

REDES NEURAIIS APLICADAS NA PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA DA LAMINAÇÃO A FRIO DA COSIPA ¹

*Amauri Dias de Carvalho*²
*Leandro Nunes de Castro Silva*³
*Marco Antônio Patrício Carvalho*⁴
*Mateus Alexandre da Silva*⁵
*Ricardo Gomes da R. Cupido*⁶
*Sérgio Luiz Muratori*⁷

Resumo

O cálculo da previsão de consumo mensal de energia elétrica da Laminação a Frio da Cosipa utiliza um modelo empírico baseado no volume total da produção do Laminador de Tiras a Frio. Este método fornece uma informação considerada adequada, mas que leva em consideração apenas médias históricas de volumes produção, não sendo possível associar esta previsão com as diferentes características dimensionais dos produtos e suas quantidades individuais no total programado. Dependendo da variedade de produtos, pode-se ter uma considerável alteração no consumo de energia. Isto ocorre porque a energia utilizada no processo de laminação depende, entre outros fatores, da redução de espessura que será aplicada à tira no laminador. A crescente aplicação de redes neurais artificiais, em substituição a modelos convencionais, tem mostrado vantagens, uma vez que elas apresentam respostas muito próximas aos valores reais medidos. Neste trabalho se pretende desenvolver e testar um modelo baseado em redes neurais artificiais (RNA) para a previsão do consumo de energia elétrica na Laminação a Frio em função dos dados do mix de produção. A RNA foi treinada e testada para definir a melhor topologia e um conjunto de pesos capazes de apresentar o melhor desempenho, quando fossem introduzidos na rede dados de entrada diferentes daqueles utilizados no treinamento, demonstrando a sua capacidade de generalização. A comparação dos resultados obtidos pela RNA em relação aos valores estimados pelo modelo atualmente utilizado, mostrou um bom desempenho da RNA.

Palavras-chave: Redes neurais; Previsão de consumo de energia; Laminação a frio.

NEURAL NETWORKS APPLIED ON THE ELECTRICAL ENERGY CONSUMPTION FORECAST AT COSIPA'S COLD ROLLING PLANT

Abstract

The calculations to forecast the electrical monthly consumption of the cold rolling plant of Cosipa uses an empirical model based on total production volume of the Tandem Cold Mill. This method provides an information considered suitable, but only considers historical averages of production, do not being possible associate this forecast with different dimensional characteristics of the products and its individual quantities on the total programmed. Depending on the product variety, it is possible to have a considerable change on the energy consumption. It happens because the use of energy on rolling process depends, among other factors, on the thickness reduction that will be applied on the strip at the mill. The growth application of artificial neural networks (ANN), replacing conventional models, has shown advantages, as they presents responses very close to real measured values. In this work it is intended to develop and test a model based on neural networks, to forecast the electrical energy consumption of the cold rolling plant as a function of mix production data. The ANN was trained and tested to define the best topology and the set of weights that could be able to present the better performance when other entry data, different to those used to train the ANN, was introduced in the network, showing its capacity of generalization. The comparison of results attained by the ANN in relation to values estimated by the model presently in use, shown a good performance of the ANN. Was possible to evidence that this technique is a good method to model systems.

Key words: Neural networks; Energy consumption forecast; Cold rolling.

¹ Trabalho técnico apresentado ao X Seminário de Automação de Processos, 4 a 6 de outubro de 2006, Belo Horizonte – MG.

² Sócio da A.B.M. Engenheiro Eletricista, M.Sc., Analista de Manutenção da Gerência de Suporte Técnico da Laminação a Frio da Companhia Siderúrgica Paulista – Cosipa, Cubatão, São Paulo.

³ Professor Dr. do Centro de Pós-graduação da Universidade Católica de Santos, Santos, São Paulo.

⁴ Técnico em Eletrônica, Analista de Automação da Gerência de Automação da Companhia Siderúrgica Paulista – Cosipa, Cubatão, São Paulo.

⁵ Sócio da A.B.M. Engenheiro Metalurgista, Analista de Processos da Gerência de Suporte Técnico da Laminação a Frio da Companhia Siderúrgica Paulista – Cosipa, Cubatão, São Paulo.

⁶ Engenheiro Químico, Analista de Automação da Gerência de Automação da Companhia Siderúrgica Paulista – Cosipa, Cubatão São Paulo.

⁷ Sócio da A.B.M. Engenheiro Eletricista, Gerência de Suporte Técnico da Laminação a Frio da Companhia Siderúrgica Paulista – Cosipa, Cubatão, São Paulo.

1 INTRODUÇÃO

O mercado brasileiro de energia elétrica tem crescido a uma taxa da ordem de 4,5% ao ano, devendo ultrapassar a casa dos 100 mil MW em 2008. O planejamento governamental de médio prazo prevê a necessidade de investimentos que atingirão R\$ 6 a 7 bilhões/ano para a expansão da matriz energética brasileira, em atendimento à demanda do mercado consumidor.

Ao longo das duas últimas décadas, o consumo de energia elétrica apresentou índices de expansão bem superiores ao produto interno bruto (PIB) em função do crescimento populacional concentrado nas zonas urbanas, do esforço de aumento da oferta de energia, da modernização de plantas industriais e da economia brasileira.

A Companhia Siderúrgica Paulista – Cosipa apresenta um consumo médio de energia elétrica da ordem de 120 GWh/mês, dos quais a Laminação a Frio participa com cerca de 10 GWh/mês. A contratação desta energia é um dos pontos cruciais para a lucratividade da empresa. Um erro na estimativa pode levar a multas e pagamento de valores elevados diante dos valores previamente estabelecidos pelo mercado. Uma previsão correta da demanda de energia elimina gastos desnecessários e desperdícios, contribuindo assim para a lucratividade da empresa.

O cálculo de uma “conta de energia” de uma empresa é feito de maneira diferente daquele empregado no cálculo de consumidores residenciais. Os consumidores industriais devem informar à concessionária a previsão de consumo mensal de energia elétrica. Caso esta previsão de consumo seja excedida haverá cobranças de taxas extras e, caso não seja atingida, a empresa não recebe o benefício da economia de consumo dentro do mesmo mês. Para a previsão correta da demanda de energia elétrica, a escolha de critérios e ferramentas apropriadas é essencial.

Os valores das despesas da Cosipa com o consumo de energia elétrica giram em torno de R\$ 5 milhões de Reais mensais. A previsão do consumo da energia necessária para manter os processos em pleno funcionamento deve ser feita da forma mais precisa possível, pois implica em grande impacto financeiro.

No presente trabalho, da mesma forma que em Lorentz,⁽¹⁾ foi escolhida como ferramenta de análise e previsão do consumo de energia elétrica a técnica computacional chamada de redes neurais artificiais (RNA). O objetivo é desenvolver e testar um modelo para prever a demanda de energia elétrica de toda a Laminação a Frio (LF) em função da quantidade e de características do mix¹ de produção, como a espessura e a largura, dos produtos processados no Laminador de Tiras a Frio (LTF). A justificativa para isto está baseada em alguns aspectos importantes:

- O LTF é o equipamento com a maior potência instalada na LF, respondendo por cerca de 40% da energia total consumida nesta área; com isso ele é também a maior carga variável da LF e uma das maiores da COSIPA;
- Aproximadamente 95% do material que é programado para ser processado na laminação a frio passa pelo LTF e
- A existência de dados em quantidade suficiente para o treinamento e teste do modelo de RNA.

¹ Participação (em toneladas ou percentual) de cada família de produtos, agrupadas por largura e espessura, no total dos produtos a serem processados.

O LAMINADOR DE TIRAS A FRIO DA COSIPA

O laminador de tiras a frio (LTF) da Cosipa, visto na Figura 1, possui quatro cadeiras instaladas em cascata, que permite realizar reduções de até 81% na espessura da tira. Cada cadeira tem seus acionamentos independentes, compreendendo dois cilindros de encosto livres apoiados sobre dois cilindros de trabalho acoplados a motores de corrente contínua. Duas cápsulas de aperto hidráulico, instaladas no topo de cada uma das cadeiras, completam o conjunto de redução.

O seu objetivo final é a produção de bobinas de aço cujas principais características de qualidade do material são a espessura, que deverá ser controlada longitudinalmente, e a planicidade, controlada transversalmente. A redução na espessura da tira é obtida principalmente pelos elevados esforços de compressão concentrados na região de contato entre a tira e os cilindros de trabalho. Os cilindros são pressionados de encontro à tira por meio das cápsulas de acionamento hidráulico. Colaboram também para a redução, os esforços de tração entre duas cadeiras adjacentes.

No LTF as três primeiras cadeiras

são responsáveis por grande parte da redução da espessura da tira. A função da última cadeira é o acabamento superficial do material. As velocidades desenvolvidas pelas cadeiras devem ser as máximas possíveis, respeitando os limites operacionais das máquinas e de qualidade do processo.



Figura 1. Vista geral do Laminador de Tiras a Frio da Cosipa.

2 PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA NA COSIPA

A usina possui três tipos de consumidores de energia elétrica:

- Grandes fábricas: que englobam as *laminações*, os *altos-fornos*, as *coquerias* e a *aciaria*;
- Sistemas de apoio (energia e utilidades): que englobam compressores de ar, unidades de separação de oxigênio, torres de resfriamento, bombas de captação de água, etc e
- Equipamentos auxiliares: que englobam desde iluminação até pequenas bombas e compressores auxiliares do processo de produção das áreas.

Os sistemas de apoio e os equipamentos auxiliares possuem um perfil de consumo razoavelmente constante e a previsão de consumo é feita, basicamente, levando-se em conta as horas de operação programadas e a potência nominal dos equipamentos. Já no caso das grandes fábricas (altos-fornos, coquerias e aciaria), por possuírem um perfil de carga relativamente constante faz-se a previsão baseando-se também em horas de operação. A exceção são as laminações (tiras a quente, tiras a frio e chapas grossas) que respondem por aproximadamente 30% do consumo total de energia elétrica da usina e têm um perfil de carga bastante variado em função da produção planejada e do tipo de aço a ser laminado.

2.1 Previsão do Consumo Diário de Energia

Tomando como base os dados da produção diária, elaborados pelo setor de planejamento da produção, é verificado o valor programado para cada dia em cada uma das principais fábricas. Daí é verificado o *consumo específico de energia elétrica* ideal para o ritmo de produção definido em uma planilha que contém um modelo de previsão de aquisição de energia elétrica, baseado no balanço entre produção e consumo. Existe, para cada laminador, uma curva relacionando os níveis de produção diária com as médias históricas de consumo de energia elétrica.

2.2 Consumo específico do LTF (kWh/t)

A Figura 2 mostra a curva utilizada para fazer a previsão do consumo de energia elétrica da Laminação a Frio, baseada em médias históricas. A partir da produção total do mês, distribuída ao longo dos dias, pode-se encontrar o consumo específico por tonelada. Multiplica-se este valor pelo peso total e se determina o consumo mensal.

A precisão da previsão depende do cumprimento do programa de produção. Porém um processo de laminação pode produzir menos ou mais do que o previsto em função de diversos fatores. Na Tabela 1 há uma comparação dos dados de produção programada e real do LTF no primeiro semestre de 2005. Nota-se que a produção real foi maior que a prevista e, portanto, o consumo de energia elétrica.

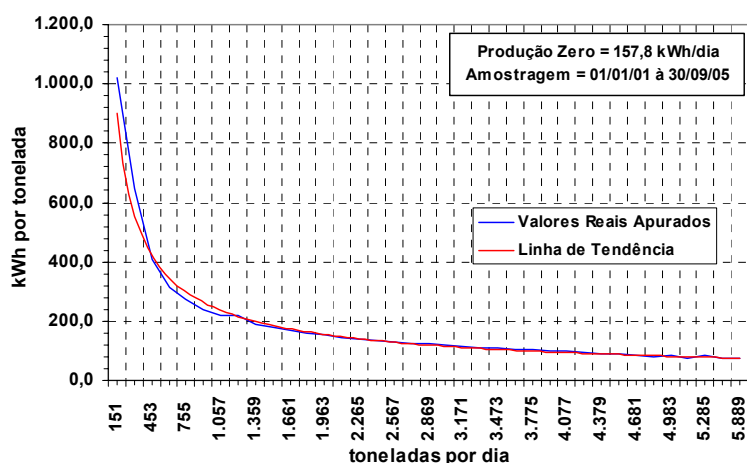


Figura 2. Consumo específico de energia elétrica do LTF.

Tabela 1. Comparativo entre produção programada e real (toneladas).

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	TOTAL
LTF – Programado	99000	88400	96600	91000	75000	94000	96500	640500
LTF – Real	102201	92901	99707	91132	77670	95720	96712	656043
LTF – Desvio	3201	4501	3107	132	2670	1720	212	15543
Erro (%)	3,23	5,09	3,22	0,14	3,56	1,83	0,22	2,43

A Tabela 2 relaciona o consumo previsto pelo modelo atual e o consumo real para o primeiro semestre de 2005. Analisando as tabelas verifica-se que o erro de previsão da produção é menor do que o erro de previsão de consumo de energia.

Tabela 2. Comparativo entre consumo de energia elétrica programado e real (MWh).

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	TOTAL
LTF - Programado	11382,6	9798,3	11074,2	10922,5	9672,4	11282,4	11164,8	75297,4
LTF - Real	11793,0	10806,4	11764,6	11108,2	10090,2	11173,0	11924,2	78659,6
LTF - Desvio	410,4	1008,1	690,4	185,6	417,8	109,4	-759,4	-3362,2
Erro (%)	-3,60	-10,28	-6,23	-1,69	-4,32	0,97	-6,81	-4,46

3 INTRODUÇÃO ÀS REDES NEURAIS

Redes neurais artificiais (RNAs) são ferramentas computacionais para a solução de problemas complexos e encontram ampla aceitação em muitas disciplinas. As RNAs podem ser definidas como estruturas compostas por elementos adaptativos simples de processamento, chamados neurônios artificiais, densamente interconectados e capazes de realizar processamento de dados e representação de conhecimento de forma massivamente paralela. A idéia das RNAs não é reproduzir de maneira simplificada a operação dos sistemas biológicos mas sim fazer uso de algumas funcionalidades específicas das redes biológicas para o desenvolvimento de ferramentas genéricas de solução de problemas. O interesse pelas RNAs apoia-se em características interessantes dos sistemas neurais biológicos, tais como não-linearidade, processamento paralelo, robustez, tolerância à falhas, aprendizagem através de exemplos, habilidade de lidar com imprecisões e sua capacidade de generalizar, ou seja, de responder (apropriadamente) a padrões desconhecidos.

3.1 Redes Neurais Biológicas

O neurônio biológico é o bloco básico de um sistema nervoso e, seu funcionamento é a inspiração para a implementação das redes neurais artificiais.⁽²⁾

O sistema nervoso humano é constituído por bilhões de neurônios de vários tipos e comprimentos. Os neurônios são células presentes no sistema nervoso e estão envolvidos na recepção, transmissão e processamento dos estímulos que chegam ou partem do organismo. Individualmente, realizam operações relativamente simples, porém a riqueza das conexões entre estes tipos de células proporciona a enorme diversidade de tarefas realizadas pelo sistema nervoso.

A Figura 3 apresenta as diferentes partes dos neurônios: corpo (soma), dendritos e axônio. De forma geral, os axônios são responsáveis pela transmissão do impulso nervoso a outros neurônios, os dendritos relacionam-se com a captação de estímulos, enquanto que no corpo celular encontram-se o núcleo e organelas responsáveis pelas demais atividades da célula. Reações químicas e elétricas representam parte do processamento de informação. A saída da informação do corpo do neurônio é realizada por impulsos elétricos que se propagam através do axônio.

No final do axônio existem inúmeras ramificações que distribuem a informação para outros neurônios vizinhos. A ligação com outros neurônios é realizada através de sinapses que estão conectadas a um dendrito ou ao corpo do neurônio receptor. A sinapse dispara uma substância química quando é excitada pelo impulso proveniente do axônio. A substância se transmite entre sinapse e dendrito, realizando a conexão entre dois neurônios vizinhos.




Figura 3. Estrutura básica de um neurônio biológico.

3.2 Redes Neurais Artificiais

A Figura 4 ilustra o modelo genérico de um neurônio artificial. Uma RNA consiste de uma coleção de unidades de processamento simples, capazes de se comunicarem entre si e com o meio ambiente, enviando sinais através de conexões ponderadas. Especificamente, uma RNA pode ser caracterizada por:

- Um conjunto de unidades de processamento, chamadas neurônios ou células. Um estado de ativação y_k para cada unidade k , que equivale à saída da unidade;
- Conexões entre as unidades; geralmente cada conexão possui um peso associado w_{kj} que define o efeito que a unidade j provoca na unidade k ;
- Uma regra de propagação, que define a entrada efetiva ou líquida s_k de uma unidade, baseada nas entradas externas e nos respectivos pesos;
- Uma função de ativação ou transferência (Tabela 3) ou propagação que define o novo nível de ativação baseado na entrada líquida ou campo induzido do neurônio $v_k(t)$ e
- Um método de ajuste de pesos, conhecido como algoritmo de treinamento.




Figura 4. Neurônio genérico em RNAs.

Tabela 3. Funções de ativação mais comuns.

Linear	$f(s) = s$	
Degrau	$f(s) = \begin{cases} +1 & \text{se } s \geq 0 \\ 0 & \text{se } s < 0 \end{cases}$	
Tangente hiperbólica	$f(s) = \tanh(s) = \frac{1 - e^{-2s}}{1 + e^{-2s}}$	

3.3 Arquiteturas de Rede

Cada neurônio artificial recebe estímulos do ambiente externo ou dos vizinhos e calcula um sinal de saída.

Em uma RNA, vários neurônios, cada um por si, pode executar essa tarefa independentemente dos demais e ao mesmo tempo. Por isso se diz que as RNAs são sistemas inerentemente paralelos. Numa RNA é possível distinguir camadas de neurônios (Figura 5), da seguinte forma:

- Camada de entrada, que recebe os estímulos provenientes do ambiente;
- Camada de saída, que envia sinais da rede para o ambiente e
- Camada(s) interna(s) ou oculta(s), cujo(s) sinais de entrada e saída são internos à rede.




Figura 5. Camadas de uma RNA.

3.4 Treinamento das Redes Neurais

O treinamento é uma das fases mais importantes e complexas na concepção de uma rede neural, o qual é feito através de algoritmos de aprendizagem.

O objetivo do algoritmo de treinamento é ajustar (atualizar) os parâmetros livres da rede neural iterativamente, para que ela possa produzir uma resposta na saída que, quando comparada à saída desejada, obtenha um erro tão pequeno quanto o determinado (ou possível).

Durante o treinamento, a rede funciona em um ciclo composto de dois passos até que seja alcançada uma condição de parada. No primeiro, um padrão (amostra de treinamento) é apresentado à camada de entrada da rede. Ocorre um processamento destes sinais que fluem como respostas parciais através da rede, camada por camada, até a camada de saída. No segundo passo a saída obtida é comparada à saída desejada para esse padrão (alvo) particular. A diferença entre elas é o erro, que será utilizado para o ajuste dos pesos das conexões das unidades nas camadas internas.

4 PROJETO DA RNA PARA PREVISÃO DO CONSUMO DE ENERGIA

A premissa deste projeto consiste em prever o consumo de energia elétrica da LF a partir da informação das espessuras e larguras das tiras de aço que serão produzidas no LTF ao longo de um mês.

4.1 Dados do Projeto

Para o projeto desta rede neural foram escolhidos os seguintes dados:

- Dados de entrada: mix de produção mensal do LTF e
- Dados de saída: consumo de energia elétrica mensal da LF.

O departamento de planejamento de produção da COSIPA distribui os pedidos mensais dos clientes, em grupos separados por espessura e largura. A Tabela 4 mostra como é feito o agrupamento dos dados do programa de produção.

Tabela 4. Modelo da tabela de dados de produção do LTF.

Largura (mm) Espessura (mm)	≤800	>800 <1000	=1000	>1000 ≤1250	>1250 ≤1350	>1350
<0,45	Pesos em toneladas					
≥0,45 e <0,60						
≥0,60 e <0,66						
≥0,66 e <0,86						
≥0,86 e <1,00						
≥1,00 e <2,30						
≥2,30						

O conjunto de dados utilizados compreende o período entre maio de 1999 e julho de 2005. Os dados de saída, que correspondem ao consumo de energia elétrica da LF, foram obtidos a partir do consumo real neste período. A matriz de dados resultante possuía 75 linhas (correspondentes ao número de meses utilizados) e 42 colunas (agrupamentos de espessura e largura).

4.2 Definição da Configuração da RNA

A melhor configuração da rede neural é aquela que tem o melhor desempenho de generalização, isto é, a que apresenta o menor erro para um dado conjunto de teste não utilizado no treinamento. Não existe uma maneira consolidada de se determinar a priori, qual a configuração ideal da RNA em função do sistema real que está se tentando modelar.

Foram testadas diferentes topologias da rede com diferentes combinações de parâmetros de treinamento. Topologia é a quantidade de neurônios na camada intermediária que compõe a RNA e parâmetros são: o critério de parada do treinamento e o percentual de dados utilizados no treinamento. Os itens que deveriam ser definidos para a construção da RNA e suas variações estão relacionadas na Tabela 5. Com base nestes itens foi utilizado um algoritmo que possibilitou a implementação de diversas redes, onde a escolha dos intervalos, os quais poderiam variar os parâmetros, foi feita de forma empírica.

Tabela 5. Definição de topologia e parâmetros das RNAs de avaliação.

Parâmetros	Varição
Quantidade de camadas intermediárias	Sempre com uma camada
Quantidade de neurônios da camada intermediária	Primeira etapa - 04 a 10 (variando de 1 em 1) Segunda etapa - 08 a 14 (variando de 1 em 1)
Função de ativação das camadas	Camada intermediária – tangente hiperbólica Camada de saída – função linear
Critério de parada da etapa de treinamento	Soma dos erros quadráticos (SSE) - menor que 0,1 a menor que 1,0 (variando de 0,1 em 0,1)
Percentual da massa de dados para treinamento/teste	≈ 50% para treinamento e ≈ 50% para teste a ≈ 90% para treinamento e ≈ 10% para teste (variando de ≈ 10% em ≈ 10%)

4.3 Metodologia de Treinamento e Teste das RNAs

O algoritmo utilizado para treinamento e teste das redes foi implementado no software Matlab® da Mathworks. Foram realizadas adaptações no algoritmo originalmente desenvolvido por Castro.^(3,4)

Os resultados foram obtidos executando-se o algoritmo 30 vezes para cada caso mostrado na Tabela 5:

A escolha dos intervalos os quais poderiam variar os parâmetros da foi feita de forma empírica. Antes dos dados serem apresentados à RNA eles foram normalizados utilizando uma função linear no intervalo $[-1, 1]$.

4.4 Funcionamento do Algoritmo

Basicamente o algoritmo de treinamento escolhe aleatoriamente os pesos iniciais para as camadas intermediárias e de saída da rede, e os atualiza iterativamente, com o objetivo de diminuir a soma dos erros quadráticos (SSE) na saída da rede. A função de ativação da camada intermediária utilizada é a tangente hiperbólica e a da camada de saída é uma função linear

O método de treinamento implementado é denominado gradiente conjugado escalonado modificado (SCGM, do inglês scaled conjugate gradient modified).⁽⁵⁾ O valor do erro de treinamento é definido a priori e irá determinar o instante de parada desta fase. A Figura 6 ilustra a rotina de treinamento da RNA.

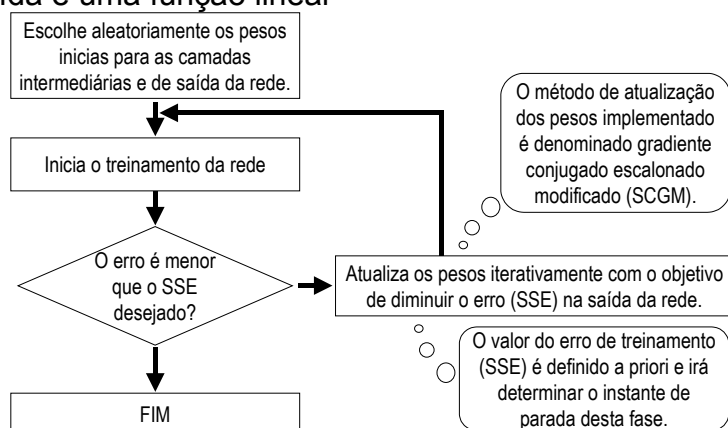


Figura 6. Funcionamento do algoritmo de treinamento.

5 RESULTADOS OBTIDOS

Após as simulações utilizando as diversas topologias e critérios, de acordo com a Tabela 5, foram coletados os dados de saída das redes para a escolha da configuração que seria adotada como a definitiva do projeto. A escolha foi baseada nos seguintes critérios:

- Menor média dos erros máximos para o conjunto de teste e
- Menor média dos desvios padrões dos erros para o conjunto de teste.

Os erros foram calculados a partir da média dos valores obtidos em cada uma das trinta vezes em que o programa testava o resultado de cada rede neural, ou seja, cada ponto plotado no gráfico é o resultado da média de trinta valores de teste. A primeira etapa do treinamento testou redes com 4 a 10 neurônios. Na Figura 7 podem ser observados os resultados para a média dos erros máximos, obtidos durante o treinamento e na Figura 8 a média dos desvios padrões dos erros. Em cada um dos gráficos, as características da rede que obtiveram os menores índices são destacadas. Cada seção do gráfico delimitada pelas linhas tracejadas, corresponde à porcentagem dos valores de erro utilizados para parar o treinamento.

Como o limite superior inicial escolhido para o “número de neurônios” foi de 10 neurônios, o melhor resultado poderia estar em uma rede com um número maior do que 10 neurônios. Sendo assim, refez-se todo o processo de simulação (segunda etapa), alterando-se apenas o número de neurônios de 8 a 14.

A Figura 9 apresenta os resultados obtidos para a média dos erros máximos na segunda etapa. Na Figura 10 vê-se a média dos desvios padrões.

A Tabela 6 mostra um comparativo dos resultados

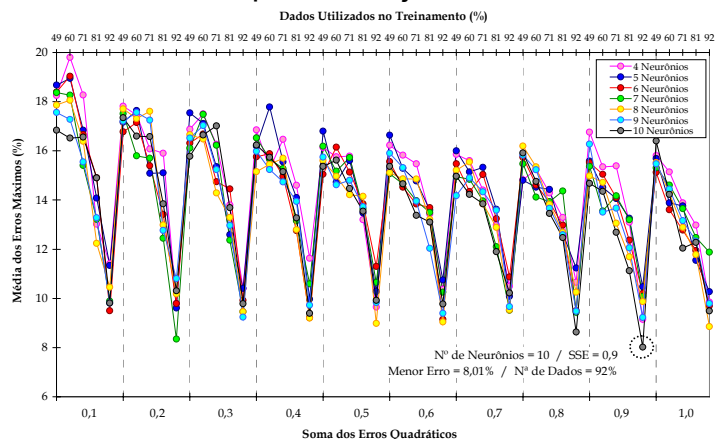


Figura 7. Erro máximo durante os treinamentos da primeira etapa (4 a 10 neurônios).




Figura 8. Desvio padrão durante os treinamentos da primeira etapa (4 a 10 neurônios).

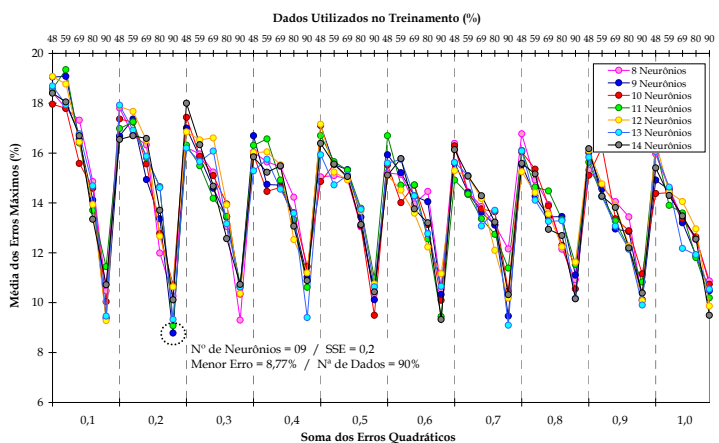


Figura 9. Erro máximo durante os treinamentos da segunda etapa (8 a 14 neurônios).

comparativo dos resultados finais obtidos para as configurações de 4 a 10 neurônios e de 8 a 14 neurônios.

Analisando os novos resultados obtidos e observando os menores índices dos critérios pré-definidos para a determinação, a RNA definitiva possui as características apresentadas na Tabela 7.

Verifica-se que a configuração de rede escolhida foi a que obteve o menor valor na média dos erros máximos e na média dos desvios padrões dos erros.

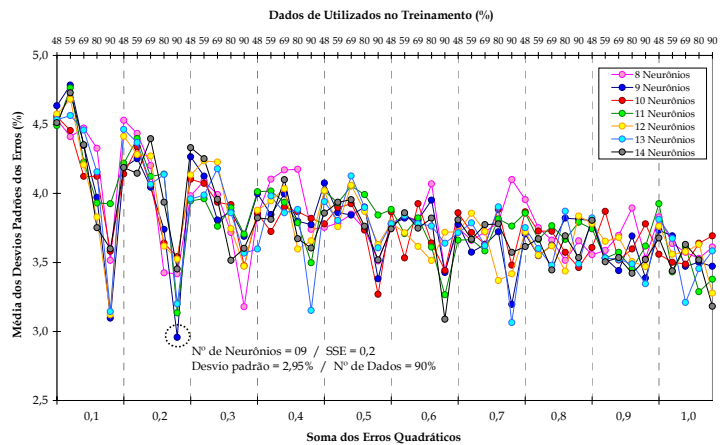


Figura 10. Desvio padrão durante os treinamentos da segunda etapa (8 a 14 neurônios).

Tabela 6. Comparativo entre os resultados obtidos nas duas etapas de simulações.

Parâmetro	Número de neurônios	
	4 a 10	8 a 14
Menor média dos erros máximos	8,01%	8,77%
Menor média dos desvios padrões dos erros.	2,73%	2,95%

Tabela 7. Parâmetros da RNA definitiva (escolhida).

Parâmetros de configuração	Valor
N.º de neurônios na camada intermediária	9
Critérios de parada do treinamento da rede SSE	0,2
Percentual de dados utilizados para o treinamento	90

A Figura 11 mostra a topologia escolhida para a RNA que será utilizada para prever o consumo de energia elétrica da Laminação a Frio.

5.1 Treinamentos e Testes da RNA Definitiva

Apresentou-se o mesmo conjunto de dados de entrada para o treinamento da rede definitiva, construída de acordo com a Tabela 7.

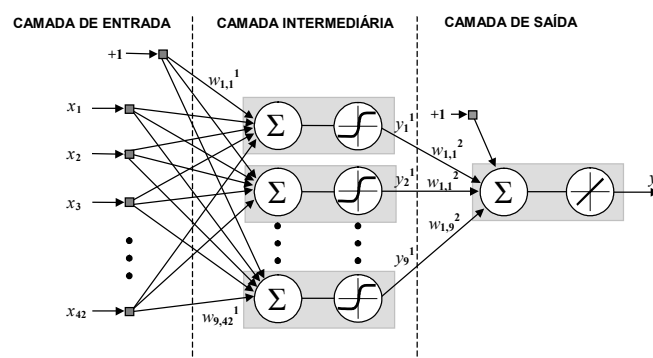


Figura 11. Topologia da RNA definitiva.

Foi definido que a rede seria treinada e testada cinco mil vezes, buscando encontrar qual matriz de pesos apresentaria o menor erro máximo. A quantidade de dados utilizados no treinamento foi de 90% do total de dados disponíveis e como critério de parada do treinamento o erro SSE igual a 0,2 (Tabela 7). A Figura 12

mostra o comportamento do SSE ao longo das épocas (apresentação de todo o conjunto de dados) do treinamento.

A comparação entre a saída da rede durante o treinamento e os valores desejados, todos normalizados, é vista na Figura 13. O eixo das abscissas não corresponde à seqüência de meses do conjunto de dados, porque o algoritmo seleciona aleatoriamente os dados apresentados para a RNA.

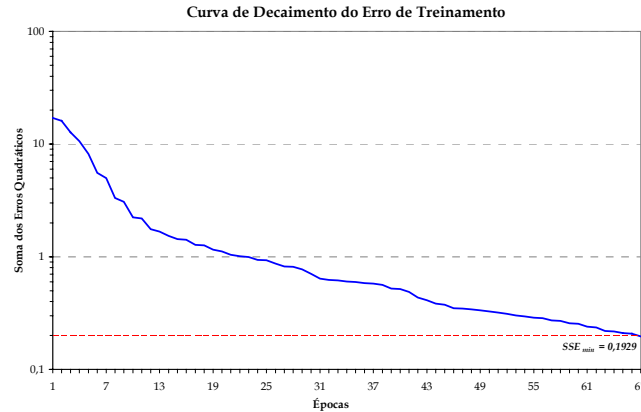


Figura 12. Curva de decaimento do erro de treinamento.




Figura 13. Comparativo da saída da rede com a saída desejada durante o treinamento.

A Figura 14 mostra o desempenho obtido pela RNA com as amostras restantes selecionadas aleatoriamente pelo algoritmo e sua capacidade de generalização.

5.2 Comparação de Resultados

Foram apresentados valores não utilizados para o treinamento (abril/05 a agosto/05) e verificado que os resultados obtidos são satisfatórios. Isto é, os valores reais de consumo de energia elétrica na laminação a frio e os previstos pela RNA apresentaram diferenças consideradas adequadas.

A Figura 15 ilustra a diferença entre os erros de previsão da demanda mensal




Figura 14. Saída da rede versus a saída desejada.

de energia realizada pelo modelo linear (atualmente utilizado) e pela RNA, desenvolvida neste trabalho.

Pode-se constatar que os erros da RNA são menores que os erros do modelo linear, com exceção do mês de abril. Em maio os erros dos dois métodos foram praticamente iguais.




Figura 15. Comparação entre modelo atual e RNA.

6 CONCLUSÕES

Após a escolha da RNA definitiva foram realizados diversos treinamentos e testes buscando um conjunto de pesos que fosse capaz de apresentar o melhor desempenho quando fossem apresentados à rede dados de entrada desconhecidos, demonstrando a capacidade de generalização da RNA.

Verificou-se que o erro da estimativa do consumo de energia em alguns meses foi maior que o esperado, porém este fato pode ser atribuído à maneira como os dados de entrada foram organizados. Além disso, alguns materiais possuem características especiais de processo, exigindo um consumo de energia diferenciado. Estes materiais devem ser melhor estudados e reagrupados de uma outra forma.

A comparação dos resultados obtidos pela RNA com relação aos valores estimados pelo modelo atualmente utilizado, demonstrou o bom desempenho da RNA. Indicando que as redes neurais artificiais constituem um bom método quando se deseja modelar sistemas.

Como desenvolvimento futuro a RNA deste trabalho deverá ser testada para um novo conjunto de dados, organizado de maneira diferente e levando-se em consideração características do material, como por exemplo, a dureza.

REFERÊNCIAS

- 1 LORENTZ, E. G. Aplicação de Redes Neurais na Previsão de Demanda de Energia Elétrica: Um Estudo Comparativo de modelos. Dissertação de Mestrado. Universidade Federal de Minas Gerais - UFMG. Belo Horizonte/MG, 1995.
- 2 HAYKIN, S. Redes Neurais – Princípios e Prática. 2ª Edição. Editora Bookman. Porto Alegre/RS, 2001.
- 3 DE CASTRO, L. N. Análise e Síntese de Estratégias de Aprendizagem para Redes Neurais Artificiais. Dissertação de Mestrado. Universidade Estadual de Campinas - UNICAMP. Campinas/SP, 1998.
- 4 DE CASTRO, L. N.; VON NUBEN, F. J. Redes Neurais Artificiais. Notas de aula. UNISANTOS. Santos/SP, 2004.
- 5 BASHEER, L. A., HAJMEER, M. Artificial Neural Networks: Fundamentals, Computing, Design and Application. Journal of Microbiological Methods. Elsevier Science, 2000.