

MODELAGEM DA TEMPERATURA DE LAMINAÇÃO DE TUBOS SEM COSTURA ATRAVÉS DE REDES NEURAIS ARTIFICIAIS¹

*Renato R. Rocha²
Thiago E. A. Souza²
Ricardo N. Carvalho³
Paulo E. M. Almeida²*

Resumo

Este artigo descreve uma abordagem para modelagem térmica de um processo industrial de laminação de tubos de aço sem costura, através de redes neurais artificiais do tipo Multilayer Perceptron (MLP) e de base radial (RBF). Para o desenvolvimento deste modelo, foram empregados grandes conjuntos de dados reais, adquiridos na linha de produção da Vallourec & Mannesmann do Brasil, empresa tradicional da área siderúrgica com sede em Belo Horizonte, Minas Gerais. O processo em questão é apresentado, as características desejáveis do modelo são levantadas e são discutidos aspectos práticos sobre a escolha e o projeto das arquiteturas das redes usadas na implementação. São apresentados resultados práticos obtidos e finalmente são discutidas as melhorias esperadas no processo com a utilização do modelo desenvolvido.

Palavras-chave: Redes neurais artificiais; Laminação de tubos; Modelagem matemática.

¹ 60º Congresso Anual da ABM, 25 a 28 de julho de 2005, Belo Horizonte, MG

² Laboratório de Sistemas Inteligentes do CEFET-MG. Emails: {Renato, Thiago, pema}@lsi.cefetmg.br

³ V & M do Brasil S. A. Email: nolasco@vmtubes.com.br

1 INTRODUÇÃO

Os últimos dez anos no mercado tecnológico têm sido marcados por uma tentativa de aproximação cada vez maior entre as “soluções inteligentes” e os problemas e aplicações práticas. Por um lado, o meio acadêmico vem desenvolvendo há mais de cinquenta anos um leque de técnicas e ferramentas que têm, entre as suas principais potencialidades, sua capacidade de processamento não convencional de informações, de tomada de decisões autônomas e de modelagem alternativa de sistemas físicos. Por outro lado, o crescimento acentuado e o grande desenvolvimento tecnológico dos processos produtivos trouxeram como efeito colateral um aumento da complexidade dos meios de produção e de fornecimento de serviços. Criou-se então uma grande demanda de técnicas mais eficazes de operação, modelagem, controle e diagnóstico dos meios de produção. Uma premissa básica para o aumento da produtividade e da qualidade da produção é o aumento da confiabilidade e da robustez durante a operação dos processos produtivos 1.

O campo de Inteligência Artificial (IA) se manteve por muitos anos distante das preocupações imediatas da engenharia de aplicação, limitado a aplicações acadêmicas e de cunho visionário, como as teorias de jogos e o desejo de criação de uma “máquina do pensamento”, substituta eventual do pensamento humano 3. Uma trajetória convergente entre IA e o meio produtivo ficou mais evidente nos anos 80, com a popularização das técnicas hoje classificadas como integrantes do campo da inteligência computacional (IC), como as redes neurais artificiais (RNA), os sistemas *fuzzy* e a computação evolucionária, entre outros 10. O grande sucesso alcançado por essas técnicas na solução não convencional de problemas clássicos de engenharia, de computação e de otimização foi a alavanca que impulsionou de vez a aproximação das áreas de IA e de produção 13. Este artigo busca demonstrar uma vez mais o emprego dessas técnicas, especificamente de RNA, por meio de uma aplicação na indústria siderúrgica. Aqui, é descrita em detalhes uma abordagem prática para modelagem térmica de um processo de laminação de tubos existente na empresa Vallourec & Mannesmann do Brasil S.A. (V & M).

Este artigo está organizado em cinco seções, incluindo esta introdução. Na seção 2, é feito um breve histórico do emprego de RNA no meio acadêmico e na indústria. Depois, são apresentados o processo global de fabricação de tubos da V & M e o processo de laminação específico a ser modelado. Na quarta seção, a abordagem de modelagem térmica usando RNA é descrita em detalhes. Na seção 5, são apresentados os resultados alcançados, são discutidos pontos críticos desta abordagem e finalmente são sugeridas continuações para este trabalho.

2 REDES NEURAIS ARTIFICIAIS NA INDÚSTRIA

Sendo uma das áreas de desenvolvimento mais promissoras no campo de IA, o estudo das RNA iniciou-se ainda na década de 40, com o trabalho inovador de McCulloch e Pitts no desenvolvimento de elementos de processamento artificiais baseados nos neurônios do cérebro 6.

Após algumas décadas sem grandes inovações nesta área, principalmente devido ao descrédito alcançado a partir de fortes críticas feitas por alguns pesquisadores de peso na área de IA 9, John Hopfield ressuscitou a idéia das RNA na década de 80, com a criação de modelos de redes recorrentes utilizados para a resolução de problemas de otimização 5. Nos últimos anos, estes avanços começam a se refletir no meio produtivo, como mostra o levantamento de aplicações práticas de RNA feito em 8.

No meio industrial de maneira geral, há sempre uma grande preocupação com a robustez e a otimização da operação das plantas e equipamentos. Ações que proporcionem um aumento da qualidade do produto e uma redução de desperdícios são sempre desejáveis, mas difíceis de ser definidas a partir das técnicas convencionais de modelagem e de otimização. Cada vez mais, as aplicações de IA vem ocupando este espaço, como ferramentas auxiliares dentro de esquemas convencionais, ou mesmo como ferramentas principais de modelagem de aspectos de difícil abordagem.

Observa-se que grande parte dos trabalhos científicos publicados até hoje ainda carece de uma ligação estreita com as aplicações reais. Mostrar que um algoritmo de modelagem funciona bem a partir de dados gerados em computador por meio de simulação é um caminho válido, amplamente reconhecido e respaldado pela comunidade científica. Mas é preciso ter em mente que o caminho entre uma simulação com resultados satisfatórios em laboratório e uma aplicação sendo executada em tempo real e de maneira confiável em uma sala de operações da indústria é muito grande.

3 PROCESSO DE LAMINAÇÃO DE TUBOS

O processo de laminação contínua de tubos representa grande parte do consumo de energia em uma siderúrgica 6. Proporcional a este consumo é sua importância na fabricação dos tubos. Assim sendo, é de suma importância um conhecimento profundo de seu funcionamento para propiciar a operação robusta e eficiente desta etapa do processo produtivo.

3.1 Descrição de Processos de Laminação de Tubos

Em um processo de laminação contínua de tubos, são fabricados tubos de aço sem costura, a partir de lingotes de aço maciço. Estes tubos são usados nas indústrias automotiva, petrolífera e petroquímica, entre outras. Para melhor compreensão deste processo produtivo, é representado na Figura 1 um fluxograma do processo de laminação contínua de tubos da V & M.

Como matéria prima, são utilizados blocos de aço. Esses blocos são aquecidos em um forno de soleira rotativa a uma alta temperatura, que utiliza uma mistura de gás natural e gás de alto forno como combustível. Do forno, o bloco aquecido é laminado no laminador oblíquo. Depois de perfurado, o bloco se transforma em lupa que ainda será deformada em um laminador redutor de lupas e no laminador contínuo. A lupa é então encaminhada para um forno de reaquecimento e em seguida é deformada no laminador redutor estirador.

É este último processo de laminação, o laminador redutor estirador, o objeto deste estudo. Nele, várias cadeiras de laminação são colocadas umas após as outras, numa linha reta, de modo que a peça a ser laminada avança continuamente, sendo trabalhada sucessivamente nos vários passes. Passada a última cadeira, a peça já se transformou em um tubo com suas dimensões definitivas, seguindo finalmente para o resfriamento e para a linha de corte 2.

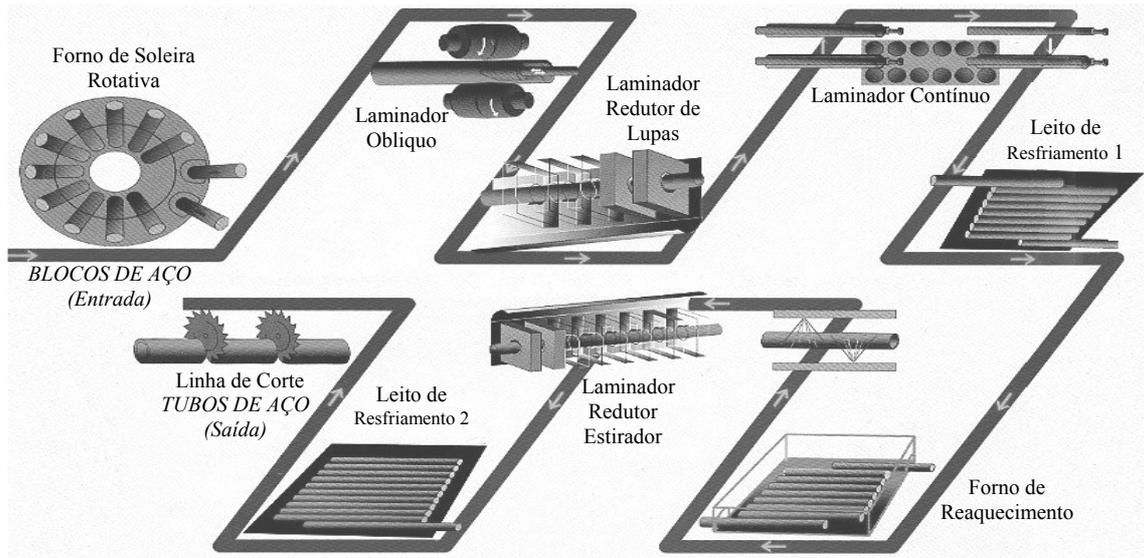


Figura 1. Fluxograma de Produção de Tubos Fonte: V & M, 2001 12

3.2 Modelagem Térmica do Processo de Laminação

Diversos problemas relacionados ao processo de laminação de aço podem comprometer significativamente a qualidade de produtos que utilizam este material. A criação de um modelo capaz de prever a variação térmica de um tubo de aço através de um laminador, levando-se em conta a variação de vários parâmetros do processo, é um passo importante para a minimização destes problemas. Um modelo térmico eficaz deve ser capaz de prever a temperatura final de um tubo após o processo de laminação, a partir de valores medidos de temperatura na entrada do processo e de parâmetros específicos do aço utilizado.

Devido à grande flexibilidade de produção da linha da V & M para fabricação de tubos, muitos parâmetros importantes para esta determinação variam de corrida a corrida durante a marcha de produção. Entre estes, pode-se destacar o tipo de aço empregado, o diâmetro do tubo, a espessura de sua parede, seu comprimento, dentre outras propriedades. Gerar um modelo que interprete estas variações, prevendo o comportamento térmico, é um trabalho complexo e dispendioso.

Normalmente, este trabalho é destinado aos engenheiros metalúrgicos, que utilizam como base o seu largo conhecimento sobre o processo e as bases de dados históricos existentes para a criação de modelos semi-empíricos. Estes modelos, via de regra, se limitam a tipos específicos de tubos ou a pontos especiais de operação do processo. Utilizando esta mesma base, procurou-se aqui mostrar o emprego de uma técnica alternativa para modelagem matemática de sistemas, para gerar um modelo único, flexível e capaz de representar com precisão o processo em questão.

Para esta tarefa de modelagem, foram utilizados dados reais fornecidos pela V & M. Uma RNA é treinada para "aprender" as relações existentes nessa massa de dados e prever a temperatura de saída de cada tubo após o processo de laminação, a partir de medições feitas na entrada e de características específicas do tipo de tubo em produção.

O ajuste de temperatura no forno de reaquecimento número 2 deve garantir que a temperatura do tubo após o laminador redutor estirador tenha um valor mínimo que não altere suas características mecânicas. A manutenção destas características é necessária para a utilização dos tubos e para que não haja problemas de trincas ou rachaduras durante o processo de corte.

Em um segundo momento, a modelagem térmica deste subsistema vai permitir a estimação da temperatura de saída e o tempo de permanência do tubo dentro do forno de reaquecimento número 2, para que se tenha uma temperatura de saída do tubo no laminador redutor estirador acima da mínima requerida. Esta modelagem também vai possibilitar estudos mais aprofundados sobre o processo produtivo e a posterior produção de tubos com novas composições químicas e características diferenciadas. Com isto, pretende-se maximizar o desempenho do processo e minimizar desperdícios de energia tanto no laminador redutor estirador quanto no forno de reaquecimento número 2.

O processo de laminação de aço é de difícil modelagem física. Com isto, tornam-se trabalhosos o controle do processo, a sua automação e as previsões a respeito de seu funcionamento. Existem vários fatores que geram estas dificuldades.

Durante a laminação dos tubos, ocorrem muitas alterações nas variáveis envolvidas no processo. À medida que a peça avança na linha de produção, suas dimensões vão sendo passo a passo alteradas. Outra variação relevante é a marcha de produção, que pode variar de acordo com a demanda e as necessidades momentâneas de manutenção ou paradas de equipamentos. Somado a tudo isto, deve-se considerar a alteração do tipo de tubo na linha de produção.

Em termos gerais, as variações físicas, químicas, espaciais e temporais tornam o processo de modelagem bastante complexo. Uma alternativa é utilizar bancos de dados já existentes e o conhecimento dos engenheiros de processo e metalúrgicos. Surgem daí modelos térmicos empíricos e semi-empíricos para a laminação de tubos. Estes modelos nem sempre são versáteis e flexíveis, o que é muito desfavorável às inovações tecnológicas e à necessidade do mercado por novos produtos 11.

Para superar todas estas dificuldades e limitações, este trabalho utiliza arquiteturas de RNA para obtenção do modelo desejado, como é descrito a partir da próxima seção.

4 MODELAGEM TÉRMICA DO PROCESSO DE LAMINAÇÃO USANDO RNA

Para utilização de RNA em uma abordagem de modelagem matemática, o primeiro passo é a seleção das variáveis relevantes ao entendimento e representação do processo. Por causa do grande número de variáveis medidas, é necessário selecionar, dentre todas, um subconjunto que apreenda as relações de troca de calor envolvidas. O conhecimento teórico auxilia nesta escolha, juntamente com análises gráficas que mostram a interdependência entre as possíveis variáveis de entrada e a variável de saída. A escolha das variáveis neste trabalho foi feita em conjunto com a equipe de técnicos responsável pelo processo de laminação na V & M.

Definidas as variáveis para construção das redes, passou-se à etapa de condicionamento dos dados adquiridos. O principal objetivo era garantir que estes dados tivessem uma relação confiável com o processo em estudo.

O projeto de uma RNA possui duas etapas importantes: a de aprendizado e a de testes. Deve-se a princípio fazer a definição da arquitetura da RNA a ser empregada, optando entre os diversos modelos de neurônios, topologias, funções de ativação dos neurônios, número de camadas de neurônios e seus respectivos números de neurônios, tipo de conexão entre estas camadas, entre outros.

A escolha entre tantas combinações deve ser cautelosa e estudada. Pôde-se perceber que não existe uma arquitetura de RNA ideal, que sempre funcione bem.

Dependendo da aplicação, pode-se deparar com RNA excelentes, que utilizadas em outro caso se mostrarão extremamente ineficientes.

Diante de vários algoritmos, alguns foram selecionados e testados. De modo geral, em problemas que podem ser mapeados em termos de uma aproximação de funções, e para redes que contêm até algumas centenas de pesos, o algoritmo de Levenberg-Marquardt tem uma velocidade de convergência muito rápida. Este algoritmo é uma derivação de segunda ordem do método geral de busca pelo gradiente da função de erro δ .

Para a implementação das arquiteturas escolhidas, foi empregada a biblioteca de RNA do aplicativo Matlab © 4. Duas arquiteturas de RNA foram testadas nos experimentos práticos aqui relatados. Uma utiliza camada única e um modelo de neurônio com funções de ativação de base radial (RBF) e a outra utiliza duas camadas e o modelo de ativação sigmoidal (MLP). O objetivo perseguido era a obtenção de uma rede com erro de modelagem inferior a 1% do valor médio da temperatura de saída dos tubos no laminador.

Na tentativa de se utilizar uma rede do tipo RBF, obteve-se a princípio resultados muito positivos durante o processo de treinamento. Mas, nos testes de generalização, o desempenho da rede não se manteve como esperado. Este resultado negativo se deve principalmente ao algoritmo de implementação utilizado pelo aplicativo em questão, que não permite muita flexibilidade para o projeto de redes RBF. A implementação aberta desta arquitetura pode render resultados melhores.

Com a utilização da rede MLP, foram obtidos bons resultados e perspectivas muito animadoras. Conseguiu-se realizar treinamentos nos quais foram encontrados baixos níveis de erro, que se mantiveram durante a generalização. O resultado de uma seção típica de treinamento de redes MLP é mostrado na Figura 2, onde é apresentada uma comparação entre a temperatura de saída medida no processo e a saída real da rede MLP treinada.

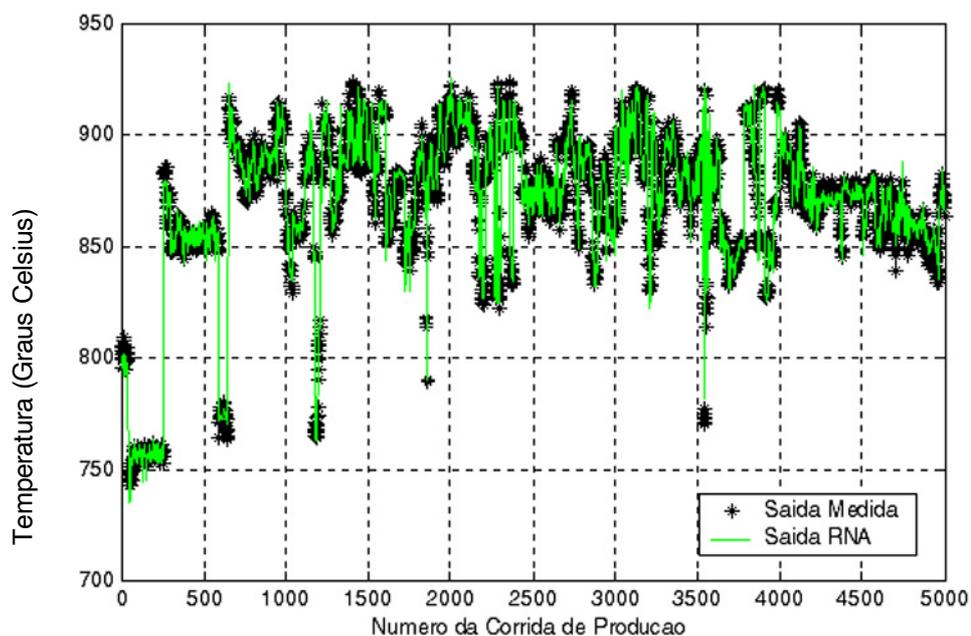


Figura 2. Resposta da rede MLP após o treinamento (teste de validação)

Muitos ajustes foram feitos até que se alcançasse o objetivo proposto. Variou-se o número de camadas, o número de neurônios de cada camada e suas respectivas funções de ativação, dentre outros fatores. Como resultado final, chegou-se a uma rede com um erro médio quadrático menor que 5°C (especificamente, $4,21^{\circ}\text{C}$). Este valor corresponde a um erro percentual de $0,57\%$, se for considerada a temperatura média de saída igual a 850° .

Analisando o treinamento através do erro, pode-se notar seu intervalo de variação. Embora não seja constante, ele está contido dentro da faixa de erro desejada, de 1% . O gráfico apresentado na Figura 3 procura mostrar esta variação e a destacar esta faixa.

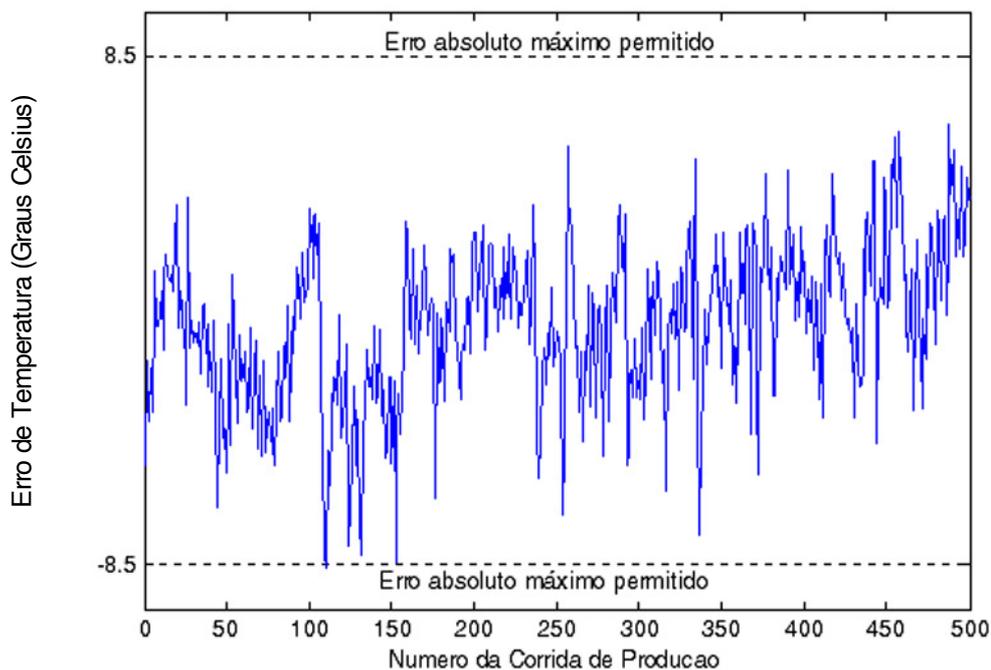


Figura 3. Análise do Erro no Treinamento.

Para uma correta análise do gráfico, deve-se salientar que o erro apresentado no gráfico da Figura 3 corresponde ao erro médio quadrático entre a temperatura dos tubos medida na saída do laminador e a saída da rede MLP treinada como modelo. Além disso, vale acrescentar que a faixa de $\pm 8,5^{\circ}\text{C}$ foi destacada propositalmente, por corresponder a uma variação de 1% da temperatura média de saída dos tubos após o processo de laminação.

Como citado anteriormente, o modelo deveria manter, em teste de generalização, um erro menor que 1% . Este valor foi escolhido devido à precisão do equipamento de medição utilizado na saída do laminador. Assim, manter a saída da rede abaixo deste valor comprova a aplicabilidade da mesma em um processo industrial, garantindo que o erro cometido pelo modelo deverá ser sempre menor que o erro de medição da temperatura. Para esta confirmação, foi feito um teste de generalização, com uma outra massa de dados, correspondendo a outro período de produção. A rede MLP forneceu a resposta mostrada na Figura 4. Este gráfico mostra uma boa aproximação entre a saída da rede e a saída desejada. O erro médio quadrático obtido foi $7,49^{\circ}\text{C}$, que corresponde a aproximadamente $0,88\%$ do valor médio de temperatura e, portanto, considerado um resultado satisfatório.

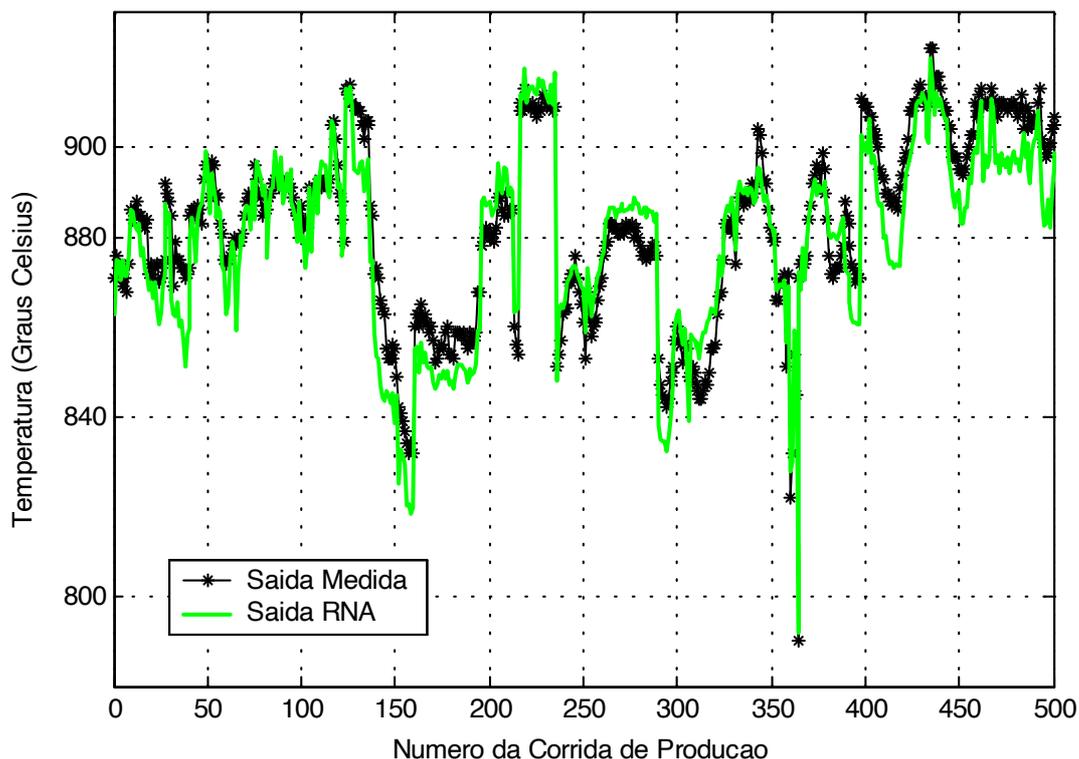


Figura 4. Resposta da rede MLP após o treinamento (teste de generalização)

Esta análise pode ser estendida se forem analisados os dados estatísticos sobre o teste de generalização realizado. Para tanto, é apresentada a Tabela 1. Observa-se por meio da Tabela 1 a proximidade entre os valores medidos de temperatura de saída dos tubos e os valores aproximados pelo modelo neural, em alguns pontos críticos do ensaio. Esta análise confirma o bom resultado alcançado pela rede MLP.

Tabela 1. Comparação Estatística entre a Saída Medida e a Saída da RNA.

Valores	Saída Medida	Saída da RNA
mínimo	790,0	791,8
máximo	922,0	919,9
média	882,4	879,5
mediana	884,0	884,5
Desvio padrão	20,27	20,39
faixa	132,0	128,1

5 DISCUSSÕES FINAIS

Este artigo procurou mostrar a aplicabilidade da utilização de RNA na indústria através de um exemplo prático. Não se buscou apenas a apresentação de um modelo específico para a área de siderurgia, mas sim a descrição de um caminho possível para a modelagem de processos industriais de maneira geral.

Foram aqui apresentados resultados de treinamento e testes de generalização de arquiteturas de RNA do tipo MLP, treinadas para modelagem térmica de um processo de laminação de tubos. As redes foram implementadas a partir da biblioteca padrão de RNA do aplicativo MatLab ©. Os conjuntos de dados utilizados foram coletados de um processo real, exemplificando uma situação prática onde as RNA surgem como uma alternativa interessante de modelagem orientada a dados.

Durante o pré-processamento da planilha de dados históricos, contendo aproximadamente 60.000 registros coletados, analisou-se as variáveis para encontrar quais tinham influência relevante na temperatura de saída do laminador. Após muitas seqüências de treinamento, foi encontrada uma condição considerada satisfatória, pois foram alcançados erros de previsão menores que os erros fornecidos pelo processo de medição de temperatura existente na planta.

A estimação da temperatura de saída dos tubos do laminador permite a realização de estudos mais aprofundados sobre a dinâmica do processo. Pode-se, por exemplo, variar a temperatura de referência do forno de reaquecimento ou a marcha de produção para economia de energia. As possibilidades de aperfeiçoamento do processo e as ações a serem tomadas com base na previsão do modelo térmico neural aqui descrito estão, no entanto, fora do escopo deste trabalho, e deverão ser discutidas em detalhes em trabalhos posteriores.

Para a seqüência deste trabalho, planeja-se a migração do código de RNA da plataforma Matlab® para uma interface industrial que possa ser utilizada pelo pessoal de processo da V & M. Além disso, estão sendo realizados testes com outras arquiteturas de RNA, com o objetivo de diminuir o tempo de treinamento necessário para a obtenção dos modelos com a precisão desejada.

Agradecimentos

Os autores gostariam de agradecer à V & M do Brasil S. A. pela cessão dos dados operacionais utilizados nos experimentos aqui descritos, e ao CNPq e CEFET-MG pelo apoio financeiro e de infra-estrutura fornecidos.

REFERÊNCIAS BIBLIOGRÁFICAS

- 1 Almeida, P.E.M. "Redes Neurais CMAC Paramétricas: Fundamentos e Aplicações em Processamento de Sinais e Controle de Processos". *Tese de Doutorado*, Escola Politécnica da USP, 2002.
- 2 Araújo, L.A. Manual de Siderurgia. Arte e Ciência, São Paulo, Vol. 2, pp.49-84, 1997.
- 3 Fernandes, A.M.R. Inteligência Artificial: Noções Gerais. *Bookstorl*, Florianópolis, 2003.
- 4 Hanselman, D. & Littlefield, B. Matlab 5 Versão do Estudante: Guia do Usuário, *Makron Books do Brasil*, São Paulo, 1999.
- 5 Hopfield, J. & Tank, D. "Neural Computation of Decisions in Optimisation Problems", *Biological Cybernetics*, Vol.52, pp.141-152, 1985.
- 6 Juvilar, J.B. Energia nos Processos Siderúrgicos. ABM, São Paulo, pp.281-319, 1980.
- 7 McCulloch, W.S. & Pitts, W. "A Logical Calculus of the Ideas Immanent in Nervous Activity". *Bulletin of Mathematics and Biophysics*, Vol.5, pp.115-133, 1943.
- 8 Meireles, M.R.G.; Almeida, P.E.M. & Simões, M.G. "A Comprehensive Review for Industrial Applicability of Artificial Neural Networks". *IEEE Transactions on Industrial Electronics*, V.50, N.3, pp.585-601, June, 2003.
- 9 Minsky, M.L. & Papert, S.A. Perceptrons. *MIT Press*, 1969.
- 10 Rezende, S.O. (Org.) Sistemas inteligentes: Fundamentos e Aplicações. *Editora Manole*, São Paulo, 2003.
- 11 Schlang, M.; Feldkeller, B.; Lang, B.; Poppe, T. & Runkler, T. "Neural Computation in Steel Industry". *European Control Conference '99*, Karlsruhe, p.1-6, 1999.
- 12 V & M do Brasil S.A. Catálogo Técnico da Gerência de Relações Corporativas, 2001.
- 13 Winston, P.H. Inteligência Artificial. *LTC Editora*, Rio de Janeiro, 1988.

SEAMLESS-TUBE ROLLING THERMAL MODELING BY MEANS OF ARTIFICIAL NEURAL NETWORKS

*Renato R. Rocha²
Thiago E. A. Souza²
Ricardo N. Carvalho³
Paulo E. M. Almeida²*

Abstract

This article describes an approach to thermal modeling of seamless-tube rolling through Multilayer Perceptron (MLP) and Radial Basis Function (RBF) artificial neural networks. Industrial data from Vallourec & Mannesmann do Brasil (VMB), based on Belo Horizonte - Minas Gerais State, were used in order to train the networks and to adjust the algorithms. This specific process is described, along with the desired features for the model and practical aspects about choosing the adequate architecture and training algorithms to be used in the implementation. Practical results for the project first stage are presented and expected improvements to be perceived at the industrial plant with the new model are discussed.

Key-words: Artificial neural networks; Mathematical modeling; Thermal modeling; Seamless-tube rolling.

² Laboratório de Sistemas Inteligentes, CEFET-MG

³ V & M do Brasil S. A. Email: nolasco@vmtubes.com.br