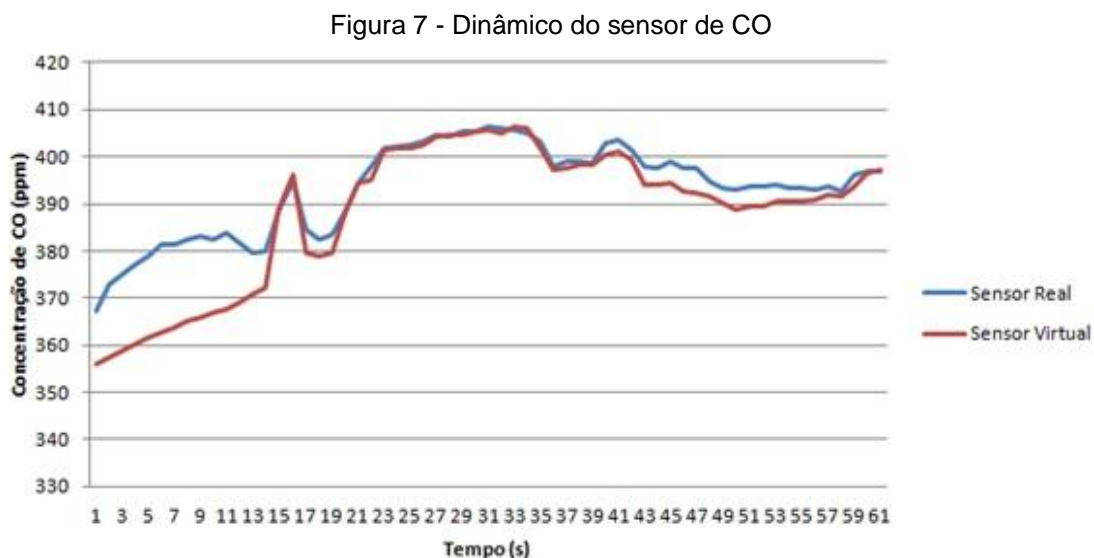
Observou-se que, para a estrutura da rede 2, o uso de mais de 10 neurônios na camada intermediária, apesar de resultar em um erro quadrático médio menor para o conjunto de treinamento, a capacidade de generalização da rede para novos vetores de entrada era reduzida.

Resultados e Análise

Treinamento

Para o treinamento da RNA1, cujos valores de configuração da rede podem ser observados na Tabela1, os padrões são as medições de temperatura e concentração de fumaça e o sensor estimado é o de CO. Após iniciar o treinamento, a rede convergiu após sete épocas, em 24,513 segundos de treinamento, com MSE menor que 0,1.


Durante o tempo inicial até 15 s, o comportamento do sensor virtual não está aderente ao comportamento das medições reais, todavia, a partir de 15 s, o resultado produzido pela rede está de acordo com o comportamento real, como pode ser observado na Figura 7.



A RNA2 utiliza os sensores fumaça e monóxido de carbono como entradas e os dados do sensor de fumaça como desejado. Esta rede convergiu após seis épocas, em 24,338 segundos de treinamento com dez neurônios ocultos e MSE menor que 0,2.

O comportamento do sensor virtual na estimativa, apesar de apresentar as variações esperadas, apresentou resultados mais afastados das medições reais, como se observa Figura 8.

Figura 8 - Dinâmica do Sensor de Fumaça.



Validação

Após o treinamento, realizou-se um teste para validar o modelo obtido a partir do uso da rede neural. A validação do modelo, isto é, generalização, foi realizada em tempo real, dessa maneira, à medida que os sensores realizam as medidas e o Arduino as enviava para o computador, a rede neural produzia os resultados frente às entradas. Os resultados podem ser vistos na Figuras 9 e Figura 10.

Para obter a concentração de CO em ppm foi necessário utilizar a interpolação dos valores de range do sensor de 10ppm à 1000ppm, uma vez que é emitido um sinal em milivolts (mV). O erro máximo encontrado foi 30 ppm de CO.

É possível notar que a rede RNA 2 obteve o melhor resultado, uma vez que conseguiu acompanhar a dinâmica apresentada pelo sensor real de fumaça com um menor erro.

Figura 9 – Resposta da validação da RNA1.





Figura 10 - Resposta da validação da RNA2.



Conclusão

Através do método aplicado e resultados apresentados pela rede criada, os objetivos foram parcialmente atingidos, sendo possível observar a capacidade computacional das RNAs na previsão e mapeamento de sensores em variadas áreas de estudo, justificando sua empregabilidade para estudo de sistemas inteligentes da atualidade.

Deste modo pode-se concluir que a inclusão de um sensor virtual, cuja leitura estima um parâmetro através da leitura de outros dois sensores, no ambiente industrial traz redução em custos e manutenção, devido à redução de equipamentos instalados e ajuda na coleta de dados, que posteriormente, poderão ser usados para o tratamento e solução de problemas como o aquecimento global.

Como continuação desta pesquisa, pretende-se: (i) Utilizar Redes Recorrentes por possuir capacidade de armazenar informações passadas e reconhecer padrões variantes no tempo; (ii) Implementar a detecção e correção de erros dos sensores virtuais proposto por Zanata (2005); (iii) Fazer um estudo mais detalhado sobre a influência dos hiperparâmetros da rede no desempenho dos sensores virtuais; (iv) Simular outros cenários e obter maior diversidade de dados para o treinamento e validação da rede.

Agradecimentos

Os autores agradecem ao Instituto Nacional de Pesquisas Espaciais (INPE) pelo apoio e disponibilidade de recursos laboratoriais e computacionais para a realização desta pesquisa.

Referências Bibliográficas

Braga, A. P., Carvalho, A.C.L.F., Ludemir, T.B. (1998). Fundamentos de Redes Neurais Artificiais. 11^a Escola de Computação, Rio de Janeiro.

Castell, N; Dauge, F. R.; Schneider, P.; Vogt, M.; Lerner, U.; Fishbain, B.; Broday, D; Bartonova, A. “Can commercial low-cost sensor platforms contribute to air quality monitoring and exposure estimates?”, *Environ. Int.*, vol. 99, pp. 293-302, 2017.

Fortuna, L., Graziani, S., Rizzo, A., Xibilia, M.G. (2007). *Soft Sensors for Monitoring and Control of Industrial Processes*. London: Springer.

Godoy, W., da Silva, I., Goedtel, A., Palacios, R. and Gongora, W. (2014). Neural approach for bearing fault classification in induction motors by using motor current and voltage. *International Joint Conference on Neural Networks (IJCNN)*, pp. 2087–2092.

Haykin, S. (2001). *Redes neurais: Princípios e Prática*. 2 ed. Porto Alegre (RS): Bookman.

- Haykin, S. (2008). *Neural Networks and Learning Machines*. 3 ed. New Jersey: Pearson Education.
- Kadlec, P., Gabrys, B., and Strandt, S. (2009). Data-driven soft sensors in the process industry. *Computers & Chemical Engineering*, 33(4), 795–814.
- Kumar, P.; Morawska, L.; Martani, C.; Biskos, G.; Neophytou, M.; Di Sabatino, S.; Bell, M.; Norford, L.; Britter, R.. “The rise of low-cost sensing for managing air pollution in cities”, *Environ. Int.*, vol. 75, pp. 199-205, 2015.
- Lin, B., Recke, B., Knudsen, J. K. H., & Jørgensen, S. B. (2007). A systematic approach for soft sensor development. *Computers and Chemical Engineering*, 31, 419–425.
- Liu, C., Ren, W., Zhang, B., & Lv, C. (2011). The application of soil temperature measurement by LM35 temperature sensors. *Proceedings of 2011 International Conference on Electronic & Mechanical Engineering and Information Technology*. doi:10.1109/emeit.2011.6023459
- Lotufo, F. A.; Garcia, C (2008). *Sensores Virtuais ou Soft Sensors: Uma Introdução*. 7th Brazilian Conference on Dynamics, Control and Applications. Presidente Prudente, SP: [s.n.]. p. 1-11.
- McAvoy, T. (2002). Intelligent “control” applications in the process industries. *Annual Reviews in Control*, 26(1), 75– 86.
- Monteiro, N., Silva, J., Neto, J. S. R. (2014). *Sensor Virtual Aplicado ao Monitoramento e Controle de Temperatura de uma Estufa*. Universidade Federal de Campina Grande, Departamento de Engenharia Elétrica.
- Mota, L. O., Costa, D. G., Rocha, K. A., Wisnieswsk, A., Souza, D. F. S., Junior, A. M. O (2016). *Aplicação de Sensores Virtuais em uma Coluna de Destilação para a Predição e Controle da Qualidade*. XVI Encontro Brasileiro sobre o Ensino de Engenharia Química. Fortaleza.
- Paula, J. S., Martins, R. L. (2018). *Modelagem de Sensor Virtual via Redes Neurais Artificiais*.
- Rani, A.; Singh, V.; Gupta, J. R. P. (2013). Development of Soft Sensor for Neural Network Based Control of Distillation Column. *ISA Transactions*, v. 52, p. 438-449.
- Rosenblatt F (1957), “The Perceptron: A Perceiving and Recognizing Automation”, Technical Report 85-460-1, Cornell Aeronautical Laboratory.
- Rumelhart D.E., McClelland J.L., and the PDP Research Group. “Parallel Distributed Processing: Exploration in the Microstructure of Cognition, vol. 1. MIT Press, Cambridge, Massachussetts, 1986.

Silva, F. L., Vasconcelos, J. S., Vasconcelos, A. C. S. (2017). Dispositivo Sensorial Olfativo Associado à Rede Neural Artificial para Identificação de Contaminantes no Leite. XIII Simpósio Brasileiro de Automação Inteligente. Porto Alegre.

Tham, M.T., Montague, G.A., Morris, A.J., and Lant, P.A (1991). Soft-sensors for process estimation and inferential control. *Journal of Process Control*, 1(1), 3–14.

Von Zuben, F. J. (2008). Modelos e Aplicações de Redes Neurais Artificiais (Parte I). Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ea072_2s08/notas_de_aula/toico1.2_08_Partell.pdf>. Acesso em: 26 de Março de 2019.

Von Zuben, F. J. (2008). Modelos e Aplicações de Redes Neurais Artificiais (Parte II). Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ea072_2s08/notas_de_aula/topico1.2_08_Partell.pdf>. Acesso em: 26 de Março de 2019.

Von Zuben, F. J. (2008). Modelos e Aplicações de Redes Neurais Artificiais (Parte III). Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ea072_2s08/notas_de_aula/topico1.2_08_Partell.pdf>. Acesso em: 26 de Março de 2019.

Zanata, D. R. P. (2005). Desenvolvimento de Sensor Virtual Empregando Redes Neurais para Medição da Composição em uma Coluna de Destilação. Escola Politécnica da Universidade de São Paulo. São Paulo, p. 245.