

ESTIMATIVA DA SENSIBILIZAÇÃO DE VARIÁVEIS INDEPENDENTES EM PROCESSOS INDUSTRIAIS, POR MEIO DE IDENTIFICAÇÃO DE SISTEMAS, UTILIZANDO REDES NEURAS ARTIFICIAIS¹

Helder Vago²

Marcelo Lucas Pereira Machado³

Resumo

Esse artigo apresenta uma forma de estimar a significância de variáveis independentes em processos industriais, por meio de identificação de sistemas, mapeados por Redes Neurais Artificiais (RNA) de forma a estabelecer uma metodologia que venha a contribuir no domínio das relações entrada-saída de processos metalúrgicos. Neste trabalho emprega-se RNA com arquitetura feedforward multicamadas; função de ativação Tangente Hiperbólica na camada intermediária e Linear na camada de saída. Os algoritmos de Levenberg-Marquardt (backpropagation), de Gradiente Descendente e a técnica de cross-validation são empregados para o treinamento/aprendizado. O primeiro estágio do estudo é a análise do mapeamento, por meio de RNAs, para funções simuladoras de processos a partir de dados sintéticos. As sensibilidades obtidas para as variáveis sintéticas foram compatíveis com os erros gerados nas saídas quando as variáveis eram consideradas inexistentes no processo, o que caracterizou a boa performance para a técnica proposta. O estágio seguinte é a aplicação da técnica no mapeamento da laminação a quente de Aço C-Mn, por meio de dados empíricos. Os resultados orientam as variáveis críticas do processo analisado.

Palavras-chave: Sensibilização; Identificação de sistemas; Redes neurais artificiais; Processos metalúrgicos.

ESTIMATE OF AWARENESS OF INDEPENDENT VARIABLE IN INDUSTRIAL PROCESSES BY MEANS OF IDENTIFICATION SYSTEM USING ARTIFICIAL NEURAL NETWORKS

Abstract

This article presents a way to estimate the significance of independent variables in industrial processes, by means of system identification, mapped by Artificial Neural Networks (ANN) in order to establish a methodology that will contribute in the field of input-output relationships of metallurgical processes. Multilayer feedforward ANN architecture is employed in this work with Hyperbolic Tangent activation function in the intermediate layer and Linear in output layer. The Levenberg-Marquardt (backpropagation), Descendent Gradient algorithms and technique of cross-validation are employed for training / learning. The first stage of the study is the analysis of mapping, using RNAs, for functions that simulate the processes by synthetic data. The sensitivities obtained for the synthetic variables were consistent with the errors generated at the outputs when variables were considered nonexistent in the process, which characterized the good performance for the proposed technique. The next stage is the application of the technique in the mapping of hot rolling C-Mn Steel, by means of empirical data. The results guide through the critical process variables analyzed.

Keywords: awareness, identification systems, artificial neural networks, metallurgical processes.

¹ *Contribuição técnica ao 17º Seminário de Automação e TI Industrial, 24 a 27 de setembro de 2013, Vitória, ES, Brasil.*

² *Engenheiro Elétrico, Professor de Automação Industrial do Instituto Federal do Espírito Santo (IFES), Vitória, ES, Brasil.*

³ *Engenheiro Metalúrgico, Dr. Professor do Programa de Mestrado em Engenharia Metalúrgica e Materiais do Instituto Federal de Espírito Santo (IFES), Vitória, ES, Brasil.*

1 INTRODUÇÃO

A conjuntura econômica mundial globalizada proporcionou intercâmbio de informações e globalização de produtos e consumidores provocando a concorrência entre as empresas que exigiu suas adequações quanto à necessidade de atingir maior número de mercados; adaptar suas estruturas de custos e seus sistemas produtivos para a melhoria contínua da produtividade; instalação e desenvolvimento de inovação tecnológica entre outros.⁽¹⁾ Segundo Campos e Teixeira,⁽²⁾ "uma das áreas tecnológicas fundamentais para se aumentar a rentabilidade das unidades é a de controle, automação e otimização de processos industriais". Dentre as diversas atividades desta área destaca-se a operacionalização de certas variáveis pertencentes ao sistema industrial, geralmente desejando-se mantê-las dentro de limites operacionais desejáveis. Estas variáveis podem ser as denominadas dependentes que sofrem os efeitos do tratamento do processo provocados pelas variáveis independentes, resultado de uma inter-relação causal no processo industrial. Estes efeitos podem ser observados nas medições das variáveis dependentes.⁽³⁾ Essa inter-relação causal entre as variáveis pode ser expressa por meio de um modelo matemático de aproximação do processo real. Existem diversas técnicas de se obter o modelo (modelagem) de um processo. Uma delas é a modelagem caixa-branca, utilizando métodos clássicos de modelagem de processos, que exige que se conheça bem o sistema a ser modelado, como as leis físicas, químicas ou de outras áreas científicas pertinentes ao processo.⁽⁴⁾ A identificação de sistemas é uma outra forma de modelagem. Uma das características da identificação é que pouco ou nenhum conhecimento prévio do sistema é necessário, o que a identifica como modelagem caixa-preta ou modelagem empírica.⁽⁵⁾ Podem haver vários motivos para se estabelecer as descrições matemáticas de um sistema dinâmico: concepção de sistema de predição, simulação, controle e detecção de falhas, entre outros. Segundo Aguirre,⁽⁵⁾ "frequentemente não se conhece todas as equações envolvidas no funcionamento de um determinado sistema" ou seria impraticável levantar tais equações, tornando assim o estudo de técnicas de identificação muito interessante e relevante. Outro problema significativo na modelagem de processos é o fato de que todos os sistemas a princípio são não lineares e a maior parte da literatura sobre a identificação de sistemas trata da identificação de sistemas lineares. Desta forma, as ferramentas matemáticas disponíveis para análise de sistemas não lineares normalmente utilizam técnicas de linearização, transformando as características não lineares em pequenas tarefas lineares. Segundo Braga, Carvalho e Lurdemir,⁽⁶⁾ "apesar de muitas vezes eficiente, essa abordagem não retrata a realidade dos sistemas físicos, podendo resultar em soluções subótimas". Ao se buscar uma técnica que execute razoavelmente bem e de forma prática uma identificação, certo tipos de RNAs parecem ser uma excelente escolha. Em especial, a rede Perceptron Multicamadas ganhou uma imensa popularidade pois possui uma capacidade impressionante de aproximação de funções.⁽⁷⁾ Uma RNA representa um mapeamento entre os seus espaços de entrada e de saída: pode ser tanto uma relação linear, quanto uma relação altamente não linear. O que determina esse mapeamento são a sua estrutura, organização dos neurônios, suas conexões, e a função associada a cada neurônio.⁽⁸⁾ Os trabalhos efetuados em identificação de sistemas utilizando RNA tem mostrado boa eficiência, alta velocidade de resposta e confiabilidade em seus resultados em diversas áreas tecnológicas, financeiras, alimentícias, entre outras. A técnica de Sensibilização de Variáveis Independentes é

efetivada por meio da simulação em uma RNA treinada para mapeamento de funções. Este treinamento, a partir dos padrões de entrada-saída, é capaz de memorizar e generalizar o processo em estudo. A proposta do presente estudo é avaliar uma metodologia para estimativa de variáveis críticas em processos industriais identificando suas significâncias no processo, mapeados por RNAs. Inspirado nesta necessidade, este artigo primeiramente proporciona a identificação, caracterização e seleção de RNAs quanto às suas aplicações como mapeadoras de funções. A seguir verifica as performances das RNAs como mapeadoras de funções de simulação que geram dados sintéticos para análise do estudo. Subsequentemente, estima as variáveis independentes de maior e de menor significância em uma função de simulação por meio da análise da sensibilidade deste tipo de variável. A validação destes resultados é feita por meio da comparação dos valores obtidos pela simulação da "eliminação" da variável no processo. Por fim, a técnica é aplicada no processo de laminação a quente de Aço C-Mn, estimando a sensibilização de suas variáveis independentes. O estabelecimento de uma RNA consiste das seguintes etapas: coleta de dados, que compõem o conjunto de padrões de ensaio; desenvolvimento da topologia da rede; treinamento (formação); e, finalmente, estabelecimento do desempenho do modelo da RNA, comparando-se a predição (saídas) da rede para padrões não utilizados no treinamento ou teste.⁽⁹⁾ Cada apresentação completa das amostras do subconjunto de treinamento é chamada de "época". As épocas são repetidas até que o erro se torne pequeno ou um critério de parada seja satisfeito.⁽⁹⁾ Uma vez ajustadas, as RNAs passam a ter a habilidade de produzir saídas adequadas para entradas que não estavam presentes no seu treinamento, desde que tais entradas sejam oriundas do mesmo tipo de população alvo do problema. Esta nada mais é do que a característica de generalização da rede, ou seja, da capacidade de fornecer respostas coerentes a padrões ou casos novos.⁽¹⁰⁾ Uma RNA pode ser representada conforme Figura 1, onde podem ser vistas suas partes componentes: camada de entrada, camadas intermediárias e camada de saída com seus respectivos neurônios.




Figura 1 - Representação de uma RNA: entradas " x_i "; 1ª camada intermediária com " n_1 " neurônios; 2ª camada intermediária com " n_2 " neurônios; camada de saída com n neurônios igual à quantidade de saídas.⁽¹¹⁾

A arquitetura de uma RNA considera a disposição dos neurônios, as formas de interligação destes e a constituição de suas camadas. As principais camadas de uma RNA são: a de entrada, constituída pelos próprios padrões de entrada, para recebimento das informações; as intermediárias, que extraem as características associadas ao processo a ser inferido; e a de saída, para produção e apresentação dos resultados finais da rede. A determinação da topologia de uma RNA envolve escolher: as variáveis de entrada, o número de neurônios, o número de camadas, o tipo da função de ativação e as conexões necessárias⁽⁵⁾. A função de ativação linear,

utilizada na camada de saída, trata a RNA como aproximadoras universais de funções.⁽¹¹⁾ Um das técnicas estatísticas mais utilizadas para seleção das melhores topologias é a validação cruzada (*cross-validation*) cujo propósito é avaliar a performance da rede: a RNA candidata é treinada com um conjunto de dados e sua validação é testada por um outro conjunto de dados diferente daquele usado no ajuste de seus parâmetros internos.⁽¹¹⁾ No software Matlab®, versão 7.12.0.635 (R2011a), verifica-se a divisão dos padrões, por meio da ferramenta "nntool" em três grupos: treinamento, com 70% dos padrões; validação, com 15% dos padrões; e teste, com 15% dos padrões. O treinamento é usado para ajustar os pesos. Os padrões de validação são utilizados para verificação da convergência das saídas e ajuste dos pesos. Os padrões de teste são usados como uma verificação adicional de que a RNA apresenta uma boa generalização; mas não tem efeito algum sobre o treinamento. Erros pequenos indicam uma topologia de RNA com chances de bom treinamento e boa predição de resultados.⁽⁹⁾ Braga, Carvalho e Lurdemir⁽⁶⁾ explicam que o treinamento/aprendizado supervisionado se aplica a pesquisa de mapeamento entre padrões de entrada e de saída. O exemplo mais conhecido deste tipo de algoritmo para redes de múltipla camadas é o algoritmo *backpropagation*. Silva, Spatti e Flauxino⁽¹¹⁾ demonstram que, se a função de ativação for do tipo logística ou tangente hiperbólica, uma topologia de Perceptron MultiCamadas (PMC), constituída de apenas uma camada neural intermediária é capaz de mapear qualquer função contínua. As RNAs PMC, um tipo de arquitetura *feedforward*, são caracterizadas pela presença de pelo menos uma camada intermediária de neurônios, situada entre a camada de entrada e a de saída. São consideradas uma das arquiteturas mais versáteis quanto à aplicabilidade.⁽¹¹⁾ Devido às características não-lineares inerentes ao mapeamento entre camadas de RNAs *feedforward*, estas se constituem em ferramentas bastante apropriadas para a modelagem e o controle de sistemas.⁽⁶⁾ A especificação de topologia de rede PMC mais apropriada para mapear um problema específico é usualmente efetuada de forma empírica, pois devem ser considerados o algoritmo de aprendizagem utilizado, a forma como as matrizes de peso foram iniciadas, a complexidade do problema a ser mapeado e a qualidade do conjunto de treinamento disponível.⁽¹¹⁾ Segundo Braga, Carvalho e Lurdemir⁽⁶⁾ o algoritmo *backpropagation* padrão requer que todos os padrões de treinamento sejam apresentados centenas ou até milhares de vezes tornando-o muito lento limitando sua utilização prática. O método de Levenberg-Marquardt, baseado no método dos mínimos quadrados para modelos não lineares, com uma taxa de aprendizado variável, é uma das variações do método *backpropagation* com o objetivo de tornar o processo de convergência mais eficiente. Este é um método de gradiente descendente.⁽¹¹⁾ Gorni⁽¹²⁾ em seu estudo de previsão de propriedades mecânicas em bobinas laminadas a quente, usou RNA *feedforward* com uma camada intermediária com função de ativação Tangente Hiperbólica, e camada de saída com função de ativação Linear. O resultado geral de modelagem obtido mostrou que usando-se RNAs obteve-se melhor precisão de cálculo do que equações obtidas por regressão linear múltipla, o que comprovou a maior capacidade das RNAs em lidar com relações não lineares entre as variáveis envolvidas. O desempenho (performance) da RNA é fornecido por meio do Erro Médio Quadrático (MSE ou EMQ) de acordo com a média do quadrado dos erros (Matlab®). A análise da Sensibilidade é feita para cada variável independente do sistema a partir da RNA treinada, que representa o modelo do sistema. Ela estima a participação da variável independente em alterações das variáveis dependentes. A variável independente "x_i" escolhida é acrescida em 5% nos seus valores que

substituem os valores anteriores usados no treinamento da rede. Este novo conjunto padrão de entrada é então simulado na RNA já treinada. É feita a diferença entre os novos valores de saída obtidos na simulação e os valores de saída desejados. Finalmente determina-se a média dessas diferenças obtendo-se a Sensibilidade Média (SENS_i) da variável independente "x_i" em questão,⁽¹²⁾ conforme expressão:

$$SENS_i = \frac{1}{N} \sum_{i=1}^N (y_i - d_i) \quad (1)$$

onde: N: número de padrões; y: valor da saída simulada na RNA com a alteração da respectiva entrada "x_i"; d: valor original da saída do sistema, sem alteração nos padrões.

Este processo é feito para cada variável independente do sistema. Quanto maior é a Sensibilidade Média, maior é o efeito da variável independente considerada. Uma outra forma de apresentar esta influência é pela Sensibilidade Média Normalizada (SENSN_i), obtida pela expressão:

$$SENSN_i = SENS_i / \sum_{i=1}^N |SENS_i| \quad (2)$$

2 MATERIAIS E MÉTODOS

A partir dos diversos tipos de RNA disponíveis foi feita uma análise para identificar, caracterizar e selecionar os que atenderiam às solicitações da modelagem (identificação) de um sistema. As características buscadas são: a análise será estática de um processo com padrões de entrada-saída, ou seja, haverá treinamento supervisionado para determinação da modelagem; o treinamento será off-line em malha aberta implicando à não necessidade de realimentação na rede, nem da dinâmica do processo; conforme orientação pesquisada inicia-se a topologia com uma camada escondida, que proporciona maior velocidade aos treinamentos. O trabalho será feito a partir do software Matlab®, versão 7.12.0.635 (R2011a), de onde serão analisadas as possíveis RNAs. A rede que atende às solicitações é *feedforward* a ser ensaiada com uma camada intermediária, com: 3 neurônios: igual ao número de entradas e 7 neurônios, conforme método de Kolmogorov "n=2.p+1" onde: n=número de neurônios; p= número de entradas.⁽¹³⁾ Objetiva-se com este procedimento verificar a influência do número de neurônios da camada intermediária nas respostas da rede. Para verificar a melhor resposta quanto às funções de ativação, serão utilizadas funções linear e não lineares na camada intermediária, e função linear na camada de saída, da seguinte forma: linear (LIN) na camada intermediária e linear na camada de saída, caracterizada por LIN/LIN; logística (LOG) na camada intermediária e linear na camada de saída, caracterizada por LOG/LIN; tangente hiperbólica (TANH) na camada intermediária e linear na camada de saída, caracterizada por TANH/LIN. Cada RNA será treinada cinco vezes na tentativa de obter um erro satisfatório, usando a *cross-validation*. A princípio serão utilizadas quatro expressões aritméticas, representando modelos lineares (F1) e não lineares de crescentes graus de complexidade (F2), (F3) e (F4), para verificar a capacidade de resposta das redes para níveis diferentes de dificuldades no modelo. Os padrões são no formato (x₁, x₂, x₃, d), ou seja, três entradas e uma saída desejada

em cada amostra, utilizados nas funções e caracterizados como dados sintéticos.⁽¹⁴⁾ As funções utilizadas para o treinamento da redes são:

$$F1: y = 15.x1 + 2.x2 + 10.x3,$$

$$F2: y = x1^2 + 3.x2 + 10.\sqrt{x3}$$

$$F3: y = x1^2 + \sqrt{x2} + x3^2;$$

$$F4: y = e^{x1/5} + x2/4 + 4.x3$$

onde "y" é a resposta da rede às entradas (x_1, x_2, x_3). As faixas de variações destas variáveis serão estipuladas de forma a equivaler às variações possíveis encontradas em modelos práticos, e que possam proporcionar diferenciação nas análises finais:

$$\begin{aligned} 20 \leq x_1 \leq 30; \\ 1300 \leq x_2 \leq 1500; \\ 80 \leq x_3 \leq 100. \end{aligned}$$

Os tipos de funções da RNA utilizados serão:

- Função de treinamento: *Levenberg-Marquardt (LM)*;
- Função de aprendizagem: *gradiente descendente com função de aprendizado para pesos e limiares (GDM)*;
- Função de performance: *erro médio quadrático normalizado (MSE)*;

A continuidade dos estudos será feita com as simulações das funções em RNAs de topologias que mapeiem estas funções, com performances que apresentem erros da ordem de 10^{-2} ou abaixo desta ordem⁽⁹⁾ possibilitando a seleção das RNA(s) apta(s). Posteriormente cada amostra independente " x_i " a ser testada terá seu valor acrescido de 5% e, juntamente com o restante do padrão de entrada, será simulada nas redes treinadas e selecionadas. Serão calculadas as diferenças entre os resultados de saídas "y" obtidos por meio dessa simulação e os valores de saídas originais "d". O valor da Sensibilidade Média para cada variável independente será obtido pela expressão (1) e o da Sensibilidade Média Normalizada pela expressão (2). A título de investigação para confirmação das Sensibilidades encontradas, uma nova simulação será feita: com essa mesma rede treinada anteriormente, serão alterados para zero, "0", os valores das entradas, uma a cada vez, no padrão original e, juntamente com o restante do padrão de entrada será simulada nas redes treinadas e selecionadas afim de obter os novos valores das saídas. Supõe-se, desta forma, que a variável não participa do processo ou que não tem significância para a saída. Após a simulação, considerando-se "y_i", o valor da saída do padrão "i" simulado com a respectiva variável " x_i "=0, e "d_i" o valor original desta mesma saída; um valor de erro é obtido para cada padrão, por meio de:

$$e = \frac{1}{N} \sum_{i=1}^N \frac{|d_i - y_i|}{d_i} \quad (3)$$

para os "N" padrões. Este erro representa a variação da saída da rede em função da não existência (valor=0) da entrada em análise; e representa uma forma alternativa de análise desta variação da saída.

A técnica será, então, aplicada a 184 padrões empíricos de Aço C-Mn laminados a quente. Cada padrão é composto de 3 entradas - temperatura de entrada do aço no laminador ($^{\circ}\text{C}$), redução da laminação e velocidade linear do cilindro (m/s); e 1 saída - força de laminação (kN). Considerando "Ee" o valor da espessura de entrada e "Es" a espessura de saída do aço no laminador, a redução foi calculada por: $(Ee - Es)/Ee$.

3 RESULTADOS

Foram treinadas as RNAs conforme arquitetura (*feedforward*) e topologias estabelecidas, e encontradas as performances para as funções F1, F2, F3 e F4, em 5 treinamentos cada. O Quadro 1 identifica as topologias que atenderam à solicitação de performance da RNA.

Quadro 1. Identificação das topologias das RNAs treinadas, que apresentaram performances com erro na ordem de 10^{-2} , no mapeamento das funções em análise

FUNÇÕES	TOPOLOGIAS					
	diferentes funções de ativação e nº de neurônios					
	LIN/LIN		LOG/LIN		TANH/LIN	
	3	7	3	7	3	7
F1	X	X	X	X	X	X
F2			X	X	X	X
F3				X	X	X
F4			X	X	X	X

A indicação "X" no Quadro 1 identifica o proposto atendimento da topologia ao mapeamento da respectiva função e pode-se verificar, então, que as topologias que atendem às solicitações a todas as funções são: LOG/LIN de 7 neurônios; TANH/LIN de 3 neurônios; e TANH/LIN de 7 neurônios. A princípio, será escolhida a topologia de TANH/LIN, por ser satisfatória, independente do número de neurônios; de 7 neurônios, conforme Método de Kolmogorov, para simulações nas análises de sensibilização das variáveis independentes na função F3, que apresenta maior complexidade. Os resultados para cada treinamento, são fornecidos pelo software, tais como: performance da rede; erro de correlação no treinamento, teste e validação; e parâmetros de treinamento. A seguir cada amostra independente " x_i " terá seu valor acrescido de 5% e, juntamente com o restante do padrão de entrada, será simulada nas redes treinadas e selecionadas. As Figuras 2, 3 e 4 apresentam os valores originais das saídas e os respectivos valores de saída após a alteração da entrada relacionada.




Figura 2 - Comparação gráfica entre as saídas correspondentes às alterações, pelo acréscimo de 5% na entrada " x_1 ", e as saídas originais.

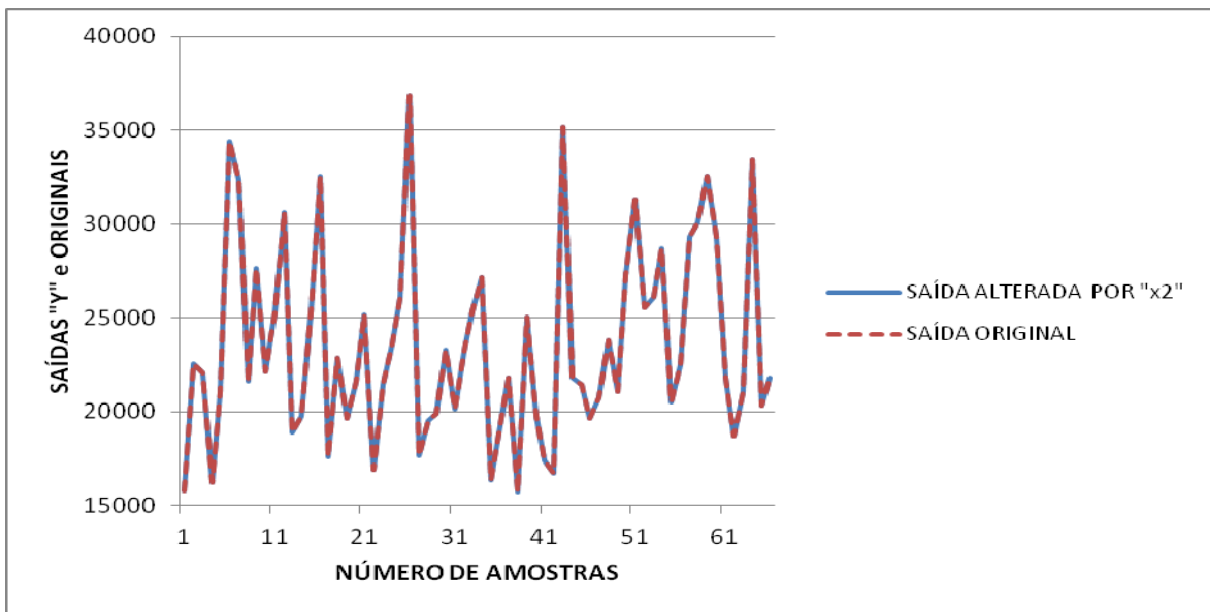


Figura 3 - Comparação gráfica entre as saídas correspondentes às alterações, pelo acréscimo de 5% na entrada " x_2 ", e as saídas originais.

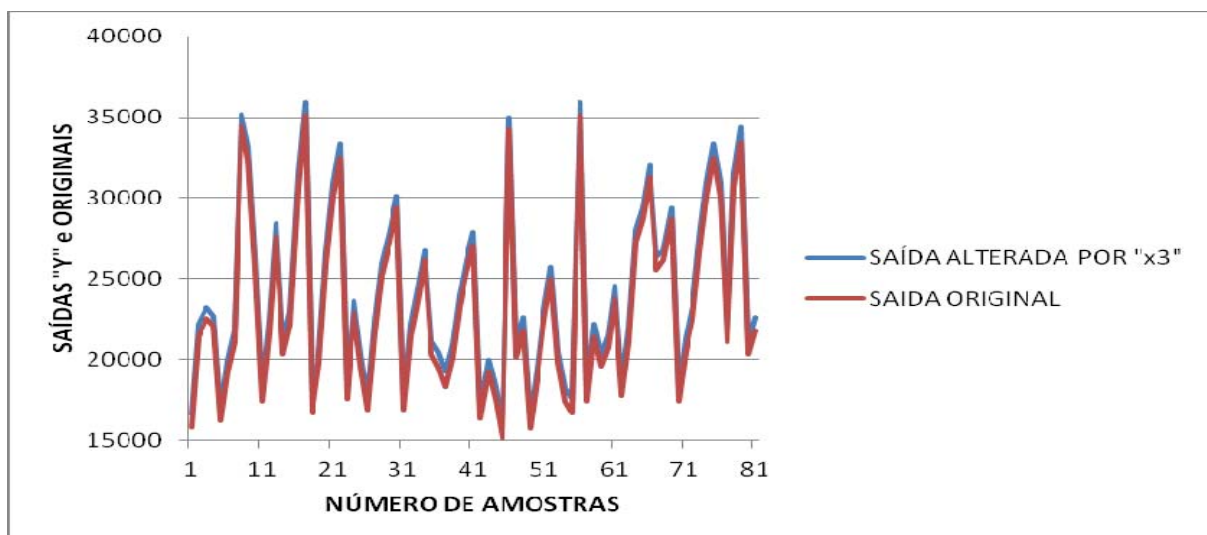


Figura 4 - Comparação gráfica entre as saídas correspondentes às alterações, pelo acréscimo de 5% na entrada " x_3 ", e as saídas originais.

Verifica-se que a variação na variável dependente ocorreu com menor intensidade pela variável " x_2 ", conforme Figura 3, e com maior intensidade pela variável " x_1 ", conforme Figura 2. A variação da variável " x_3 " provocou variação intermediária na variável dependente, conforme Figura 4. A partir dos resultados do procedimento anterior foram obtidos os valores das Sensibilidades Médias ($SENS_i$) e as Sensibilidades Médias Normalizadas ($SENSN_i$) de cada variável independente em análise, apresentados na Tabela 1.

Tabela 1. Valores das Sensibilidades Médias e Médias Normalizadas para cada variável independente

VARIÁVEL	SENS	SENSN (%)
X1	2218	73,63
X2	0,9377	0,03
X3	793	26,33

Foi investigado o efeito da não existência (zerada) de cada variável independente na variável dependente por meio do erro médio obtido nesta simulação em comparação com a situação original. Para uma análise comparativa foi obtido este mesmo erro para as saídas do treinamento da rede, apresentado na Tabela 2.

Tabela 2. Valores dos erros para o treinamento e para cada situação de não existência da variável independente no processo.

SITUAÇÃO	TREINA- MENTO	VARIÁVEL INDEPENDENTE "ZERADA"		
		X1	X2	X3
ERRO (%)	0,0011	70,7	0,0892	40,7

A Tabela 3 evidencia que o erro de treinamento, de 0,0011%, é muito menor do que os erros obtidos com a alteração das variáveis independentes. Pela Tabela 3 podemos comparar os resultados da Sensibilidade Média Normalizada e dos erros obtidos com a simulação de variáveis independentes "zeradas".

Tabela 3. Valores de SENS e ERROS de apresentados por cada Variável Independente.

VARIÁVEL INDEPENDENTE	SENS %	ERRO %
X1	73,63	70,7
X2	0,03	0,0892
X3	26,33	40,7

A Tabela 4 apresenta os valores das Sensibilidades Médias e Normalizadas para as variáveis do processo de laminação do Aço C-Mn.

Tabela 4. Valores de Sensibilidades Médias e Normalizadas na de Laminação de Aço C-Mn

VARIÁVEL INDEPENDENTE	SENSIBILIDADE MÉDIA SENS	SENSIBILIDADE MÉDIA NORMALIZADA SENS(%)
Temperatura de Entrada "Te"	-9067	-57,4
Redução "r"	3351	21,2
Velocidade do passe "v"	3389	21,4

4 DISCUSSÃO

Com base nos procedimentos praticados e nos resultados observados, pode-se verificar que:

a) pelo Quadro 1, todas as funções de ativação utilizadas atendem a modelos lineares (F1);

b) pelo Quadro 1, os modelos não lineares F2, F3 e F4 não tiveram performance satisfatórias quando treinados numa topologia de função de ativação linear (LIN) na camada intermediária;

c) pelo Quadro 1, as funções de ativação Logística (LOG) e Tangente Hiperbólica (TANH), em camadas de 7 neurônios atendem aos modelos não lineares de diferentes complexidades, como F2, F3 e F4;

d) pela Tabela 1 verifica-se que a simulação do modelo F3 ($y = x_1^3 + \sqrt{x_2} + x_3^4$) mostra que a variável independente "x₁" tem maior significância ao provocar maiores variações na variável dependente visto que sua Sensibilidade Média (SENS₁=2218) e sua Sensibilidade Média Normalizada (SENSN₁=73,6%) foram as de maior valor. Este fato evidencia a importância de flutuações desta variável no processo em cuja modelagem está elevada à potência 3 (x₁³). A variável "x₂", apesar de ter maior valor absoluto em sua faixa de variação (1300 ≤ x₂ ≤ 1500) acabou por ter pouca significância neste modelo pois sua Sensibilidade Média (SENS₂=0,9377) e sua Sensibilidade Média Normalizada (SENSN₂=0,03%) apresentaram os menores valores entre as variáveis independentes. O modelo F3 em análise aplica a função de radiciação na variável "x₂" ($\sqrt{x_2}$) o que faz com que sua influência em variações na variável dependente seja pequena; desta forma fica caracterizada a variável independente "x₁" como a crítica deste processo;

e) pela Tabela 2 pode-se verificar que os erros obtidos "zerando" cada uma das variáveis é maior do que o erro de treinamento da RNA, o que garante que não existe influência da rede nestes erros. O valor do erro obtido par as saídas nessa nova situação com relação aos valores originais foi bem pequeno (0,0892%) para a

variável " x_2 " e muito significativo para a variável " x_1 " (70,7%). Comparando-se estes valores relativos às variáveis independentes e suas respectivas Sensibilidades Médias Normalizadas, apresentados na Tabela 3 infere-se a grande relação que existe entre eles. A variável " x_1 ", de maior sensibilidade apresentou o maior erro; e a variável " x_2 ", de menor sensibilidade, apresentou o menor erro. Desta forma, a validação da utilização da técnica da sensibilização em dados sintéticos fica confirmada por meio na Tabela 3 que apresenta a comparação dos resultados obtidos por meio da sensibilização que são compatíveis com os obtidos pela eliminação (valor=0) das entradas respectivas.

f) pela Tabela 4 observa-se que a técnica indica que a variável crítica na laminação em questão é a temperatura de entrada do aço no laminador, cuja variação é responsável por 57,2% de variação na força de laminação. O sinal negativo indica que as variações tem sentido contrário: aumentando a temperatura, reduz a força de laminação. Este tipo de informação pode auxiliar em investimentos de controle de processo mais eficazes.

5 CONCLUSÃO

a) após considerações de arquitetura e topologia a RNA treinada conseguiu aprender o modelo pela identificação do sistema e generalizar (apreender) este modelo quando foram simuladas essas novas situações de 5% de variação em entrada dos padrões; logo as RNAs representam boas ferramentas para mapeamento de funções pois conseguem armazenar, via algoritmo e de forma oculta, uma identificação satisfatória de um modelo, preservando sua generalização, podendo ser simulado a qualquer momento;

b) as funções de ativação do tipo Tangente Hiperbólica e Logística podem ser utilizadas na camada intermediária e a Linear na camada de saída apresentando boa performance, confirmando o já citado na revisão da literatura;

c) A Sensibilidade da variável independente é representativa da significância desta variável no processo. Os valores obtidos são coerentes com as funções simuladas. Esta Sensibilidade mostra a estimativa da variável independente mais representativa quanto a estimativa da de menor significância. A variável de Sensibilidade de maior valor indica a que tem maior representação na variável dependente em estudo que justificaria, por exemplo, investimentos em seu controle. A de menor sensibilidade pode indicar que nem precisa ser considerada a sua influência na variável dependente;

d) a aplicação da técnica de Sensibilização via RNA a processos industriais, tal como a laminação a quente, traz informações diretrizes para a indústria.

REFERÊNCIAS

- 1 TUBINO, Dalvio Ferrari. **Manual de Planejamento e Controle da Produção**. 2. ed. São Paulo: Atlas, 2000.
- 2 CAMPOS, Mario C. M. M. de; TEIXEIRA, Herbert C. G. **Controles Típicos de Equipamentos e Processos Industriais**. São Paulo: Editora Blucher, 2006.
- 3 GRESSLER, Lori Alice. **Introdução à Pesquisa: projetos e relatórios**. 2.ed. São Paulo: Loyola, 2004.
- 4 GARCIA, Cláudio. **Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos**. 2. ed. São Paulo: Editora da Universidade de São Paulo, 2005.
- 5 AGUIRRE, Luis A. **Introdução à Identificação de Sistemas - técnicas lineares e não lineares aplicadas a sistemas reais**. 3. ed. Belo Horizonte: Editora UFMG, 2007.

- 6 BRAGA, Antonio de P.; CARVALHO, André P. de L. F. de ; LUDERMIR, Teresa B. **Redes Neurais Artificiais** - teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 2007.
- 7 NORGAARD, M.; RAVN, O.; POULSEN, N. K.; HANSEN, L. K. **Neural Networks for Modelling and Control of Dynamic Systems: a practitioner's handbook**. Grã Bretanha: Springer-Verlag London Limited, 2000.
- 8 CAMPOS, Mário M. de; SAITO, Kaku. **Sistemas Inteligentes em Controle e Automação de Processos**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2004.
- 9 PIULEAC, C. G.; RODRIGO, M. A.; CAÑIZARES, P.; CURTEANU, S.; SÁEZ, C. **Ten Steps modeling of electrolysis processes by using neural networks**. Environmental Modelling & Software, n. 25, 2010, p. 74-81.
- 10 BRAGA, Antonio de P.; CARVALHO, André P. de L. F. de ; LUDERMIR, Teresa B. **Fundamentos de Redes Neurais Artificiais**. Rio de Janeiro: DCC/IM, COOPE/Sistemas, NCE/UFRJ, 1998.
- 11 SILVA, Ivan N. da; SPATTI, Danilo H.; FLAUZINO, Rogério A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. São Paulo: Artliber, 2010.
- 12 GORNI, Antonio A.; SILVA, Marcos R. S. da; SILVEIRA, José H. D. **Previsão de Propriedades Mecânicas de Bobinas Laminadas a Quente Através de Redes Neurais**. Tecnologia em Metalurgia, Materiais e Mineração; São Paulo, v. 5, n. 4, p. 229-234, abr-jun, 2009.
- 13 HECHT-NIELSEN, R. **Neurocomputing**. Addison-Wesley, Reading, 1991.
- 14 GOMES, Gecynalda S. da S.; LUDERMIR, Teresa B. **Redes Neurais Artificiais com Funções de Ativação complemento Log-Log e Probit para aproximar funções na presença de observações extremas**. Learning and Nonlinear Models, Revista da Sociedade Brasileira de Redes Neurais (SBRN), v. 6, n. 2, p.142-153, 2008.