

# MODELO MATEMÁTICO NEURAL ARTIFICIAL PARA CÁLCULO DE RENDIMENTO METÁLICO TEÓRICO DE UM LAMINADOR DE TIRAS A FRIO\*

Arlei Fonseca Barcelos<sup>1</sup>  
Hugo Shokychi Toshimitsu<sup>2</sup>

## Resumo

As RNAs, ou redes neurais artificiais, são ferramentas computacionais utilizadas atualmente para desenvolvimentos de processos que aprendem de forma automática através de comparações de padrões definidos. Através de um modelo matemático desenvolvido por RNA, temos a sua aplicação na avaliação de um indicador extremamente importante em um laminador de tiras a frio, que é o Rendimento metálico teórico. O rendimento metálico é um indicador que demonstra o balanço de perdas metálicas de um processo, sendo controlada pelos gestores de um processo, o mesmo é referência de aproveitamento de material, que sai e que entra em determinado processo. Esta ferramenta permite que a rede desenvolvida adquira conhecimento com base em um longo histórico de banco de dados com multivariáveis permitindo concluir se o processo está controlado ou não. **Palavras-chave:** Laminador de tiras a frio; Rendimento metálico; Rede neural.

## ARTIFICIAL NEURAL NETWORK MODEL FOR THE CALCULATION OF THEORETICAL METALLIC PERFORMANCE OF A TANDEM COLD MILL

## Abstract

ANNs, or artificial neural networks, are computational tools currently used for process developments that learn automatically through defined pattern comparisons. Through a mathematical model developed by ANN, we have its application in the evaluation of an extremely important indicator in a tandem cold mill, which is Theoretical Metallic Performance. The metallic performance is an indicator that shows the balance of metallic losses of a process, being controlled by the managers of a process, the same is reference of material utilization, that leaves and that enters a given process. This tool allowed the developed network to acquire knowledge based on a long history of database with multivariables allowing us to conclude whether the process is controlled or not.

**Keywords:** Tandem cold mill; Metallic performance; Neural Network.

<sup>1</sup> Engenheiro Eletrônico, Mestrado em Engenharia Elétrica/COPPE/UFRJ, Engenheiro Especialista de Manutenção, GRF/GGLD, CSN, Volta Redonda, Rio de Janeiro e Brasil.

<sup>2</sup> Engenheiro Metalúrgico, Especialista em Laminação, Engenheiro de Processos, GRF/GGLD, CSN, Volta Redonda, Rio de Janeiro e Brasil.

## 1 INTRODUÇÃO

O rendimento metálico é um indicador que demonstra o balanço de massa de um processo (levando em consideração o que sai dividido pelo o que entra, vezes 100%, sendo assim quanto mais próximo de 100, melhor. Do contrário, demonstra perdas metálicas no processo ou o não aproveitamento da massa/produto. O rendimento metálico teórico é o valor calculado no laminador já prevendo os cortes do material fora de espessura, intrínseco ao processo tandem de laminação, que é enviado aos clientes para terem previsibilidade de rendimento real. O mesmo depende das principais variáveis, como: espessura de saída, largura, comprimento e tolerância de espessura contratada pelo cliente. No trabalho a seguir, utilizou-se o método de modelamento neural artificial através de softwares como: Matlab, NeuroSolutions e Excel para calcular o rendimento teórico ideal em função do comportamento das variáveis de entrada.

## 2 CONCEITO BÁSICO SOBRE RNA

O modelo matemático criado tem por base as teorias já desenvolvidas na década de 40 pelo matemático Walter Pitts e o neurofisiologista McCulloch onde foi objetivado associar um neurônio biológico a um circuito eletrônico. Analogamente a um sistema nervoso humano onde cada neurônio armazena informações, conhecido por cognição, o modelo artificial também possui sua forma de guardar estas informações, estes dados são calculados através de padrão histórico utilizado para treinar a rede neural artificial.

Esse método de armazenamento permitiu as máquinas adquirir aprendizado e o reconhecimento de padrões assim resultando em aplicações onde a máquina pode avaliar parâmetros como o cérebro humano.

O modelo de um neurônio artificial matemático pode ser multivariável, sendo composto por “n” entradas, como os dendritos, ou seja, a saída de um problema pode depender de “n” variáveis. A Figura 1 mostra o modelo de neurônio artificial, onde segundo Haykin (2001)[1], é possível identificar os elementos básicos que estão descritos abaixo.

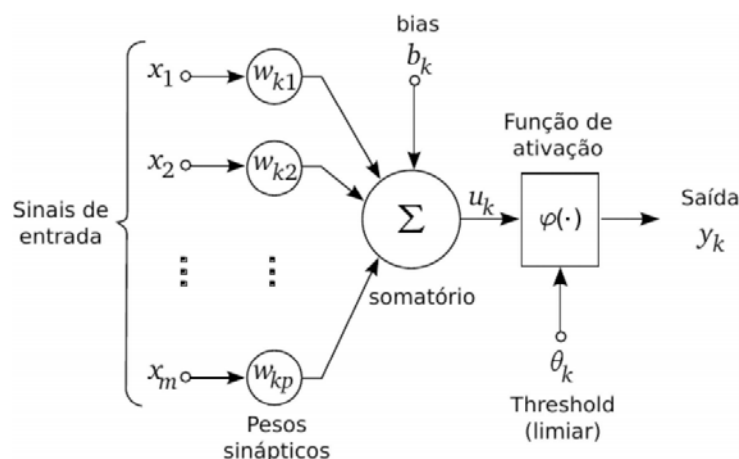


Figura 1. Modelo de um neurônio artificial-Fonte: Haykin, 2001.

No modelo da Figura 1, é representado um conjunto de elos de conexão (ou conjunto de sinapses), cada um caracterizado por um peso ou força própria. Especificamente, um sinal  $x_m$  na entrada da sinapse conectada ao neurônio  $k$  é multiplicado pelo peso sináptico  $w_{km}$ . A representação do sinal de somatório realiza

a adição dos sinais de entrada ponderados pelas respectivas sinapses do neurônio, formando uma espécie de combinador linear. Uma função de ativação é utilizada para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva, já que, restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito. O bias, representado por  $b_k$ , tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se este assume, valores positivos ou negativos, respectivamente.

### 3 MATERIAIS E MÉTODOS

A criação do modelo de rede neural pode ser dividida entre as fases descritas abaixo:

- 3.1 Coleta de dados
- 3.2 Preparação do banco de dados
- 3.3 Validação da rede neural
- 3.4 Treinamento da rede neural
- 3.5 Avaliação dos resultados

#### 3.1 Coleta de dados

Para a coleta de dados precisa-se inicialmente definir as variáveis de entrada, ou seja, as variáveis que influenciarão no resultado do modelo (rendimento metálico teórico). Com isso, temos que a definição do RMT rendimento metálico teórico é: a relação útil da bobina (CORPO) com espessura dentro da tolerância contratada pelo cliente.

Através da figura 2 apresentada abaixo, pode-se ilustrar melhor as variáveis no produto laminado e estudado, onde as pontas e caudas são as partes a serem descartadas (perdas metálicas).




Figura 2. Ilustração das variáveis – produto estudado.

Logo,

$$RMT (\%) = \frac{Mco}{Mpo + Mco + Mca}$$

Onde,

Mco = Massa do CORPO da bobina com espessura dentro da LSE/LIE

Mpo = Massa da PONTA da bobina com espessura fora da LSE/LIE

Mca = Massa da CAUDA da bobina com espessura fora da LSE/LIE

Sendo que, M – massa: corpo, ponta ou cauda é:

$$M = \int_{c'}^{c''} e(c) \cdot l \cdot \rho \cdot \delta c$$

Onde,

$\rho$  = massa específica do aço – 7,85g/cm<sup>3</sup>

$c'$  = LIE = Limite inferior de especificação

$c''$  = LSE = Limite superior de especificação

e, as variáveis da entrada do modelo neural são dadas pela tabela 1:

**Tabela1.** Declaração de variáveis da RNA

Variável na entrada na RNA	Descrição Variável	Símbolo na equação
X <sub>1</sub>	Espessura	$e$
X <sub>2</sub>	Largura	$l$
X <sub>3</sub>	comprimento do material entre os limites de especificação	$c$
X <sub>4</sub>	tolerância do cliente= $ (c' - c'')/2 $	$t$

Definido as variáveis, as mesmas foram buscadas através do banco de dados. Esta etapa é primordial para que se tenha um resultado consistente, tendo um número significativo de dados para cobrir amplamente todos os possíveis resultados não somente os resultados rotineiros, mas também as condições limites dos possíveis resultados. O banco de dados utilizado foi requisitado através do banco de dados Oracle (sistema do processo em estudo) onde foram salvos bobina a bobina os dados de entrada e saída, sendo no total 2600 dados. Na tabela 2 é apresentado um pequeno exemplo de amostras do banco de dados exportado para o Excel.

**Tabela 2.** Banco de dados.

Média de TOLERÂNCIA	Média de LARGURA	Média de ESP_SAI	Média de COMPR_CALC	Média de RM
6,41817314	1,181695695	0,977560462	3256,299317	98,39
6,805837117	1,163106198	0,920603994	3392,894943	98,50
6,631470893	1,169997526	1,006647766	3109,442485	98,39
6,488785387	1,174962783	0,995468997	3107,773655	98,40
6,585775234	1,173929182	1,01593561	3027,376142	98,40
6,627948818	1,185980991	0,977611573	3126,447251	98,40
6,637859425	1,175928173	0,957225885	3329,89919	98,44
6,475520123	1,165245819	0,97605278	3230,477873	98,45
6,483008252	1,179915667	1,007172829	3172,857878	98,50
6,387448658	1,180102859	0,979335122	3165,632699	98,50
6,380774557	1,189030072	1,019885104	3017,546596	98,45
6,150457126	1,171244569	0,954445195	3335,890545	98,37
6,575029798	1,180737879	1,025138843	3043,78614	98,36
6,249712522	1,170952217	0,961318075	3224,058788	98,39
6,399818541	1,171515361	0,968810081	3164,850364	98,34
6,753357361	1,163792472	0,995333075	3134,144156	98,41
6,891692349	1,154358655	1,079842052	2870,359035	98,35

### 3.2 Preparação do banco de dados

É importante que se tenha uma grande quantidade de amostras para treinamento da rede neural, pois quanto maior o número, mais próximo os resultados serão do real. Neste trabalho foram utilizadas 2600 bobinas, sendo divididos em 2 partes: 2200 dados de treinamento e 400 dados para uso no testes.

Os dados devem passar por uma normalização, ou seja, devem ter escala aproximada, tendo a mesma ordem de grandeza para não causar distúrbios nos cálculos da rede devido pesos das grandezas bem diferentes, no caso foi utilizado de acordo com a tabela 2

Tabela 2. Fator de ponderação nas variáveis para normalização.

VARIÁVEL	TIPO	RANGE	NORMALIZAÇÃO
Espessura de saída	entrada	0,28mm-2,99mm	nenhuma
Tolerância do cliente	entrada	1,5% -15%	nenhuma
Largura	entrada	610mm-1575mm	Largura/1000
Comprimento	entrada	0,6km-12km	Comprimento/3000
RMT	saída	80%-100%	(100-RMT)

Os dados devem ser alocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. Outro ponto na preparação dos dados é retirar os outliers pois eles podem causar anomalias nos resultados obtidos, lembrar-se bem que ao eliminá-los, ter certeza que o mesmo não é somente um ponto particular do processo e sim um ponto drástico diferenciado da normalidade.

### 3.3 Validação da rede neural

Após importação dos dados tratados no programa Matlab é feita a validação da rede para verificar se o problema poderá ser resolvido. Através dos algoritmos criados é feita a declaração das amostras (dados) de entrada e saída para treino e teste, sendo nomeadas de *entrada\_treino*, *saída\_treino*, *entrada\_teste* e *saída\_teste*, e definição da melhor estrutura de rede neural que atenderá a resolução para o cálculo do rendimento teórico neural. Foi utilizada a estrutura

neuralfeedfowbackpropagation por facilidade de implementação posteriormente. Na figura 3, está descrito um diagrama genérico da rede aplicada neste trabalho.

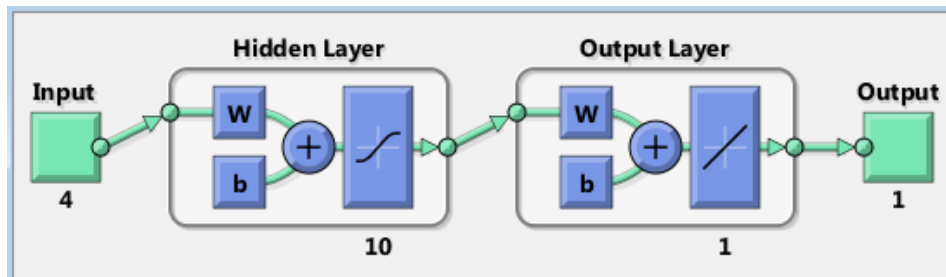


Figura 3. Estrutura FeedForwardBackprop no Matlab. Estrutura genérica.

Na figura 4 é apresentada a estrutura da rede neural, de forma detalhada, com as quantidades de neurônios nas diferentes camadas, bias, sinapses e funções de ativação. A validação da rede neural foi concluída após verificação da saída Y1, sendo verificada próxima das saídas já conhecidas.

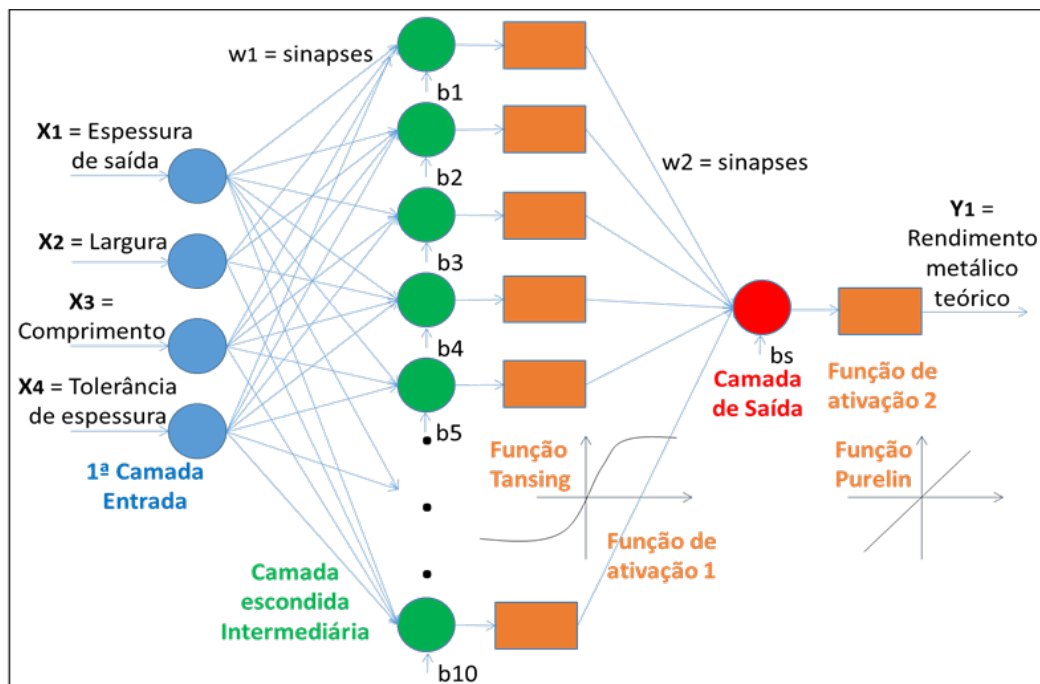


Figura 4. Estrutura detalhada do modelo RNA para 4 variáveis.

### 3.4 Treinamento da rede neural

Definido a estrutura e validado seu desempenho na etapa anterior entra-se na fase de aprimorar a rede neural, através da ferramenta gráfica nntools do Matlab,acionamos a função "Train" para executar o treinamento com os dados de *entrada\_treino* e *saída\_treino*. Ao término do treinamento da rede neural, um gráfico é gerado, apresentando o índice da média quadrática do erro, onde é esperado o menor erro possível, e após vários treinamentos de 1000 épocas foi alcançado um erro de aproximadamente da escala  $10^{-1}$ , como mostra a figura 5, e um coeficiente de correlação próximo a 1 como mostra a figura 6 a seguir concluindo o treinamento.




Figura 5. Erro médio quadrático – Treinamento da RNA.




Figura 6. Coeficiente de correlação – Treinamento da RNA.

### 3.5 Avaliação dos resultados

Na etapa de avaliação dos resultados da RNA foram executadas as funções no Matlabcom os dados *entrada\_teste* afim de verificar as saídas de rendimentos teóricos neurais ( $Y_1$ ) comparando as com os rendimentos teóricos reais (saída\_teste) ainda não utilizados, conforme figura 4. Como mostra a figura 7 abaixo, tem-se uma linearidade aproximada entre as duas saídas, concluindo a avaliação como satisfatória.

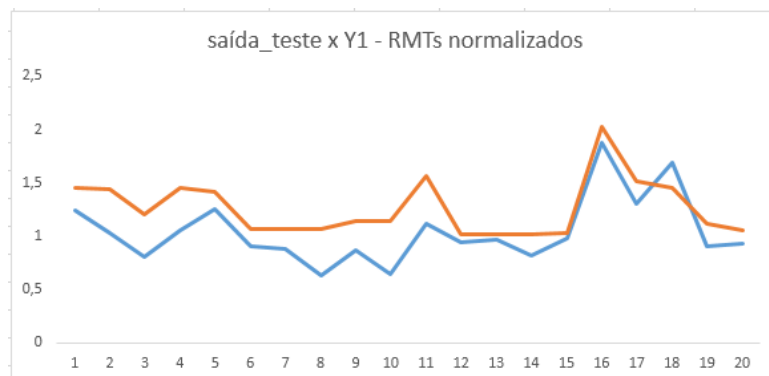


Figura 7. Resultado da avaliação saída\_teste x Y1.

## 4 RESULTADOS E DISCUSSÃO

Afim de facilitar a aplicabilidade da ferramenta (RNA) na avaliação do rendimento teórico, foi utilizado através da linguagem VBA – Visual Basic na plataforma Excel um algoritmo para automatizar as operações matemáticas entre as matrizes resultantes do modelo no Matlab e as entradas do modelo no banco de dados. Matrizes estas com os valores das sinapses, bias, funções de ativação e entradas reais que resultaram na figura 8 apresentada a seguir.




Figura 8. Resultado da avaliação (RMT neural - Rendimento metálico teórico neural) x (RMT - Rendimento metálico teórico realizado)

Pode-se comparar através do gráfico na figura 8, os valores do RMT neural (padrão de valor histórico) com o RMT realizado, logo, quando o balanço é positivo, ou seja onde o RMT realizado é maior do que o RMT neural, conclui-se que o processo foi melhor do que o histórico e assim vice versa.

## 5 CONCLUSÃO

O uso da ferramenta RNA apresenta boa previsibilidade quando comparado sua saída aos valores realizados. Concluindo como uma ferramenta rápida de tomada de decisão sem perder tempo avaliando o histórico das variáveis de entrada. O resultado da avaliação do balanço entre os RMTs diz de forma rápida, se tem que



tomar ações no processo ou não, já que a saída neural traz o melhor resultado em função do aprendizado histórico nas mesmas condições das variáveis processadas.

## 6 REFERÊNCIAS

- 1 Haykin S. Redes Neurais - Princípios E Práticas. Porto Alegre: Bookman; 2001.
- 2 Braga AP, Carvalho APLF, Ludemir TB. Redes Neurais Artificiais - Teoria e Aplicações. 2ª Edição. Rio de Janeiro: Editora LTC; 2000.
- 3 Santos RA, Barcelos AF, Oliveira JCA, Dias ES, Toshimitsu HS. FERRAMENTA DE DETECÇÃO DE PADRÕES DE PLANICIDADE UTILIZANDO REDES NEURAIS. ABM 53º Seminário de Laminação; 2016