



MODELO MATEMÁTICO NEURAL ARTIFICIAL PARA CÁLCULO DE RENDIMENTO METÁLICO TEÓRICO de um laminador de tiras a frio

Arlei Fonseca Barcelos
arlei@csn.com.br
AEDB

Hugo Shokychi Toshimitsu
Hugo.Toshimitsu@csn.com.br
AEDB

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 nos permitiu que a rede desenvolvida adquirisse conhecimento com base em um longo histórico de banco de dados com multivariáveis nos permitindo concluir se o processo está controlado ou não.

Palavras Chave: Laminador tiras frio - Rendimento metálico - Rede neural - -



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, utilizamos o método de modelamento neural artificial através de softwares como: Matlab, NeuroSolutions e Excel para calcularmos 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.

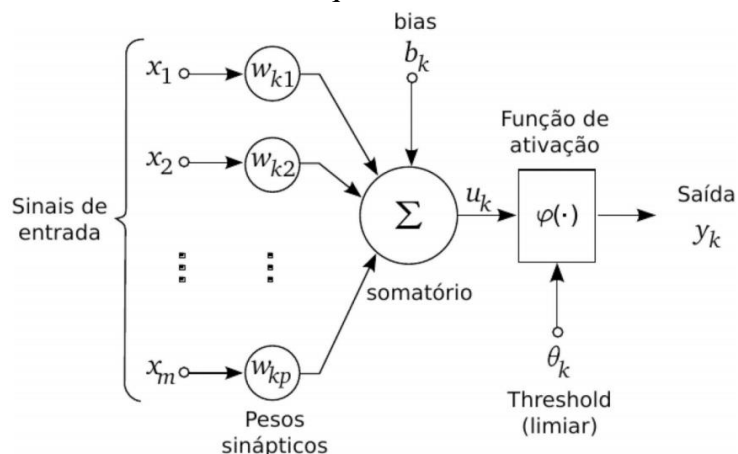


Figura 1. Modelo de um neurônio artificial-Fonte: Haykin, 2001.

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 precisamos 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, podemos ilustrar melhor as variáveis no produto laminado e estudado, onde as pontas e caudas são as partes a serem descartadas (perdas metálicas).

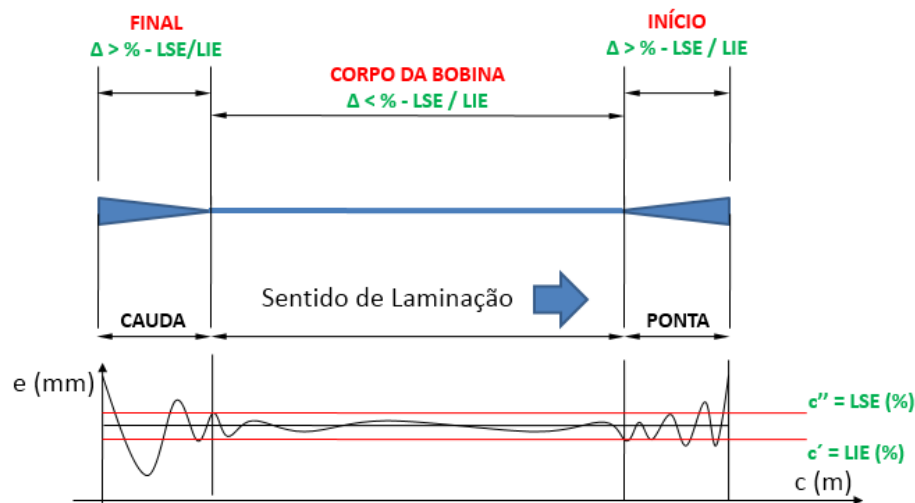


Figura 2. Ilustração das variáveis – produto estudado.

Logo,

$$RMT (\%) = \frac{M_{co}}{M_{po} + M_{co} + M_{ca}}$$

Onde,

M_{co} = Massa do CORPO da bobina com espessura dentro da LSE/LIE

M_{po} = Massa da PONTA da bobina com espessura fora da LSE/LIE

M_{ca} = 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,

- ρ = massa específica do aço – 7,85g/cm³
- c' = LIE = Limite inferior de especificação
- c'' = LSE = Limite superior de especificação

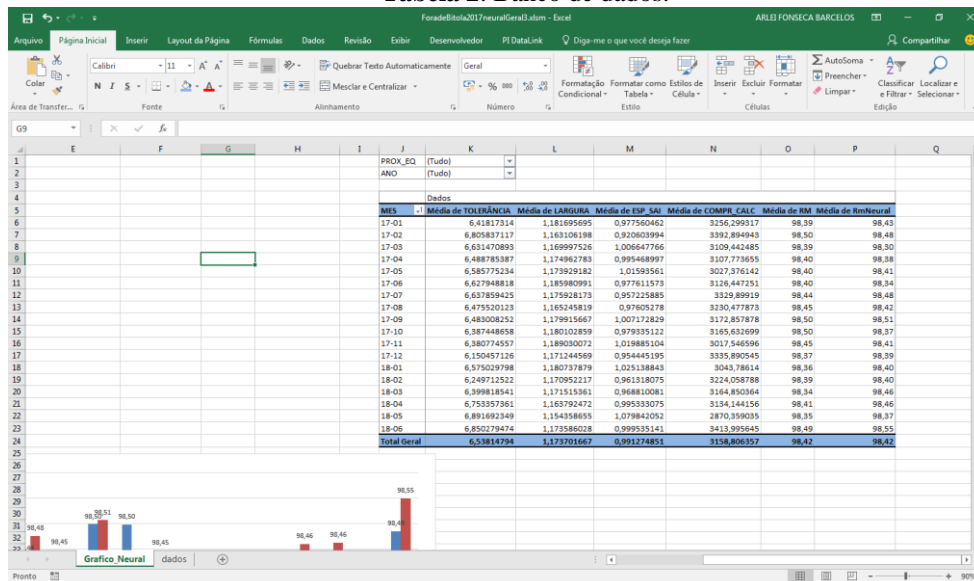
e, as variáveis da entrada do modelo neural são dadas pela tabela 1:

Tabela1. Declaração de variáveis da RNA

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

Definido as variáveis, buscaremos estes dados através do banco de dados. Esta etapa é primordial para que tenhamos 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.



MES	Média de TOLERÂNCIA	Média de LARGURA	Média de ESP. SA	Média de COMPE. CALC	Média de RM	Média de RmNeural
17-01	6,41817314	1,18169595	0,97756042	3126,29517	98,39	98,43
17-02	6,80783717	1,16106198	0,93020394	3192,89445	98,50	98,48
17-03	6,63147089	1,16999752	1,00664776	3109,44245	98,39	98,30
17-04	6,48878538	1,17496278	0,99548897	3107,77365	98,40	98,38
17-05	6,58577523	1,17392918	1,01595561	3027,37614	98,40	98,41
17-06	6,62794818	1,18598091	0,97761178	3126,44751	98,40	98,34
17-07	6,63785942	1,17592817	0,95722585	3329,89919	98,44	98,48
17-08	6,47552012	1,16524581	0,97605278	3230,47787	98,45	98,42
17-09	6,48302825	1,17991567	1,00717282	3172,85787	98,50	98,51
17-10	6,38744868	1,18012859	0,97931122	3165,63199	98,50	98,37
17-11	6,38077457	1,18903007	1,01988510	3017,54656	98,45	98,41
17-12	6,15045712	1,17124456	0,95444519	3335,89254	98,37	98,39
18-01	6,57623979	1,18073787	1,02513843	3043,78614	98,36	98,40
18-02	6,24971252	1,17095217	0,96131807	3124,05878	98,39	98,40
18-03	6,39981854	1,17151531	0,96881008	3164,85264	98,34	98,46
18-04	6,75335761	1,16379247	0,99533307	3134,14415	98,41	98,46
18-05	6,89169234	1,15433855	1,07984102	2870,35905	98,35	98,37
18-06	6,85027844	1,17558628	0,99953141	3413,99545	98,49	98,55
Total Geral	6,53814794	1,17370167	0,99127495	3158,80637	98,42	98,42

3.2 Preparação do banco de dados



É importante que tenhamos uma grande quantidade de amostras para treinamento da rede neural, pois quanto maior o número, mais próximos 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 nosso caso foi utilizado de acordo com a tabela 2

Tabela 2. Fator de ponderação nas variáveis para normalização.

VARIAVEL	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 verificarmos 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 neural feedforward backpropagation por facilidade de implementação posteriormente. Na figura 3, está descrito um diagrama genérico da rede aplicada neste trabalho.

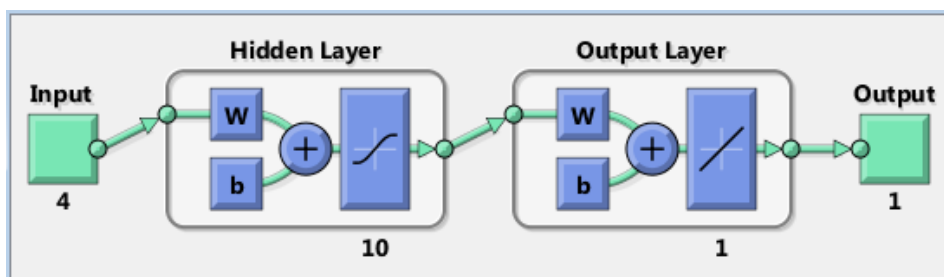


Figura 3. Estrutura Feed Forward Backprop no Matlab. Estrutura genérica.

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.

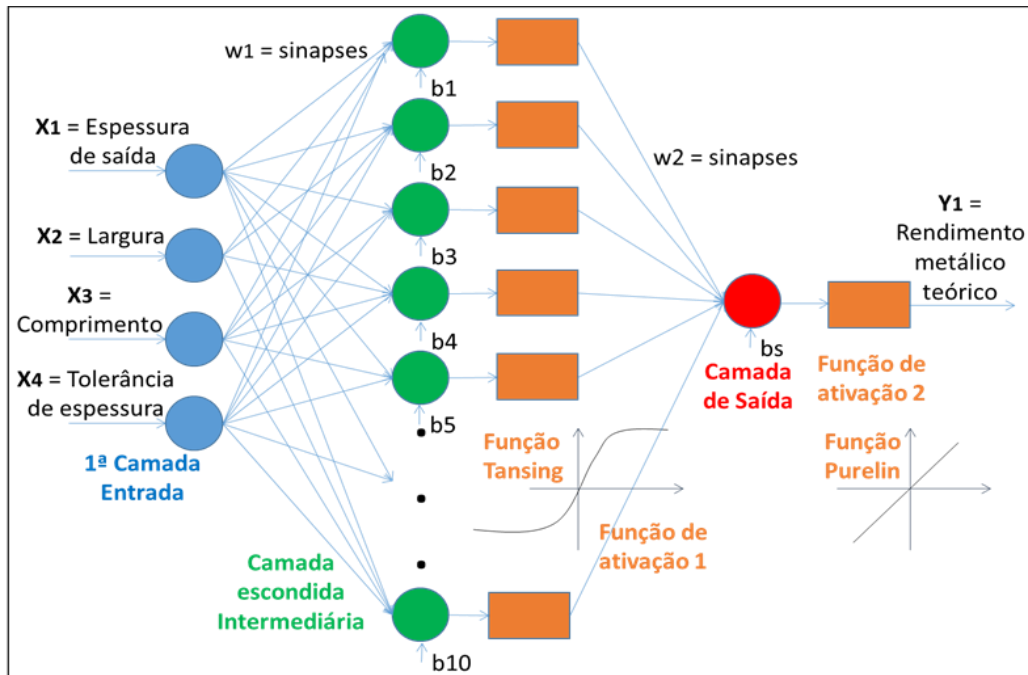


Figura 4. Estrutura detalhada do modelo RNA para 4 variáveis.

3.4 Treinamento da rede neural

Definido a estrutura e validado seu desempenho na etapa anterior entramos 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.

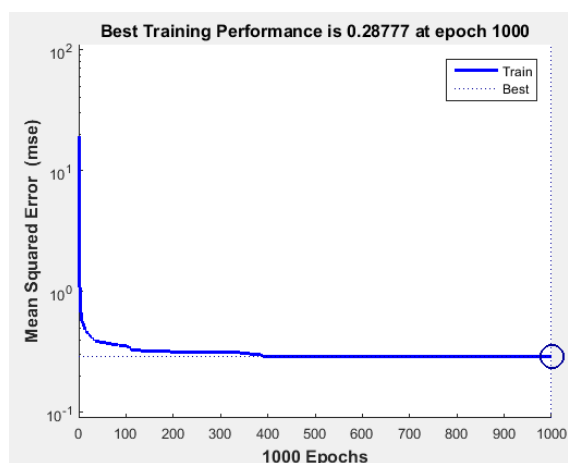


Figura 5. Erro médio quadrático – Treinamento da RNA.




Figura 6. Coeficiente de correlação – Treinamento da RNA.

3.5 Avaliação dos resultados

Na etapa de avaliação dos resultados da RNA é onde executamos as funções no Matlab com os dados *entrada_teste* afim de verificar as saídas de rendimentos teóricos neurais (Y1) comparando as com os rendimentos teóricos reais (saída_teste) ainda não utilizados, conforme figura 4. Como mostra a figura 7 abaixo, temos uma linearidade aproximada entre as duas saídas, concluindo a avaliação como satisfatório.

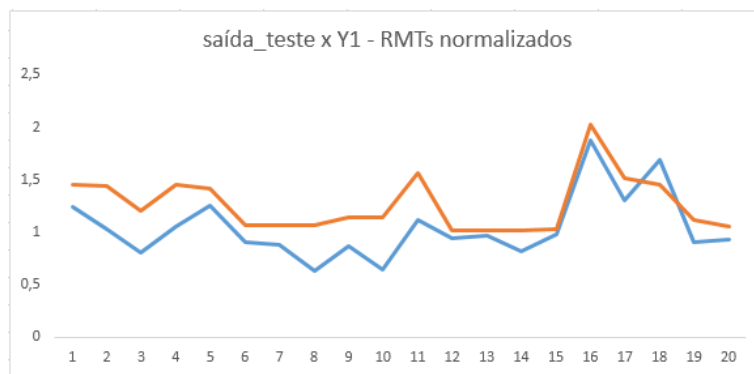


Figura 7. Resultado da avaliação saída_teste x Y1.

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.

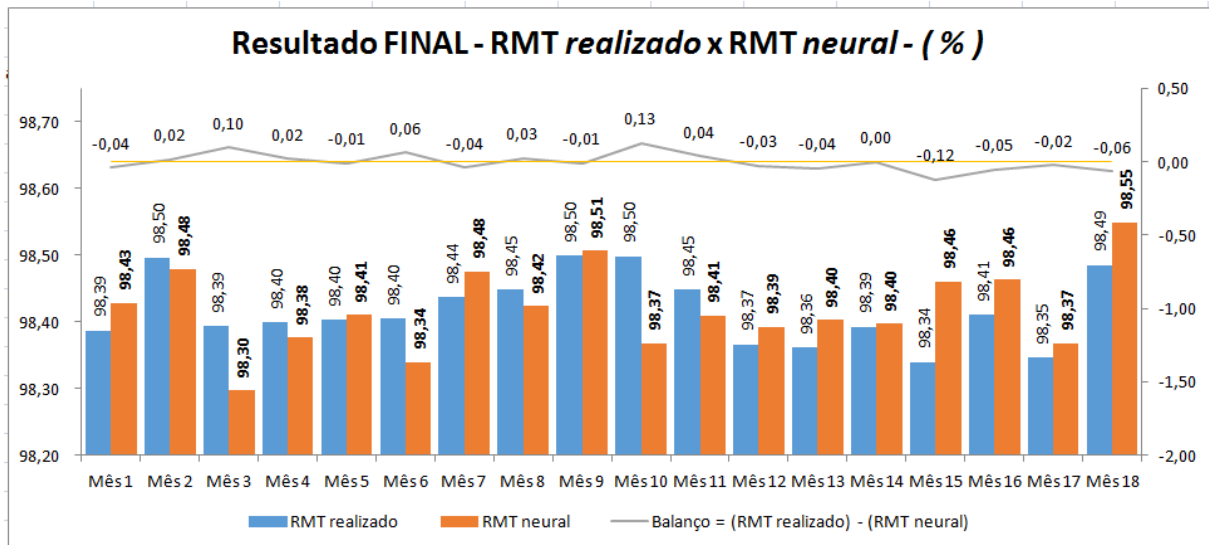


Figura 8. Resultado da avaliação (RMT neural - Rendimento metálico teórico neural) x (RMT - Rendimento metálico teórico realizado)

Podemos 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 fomos melhor do que o histórico e assim vice versa.

5 CONCLUSÃO

O uso da ferramenta RNA apresentou 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 nos diz de forma rápida, se temos que tomar ações no processo ou não, já que a saída neural nos 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 NEURAI. ABM 53º Seminário de Laminação; 2016