

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NO
MODELAMENTO DE PROCESSOS DA LAMINAÇÃO DE CHAPAS GROSSAS

Antonio Augusto Gorni (1)

(1) Engenheiro de Materiais, M.Eng., da Gerência de Pesquisas da
Companhia Siderúrgica Paulista - COSIPA

RESUMO

Redes neurais artificiais são uma técnica relativamente recente de Inteligência Artificial que consiste na emulação de sistemas nervosos biológicos em programas ou circuitos digitais. Tais redes são capazes de estabelecer relações complexas entre dados, de forma relativamente precisa, sem que seja necessário informar a elas qual a função que os relaciona. Isto as tornam particularmente adequadas para o modelamento de processos cuja formulação matemática é difícil ou complicada. Neste trabalho são expostos e discutidos alguns exemplos reais da utilização de redes neurais no modelamento de alguns processos da Laminação de Chapas Grossas da COSIPA. Os resultados obtidos confirmaram a versatilidade das redes neurais, que permitiram o estabelecimento de modelos mais precisos que os obtidos através de regressão estatística, que podem mesmo rivalizar em desempenho com modelos deduzidos numericamente.

INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAIS

Desde o advento da computação digital até o final da década de 1980, praticamente todas as aplicações para processamento de dados e informações adotaram uma única abordagem básica: a computação programada. Ela consiste no desenvolvimento prévio de um algoritmo para a resolução do problema em questão, o qual era codificado em alguma linguagem de computação.

Esta abordagem é limitada, pois ela somente pode ser utilizada em casos onde o processamento a ser efetuado pode ser descrito em termos de um conjunto de regras conhecido. Contudo, nem sempre isso acontece; muitas vezes a dedução desse conjunto de regras pode ser difícil ou mesmo impossível. Além disso, uma vez que os computadores atuais trabalham de forma totalmente lógica, o programa final tem de estar praticamente perfeito para poder funcionar a contento. Logo, o desenvolvimento de programas para computador é, na verdade, uma sucessão de ciclos "projeto-teste-melhoria iterativa", que pode vir a demandar muito tempo, esforço e dinheiro.

No final da década de 1980 surgiu uma abordagem revolucionária para o processamento de dados e informações: a neurocomputação ou, como é mais conhecida, as redes neurais artificiais, também conhecidas como "perceptrons". Ela não requer o desenvolvimento de algoritmos ou conjunto de regras para analisar os dados, o que freqüentemente reduz de forma significativa o trabalho de desenvolvimento de programas que uma dada aplicação venha a requerer. Na maior parte dos casos, a rede neural passa por um processo de treinamento a partir de casos reais conhecidos, adquirindo a partir daí a metodologia necessária para executar adequadamente o processamento desejado dos dados fornecidos. Ou seja: ela tem capacidade de extrair as regras básicas desejadas a partir de dados reais, dispensando qualquer modelo prévio já conhecido. Esta é a abordagem utilizada nos sistemas nervosos biológicos, particularmente em seres humanos.

Com efeito, pode-se perceber melhor a diferença entre a computação programada e as redes neurais comparando-se computadores e seres humanos. Por exemplo, um computador efetua operações matemáticas com rapidez e precisão muito superiores aos seres humanos. Em contrapartida, estes conseguem reconhecer faces e imagens complexas de maneira muito mais precisa, eficiente e rápida que o melhor computador disponível atualmente.

Uma das razões dessa diferença de desempenho em tarefas diversas pode estar na forma como se organizam computadores e sistemas nervosos. Geralmente um computador consiste de um processador trabalhando sozinho, executando instruções fornecidas por um programador, uma a uma. Já sistemas nervosos consistem de bilhões de células nervosas - ou seja, neurônios - com alto grau de interconexão entre elas, que efetuam cálculos simples sem que haja a necessidade de serem programadas.

O elemento básico que constitui uma rede neural artificial chama-se, naturalmente, neurônio, conhecido ainda por nó ou elemento processador. Ele pode ser visto esquematicamente na figura 1. As ligações entre eles são chamadas de sinapses.

Os sinais fornecidos a um dado neurônio são, na verdade, o estado ou o valor de ativação dos neurônios precedentes, os quais são multiplicados por um peso correspondente. O estado, ou valor de ativação, do neurônio em questão, é calculado a partir da aplicação de uma função de limiar ao valor de entrada fornecido ao neurônio, ou seja, a somatória dos valores de ativação dos neurônios precedentes, multiplicados pelos respectivos pesos. A função de limiar (ou de ativação) geralmente é não-linear, e deve garantir a plena funcionalidade das redes neurais.

Nos primórdios de seu desenvolvimento, as redes neurais eram emuladas através de circuitos analógicos. A energia correspondente às conexões entre os neurônios (ou seja, a sinapse) era controlada por potenciômetros. Atualmente, é mais comum a utilização de "software" para a geração de redes neurais, ou seja, o funcionamento dos neurônios é simulado por programas. Uma tendência bastante recente é a implementação de redes neurais em circuitos digitais, visando à maximização de sua velocidade de processamento. Isto é conseguido através de arquiteturas digitais que permitam o processamento de dados de forma paralela. Normalmente elas são fornecidas na forma de placas que podem ser acopladas a micro-computadores ou estações de trabalho.

São mostrados na figura 2 os dois tipos básicos de redes neurais em função do fluxo de dados e tipo de treinamento.

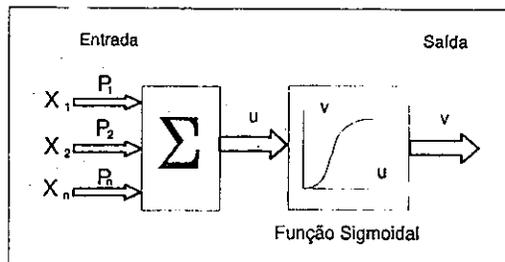


Figura 1: Representação esquemática de um neurônio ou elemento processador.

A primeira delas, do tipo Rummelhart, é aquela onde o fluxo de dados se dá apenas em um sentido - ou seja, é uma rede unidimensional. Ela é muito utilizada devido a sua simplicidade e estabilidade, sendo aplicada para classificação, análise e interpolação de dados, o que a torna particularmente adequadas para o modelamento de processos em geral. Uma característica fundamental deste tipo de rede é a disposição dos neurônios em camadas. Deve haver no mínimo duas camadas: a de entrada (de dados) e a de saída (de resultados). Uma vez que o desempenho desta tipo de rede neural com apenas duas camadas é muito limitado, normalmente se inclui pelo menos uma camada intermediária entre as duas, também chamada de oculta. Cada neurônio está ligado a todos os neurônios das camadas vizinhas, mas não há ligações entre os neurônios de uma mesma camada. O comportamento deste tipo de rede é estático; ela se comporta de modo a tornar sua saída um reflexo da respectiva entrada. Ela deve ser treinada de modo a produzir os resultados desejados a partir da apresentação de dados reais.

A outra rede neural da figura 2, do tipo Hopfield, se caracteriza por apresentar fluxo de dados multidirecional. Seu comportamento é dinâmico, mais complexo que o das redes de Rummelhart. Note-se que neste caso não há camadas discretas de neurônios: há total integração entre os dados de entrada e os resultados obtidos, pois todos os neurônios são ligados entre si. Tais redes são aplicadas em estudos sobre a otimização de conexões como, por exemplo, para se determinar o percurso ótimo de um caminhão de entregas ou um vendedor. Seu treinamento é feito de modo a minimizar a energia da rede, gerando um comportamento independente.

Aplicações particularmente adequadas para redes neurais são:

- Análise e processamento de sinais;
- Controle de processos;
- Robótica;

- Classificação de dados;
- Reconhecimento de padrões em linhas de montagem;
- Filtros contra ruído eletrônico ("smoothing");
- Análise de imagens;
- Análise de voz;
- Diagnóstico médico;
- Previsões do mercado financeiro;
- Avaliação de solicitações de crédito ou empréstimos;
- "Marketing" orientado;

pois normalmente se tratam de casos de difícil formulação matemática formal]

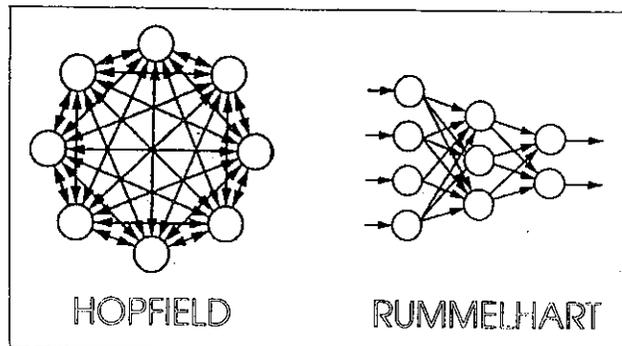


Figura 2: Tipos básicos de redes neurais.

COMPARAÇÃO COM OUTRAS TÉCNICAS DE MODELAMENTO

Redes neurais, sistemas especialistas e lógica nebulosa ("fuzzy logic") são técnicas de Inteligência Artificial bastante diferentes entre si, bem como da programação tradicional.

Sistemas Especialistas são diferentes da programação tradicional, uma vez que a base de conhecimento é separada do processador de conhecimentos (ou seja, o motor de inferência). Isto permite que se adicione conhecimento suplementar sem que seja necessário reprogramar o sistema. Esta técnica requer que se disponha de um especialista na área de conhecimento em questão, para que ele defina as regras que codifiquem a informação pertinente.

Já as redes neurais podem ser implementadas sem que haja a necessidade de se impor regras explícitas ou conhecimento formal prévio. Muito pelo contrário, a rede neural aprende as regras necessárias para lidar com o conhecimento, através do ajuste dos pesos

relativos às sinapses, de modo a minimizar o erro entre os dados reais e os calculados pela rede. Logo, o desenvolvimento de uma rede neural prescinde do trabalho intensivo de um especialista na matéria em questão, embora ele seja necessário para definir os critérios de seleção e preparação dos dados a serem fornecidos ao treinamento da rede neural.

Além disso, há uma diferença marcante entre as redes neurais e os sistemas especialistas: nem sempre é possível saber como uma rede neural chegou a um dado resultado, enquanto que um sistema especialista sempre tem condições de dar essa informação. Isso se torna crítico para problemas muito complexos.

Em certos casos torna-se interessante desenvolver sistemas híbridos de inteligência artificial que empregam redes neurais juntamente com sistemas especialistas ou de lógica difusa. Estes casos se caracterizam por aproveitar, de forma otimizada, as melhores características de cada abordagem.

Comparando-se as redes neurais com regressão estatística fica evidente uma vantagem da neurocomputação, ou seja: não há, a princípio, a necessidade de se determinar a priori quais variáveis são importantes. As redes neurais tendem a determinar automaticamente quais são elas. Parâmetros irrelevantes são anulados através das reduções das energias de suas conexões com os demais neurônios a que estão ligados. Além disso, não é necessário impor uma função como modelo, condição imprescindível para o uso da regressão estatística.

Outra vantagem das redes neurais em relação à regressão estatística é sua robustez, ou seja, maior grau de imunidade a ruídos nos dados ou falhas parciais no equipamento. Aliás, é até interessante treinar as redes neurais com dados contendo ruído, para que sua precisão aumente quando em uso sob condições reais.

As características acima permitem que as redes neurais incluam o maior número possível de variáveis de entrada no modelo. Do mesmo modo que parâmetros irrelevantes são progressivamente eliminados, são criadas interações múltiplas mais complexas e sutis entre as variáveis importantes, levando à maximização da precisão no modelo. Isto é particularmente útil em modelos com mais de três variáveis de entrada envolvidas.

Por outro lado, o uso de técnicas estatísticas pode ser muito útil na análise preliminar dos dados, refinando a informação a ser fornecida à rede neural e, desse modo, promover a minimização do tempo e esforço requeridos em seu desenvolvimento, bem como aumentar a precisão do modelo final. Há casos de modelos mistos onde se utilizam, de forma conjunta, redes neurais e regressão estatística.

Maiores detalhes sobre os fundamentos das redes neurais podem ser vistos em outros trabalhos [1,2].

EXEMPLOS PRÁTICOS: METALURGIA EM GERAL

No caso específico da Engenharia Metalúrgica já há um número significativo de aplicações de redes neurais:

- Modelamento do processo de flotação de minérios [3];

- Cálculo do perfil de temperatura do cadinho e do nível de carga do alto-forno [4];
- Modelamento das atividades químicas em soluções metálicas binárias, partição de enxofre e manganês entre o gusa e a escória, viscosidade de escórias em geral [5];
- Sistema para alerta preventivo ao risco iminente de rompimento do veio no lingotamento contínuo de placas, através da detecção prematura de perfis térmicos peculiares no molde ao longo do tempo [6];
- Sistema híbrido rede neural-lógica nebulosa para a prevenção de problemas operacionais durante o lingotamento contínuo [7];
- Reconhecimento e avaliação da legibilidade de caracteres de identificação escritos em placas [8];
- Dimensionamento de placas destinadas à laminação de chapas grossas [9];
- Modelamento da resistência à deformação a quente em função da temperatura, grau e velocidade de deformação para aços ARBL [10];
- Controle de planicidade num laminador a frio Sendzimir, através de um sistema híbrido rede neural-lógica nebulosa [11];
- Supressão de "chattering" em Laminadores de Tiras a Frio, através de um sistema híbrido rede neural-sistema especialista [12];
- Determinação de diagramas TTT para aços a partir de sua composição química [13];
- Análise sobre a viabilidade da fabricação de produtos laminados numa dada usina, em função das propriedades desejadas do produto, como limite de escoamento, espessura e garantia de tenacidade [14].

EXEMPLOS ESPECÍFICOS DO LAMINADOR DE CHAPAS GROSSAS

A fim de se avaliar o desempenho das redes neurais sob condições práticas, decidiu-se utilizar esta técnica no modelamento de vários processos na área do Laminador de Chapas Grossas da COSIPA, os quais já foram estudados no passado utilizando-se outras abordagens, notadamente regressão estatística.

As redes neurais aqui desenvolvidas foram do tipo unidimensional ("Rummelhart"), com uma camada oculta, treinada por retropropagação. A avaliação do grau de ajuste da rede treinada em relação aos dados reais presentes no conjunto de teste foi feita

calculando-se o coeficiente de correlação r de Pearson e o erro padrão da estimativa, bem como pelo traçado de gráficos de dispersão.

Modelamento do Perfil Térmico de Placas no Forno de Reaquecimento

Há algum tempo atrás foi feita a determinação experimental do perfil térmico de uma placa no Forno de Reaquecimento de Placas nº 1 do Laminador de Tiras a Quente da COSIPA. O resultado final da experiência foi um conjunto com aproximadamente 100 registros de dados, que descrevem a evolução da temperatura em onze locais da placa ao longo do tempo. Maiores detalhes podem ser obtidos em outra referência [15].

Decidiu-se modelar as temperaturas nos diversos pontos do interior da placa - de 1 a 10 - em função do tempo decorrido a partir de seu enformamento e das respectivas temperaturas da superfície superior (nº 11) e inferior (nº 12). A rede neural que apresentou o melhor desempenho em termos de ajuste entre os dados reais e calculados tinha a seguinte arquitetura:

- Camada de entrada com três neurônios, a saber:
 - . Tempo de enformamento [min];
 - . Temperatura da Superfície Superior [°C];
 - . Temperatura da Superfície Inferior [°C].
- Camada oculta com treze neurônios.
- Camada de Saída com dez neurônios, correspondentes à temperatura de cada ponto medido na placa.

A tabela I mostra o grau de ajuste obtido para cada ponto modelado, em termos de r e do erro padrão da estimativa. A figura 6 mostra os gráficos de dispersão para as temperaturas dos pontos nº 3 (melhor ajuste) e nº 6 (pior ajuste). O valor médio de r foi igual a 0,995 e o do erro padrão da estimativa, 36,6°C. A precisão obtida por esta rede neural pode ser considerada adequada, uma vez que é similar à obtida em modelos matemáticos desenvolvidos anteriormente.

Modelamento do Esquema de Passes para se Minimizar a Ocorrência de Ponta Alta

O encurvamento acentuado do esboço para cima ao sair do laminador - o chamado defeito ponta alta - deve ser evitado, pois pode ocorrer colisão do laminado com a cadeira ou seus equipamentos acessórios, acarretando prejuízos de grande monta. Foi realizado há algum tempo atrás um trabalho para se identificar as causas deste problema [16]. A contra-medida mais importante então sugerida foi a alteração do esquema de passes no laminador nas ocasiões em que se verificasse maior tendência à ocorrência do problema, objetivando maiores graus de deformação por passe.

Essa abordagem realmente se mostrou válida na operação industrial do Laminador de Chapas Grossas e, de fato, foi confirmada pela literatura. Infelizmente, ao se objetivar ponta alta nula, os esquemas de passe propostos pelo modelo estatístico desenvolvido naquele trabalho frequentemente requeriam reduções nulas ou excessivas em relação à capacidade efetiva da cadeira.

Nº Termopar	r	E.P.E. [°C]
1	0,996	26,5
2	0,997	27,1
3	0,997	26,5
5	0,997	30,7
6	0,993	46,2
7	0,992	40,1
8	0,996	34,6
9	0,995	43,9
10	0,995	44,6

Tabela I: Grau de ajuste obtido entre os valores calculados pela rede neural e os respectivos valores reais para cada ponto da placa.

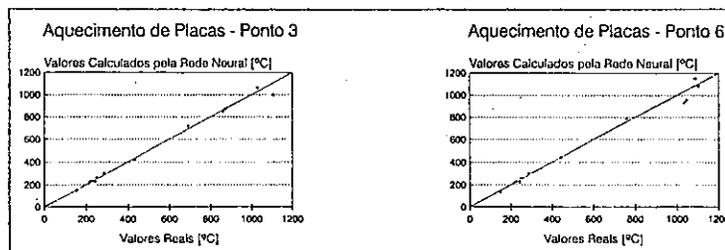


Figura 6: Grau de ajuste obtido pela rede neural para o melhor e pior caso (temperatura dos pontos nº 3 e nº 6, respectivamente) verificado no modelamento do perfil térmico da placa.

Surgiu então a idéia de se utilizar as redes neurais artificiais para se modelar o esquema de passes a ser aplicado ao esboço, objetivando-se um nível mínimo de ponta alta, utilizando-se reduções por passe otimizadas e factíveis.

A rede neural que melhor efetuou esse modelamento apresentou a seguinte configuração:

- Camada de entrada com cinco neurónios, a saber:
 - . Grau de Ponta Alta;
 - . Velocidade Periférica dos Cilindros [rpm];
 - . Carga de Laminação [t];
 - . Largura do Esboço [mm];
 - . Espessura Inicial do Esboço [mm].
- Camada oculta com onze neurónios.
- Camada de Saída com um neurónio, que é a espessura final do esboço após o passe [mm].

O grau de ponta alta, uma das variáveis de entrada, foi definido através de uma escala arbitrária que variou de 0 a 5, proporcionalmente ao nível de gravidade do defeito.

A rede neural aqui desenvolvida apresentou r igual a 0,992 e erro padrão da estimativa de 3,0 mm. A figura 7 mostra o gráfico de dispersão obtido. As variáveis de maior influência, segundo o aprendizado desenvolvido pela rede neural, são o grau de defeito e a espessura inicial do esboço, seguidos da largura do esboço, carga de laminação e velocidade periférica dos cilindros, em ordem decrescente de importância.

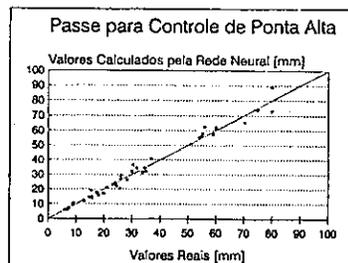


Figura 7: Grau de ajuste gráfico obtido pela rede neural na previsão do passe a ser aplicado de modo a se controlar o grau de ponta alta.

Como se pode observar neste gráfico, todos os valores calculados estão bem próximos aos reais, não sendo apresentados valores

absurdos como os que o polinômio de regressão anteriormente desenvolvido gerava [16].

Havia sido verificado anteriormente que a ocorrência de ponta alta é mais séria na faixa de espessuras de esboço entre 80 e 40 mm [16]. Isso é confirmado pelo aprendizado desenvolvido pela rede neural, uma vez que a espessura inicial do esboço é um dos fatores mais importantes do modelo. Além disso, o erro padrão da estimativa do modelo é aceitável, uma vez que é de apenas 7,5% em relação à menor espessura, desde que o produto final não apresente espessura dentro da faixa de 40 a 80 mm.

Cálculo do Descarte no Esboço Final ao se Aplicar o Sistema CPC

A laminação de chapas grossas a partir de placas provenientes do lingotamento contínuo tem como característica a obtenção de esboços com ponta em forma de língua, ou seja, baixo índice de retangularidade. Tal fato se deve à distribuição de espessura peculiar à este tipo de placa, ou seja, ela é maior no centro do que nas bordas, resultando numa distribuição de massa não-homogênea ao longo do esboço laminado.

Uma solução proposta para esse problema foi a aplicação de um perfil de espessura especial no esboço por ocasião da aplicação do último passe da fase de alargamento. Basicamente este perfil consiste num entalhe em "V" ou em forma de "osso de cachorro". A implantação deste recurso levou a um aumento de 0,7% no rendimento metálico do processo [17].

Procurou-se relacionar a profundidade do entalhe aplicado e a redução total após o alargamento com o comprimento do descarte efetuado no esboço final, a fim de se compreender melhor o processo e verificar as possibilidades de sua otimização. Obteve-se desse modo um polinômio de regressão com grau de ajuste de r da ordem de 0,903 e erro padrão da estimativa de 132 mm.

A fim de se conseguir melhor precisão neste modelamento, resolveu-se construir uma rede neural com o mesmo objetivo. O melhor perceptron apresentou a seguinte topologia:

- Camada de entrada com dois neurônios:
 - . Profundidade do entalhe aplicado [mm];
 - . Grau de redução total aplicado após o alargamento.
- Camada oculta com cinco neurônios.
- Camada de saída com um neurônio, o comprimento do descarte a ser efetuado [mm].

Ela apresentou coeficiente de correlação r igual a 0,943 e erro padrão da estimativa igual a 61 mm. O diagrama de dispersão está mostrado na figura 8.

Apesar da rede neural ter apresentado desempenho bom melhor que o do polinômio de regressão (o erro padrão de estimativa caiu em 54%, aproximadamente), os desvios observados na figura 8 ainda são consideráveis. Uma provável causa para este problema está no uso

do comprimento do descarte como avaliação do grau de rendimento metálico do processo. Ele é bem menos representativo do que o peso ou área do descarte efetuado, mas, em compensação, é um parâmetro bem mais fácil de ser medido.

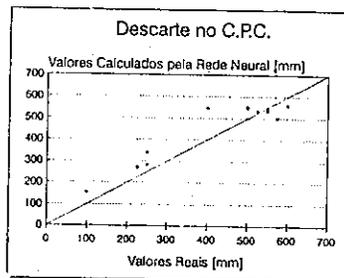


Figura 8: Grau de ajuste gráfico proporcionado pela rede neural no cálculo do descarte efetuado no esboço laminado quando se aplicou o sistema CPC.

Modelamento do Esquema de Passes Visando Otimizar a Planicidade do Esboço

Um dos atributos mais críticos em termos da qualidade do esboço é seu grau de planicidade. Recentemente foi desenvolvido um estudo para se propor um modelo de controle do processo com o objetivo de se garantir um nível adequado de planicidade [18]. A metodologia então proposta consistiu em se controlar a taxa de variação de coroa/variação de espessura dentro de uma faixa de valores que foi determinada experimentalmente para os últimos três passes, objetivando-se nível ótimo de planicidade.

O principal inconveniente deste modelo é que ele deve ser inserido dentro de um algoritmo para cálculo de esquema de passes "on-line" que estime a carga prevista e, a partir daí, determine a coroa mecânica que será aplicada no laminado. O passe objetivado deve atender à condição citada no parágrafo anterior. Caso contrário, deverá ser modificado iterativamente até que a condição para boa planicidade seja atendida. Eventualmente este processo poderá ser demorado, se o microcomputador onde o programa estiver sendo executado for lento.

Uma vez que a literatura afirma que apenas os últimos três passes aplicados exercem papel fundamental na planicidade do esboço, resolveu-se experimentar a técnica das redes neurais para se estabelecer uma relação direta entre o nível de planicidade do produto final e o esquema de passes aplicado.

Foram propostas três redes neurais, uma para cada passe a ser modelado. Suas topologias foram idênticas:

- Camada de entrada com dez neurônios:
 - . Espessura do Esboço Final [mm];
 - . Largura do Esboço Final [mm];
 - . Grau de Planicidade Objetivado no Produto Final;
 - . Grau de Planicidade Observado após o Passe Anterior;
 - . Abertura dos Cilindros do Passe Anterior [mm];
 - . Carga do Passe Anterior [t];
 - . Temperatura do Passe Anterior [°C];
 - . Coroa Imposta ao Cilindro Superior [mm];
 - . Coroa Imposta ao Cilindro Inferior [mm];
 - . Tonelagem Laminada [t].
- Camada oculta com 21 neurônios;
- Camada de saída com um neurônio: abertura de cilindros objetivada no passe em questão [mm];

O grau de planicidade utilizado neste modelo era uma escala arbitrária de 0 a 5: quanto pior ela fosse, maior era o índice atribuído ao esboço.

A tabela II mostra o grau de ajuste obtido em termos de r e do erro padrão de estimativa, enquanto que a figura 9 mostra o gráfico de dispersão para os três passes calculados.

PASSE	r	E.P.E. [mm]
Antepenúltimo	0,998	0,430
Penúltimo	0,998	0,394
Último	0,999	0,140

Tabela II: Grau de ajuste obtido pelas redes neurais que calculam os passes de acabamento, visando otimização do grau de planicidade do esboço.

As variáveis de maior influência nesta rede neural foram o grau de planicidade objetivado no esboço final, a coroa imposta no cilindro superior e a tonelagem laminada. Num segundo escalão ficaram parâmetros como a espessura final do esboço, a temperatura/carga de laminação do passe anterior e a largura do esboço. Já variáveis como o grau de planicidade e a abertura dos cilindros relativos ao passe anterior não apresentaram influência muito forte, mas foram vitais para que a rede neural apresentasse um nível de precisão viável para que ela pudesse ser utilizada sob condições industriais.

Efetivamente a rede neural conseguiu identificar as variáveis teoricamente mais importantes quanto à planicidade do esboço ao longo de seu treinamento. A coroa imposta aos cilindros foi fornecida diretamente como dado à rede neural, que a selecionou como

uma das variáveis mais significativas, juntamente com a tonelagem laminada. Esta, por sinal, apresenta boa correlação com a coroa térmica e o desgaste do cilindro, que são variações na coroa total do cilindro decorrentes da operação de laminação. A deflexão dos cilindros devido à carga de laminação também foi considerada, uma vez que esta última variável apresentou grau destacado de importância na rede neural.

No processo de laminação de chapas grossas, o último passe é o mais crítico quanto à precisão dimensional do produto, particularmente no tocante à espessura. Os desvios máximos observados nos resultados calculados pela rede neural que modela o último passe foram de -0,26 mm a +0,17 mm, praticamente dentro da faixa operacional desejada, uma vez que apenas houve uma ocorrência fora da especificação. Os resultados obtidos poderão ser ainda melhores com a implantação da aquisição automatizada dos dados, evitando-se erros humanos em sua coleta e aumentando a precisão dos parâmetros medidos, o que sem dúvida se refletirá na acuracidade da rede neural.

CONCLUSÕES

A neurocomputação, técnica que emula sistemas nervosos biológicos em programas ou circuitos de computador, foi concebida há mais de cinquenta anos atrás, mas só recentemente experimentou ampla utilização prática, graças à intensa pesquisa teórica nesse campo e ao enorme desenvolvimento na área dos microprocessadores.

Uma grande característica das redes neurais é sua capacidade de aprendizado, ou seja, a possibilidade de estabelecer, de forma precisa, relações complexas entre diversas variáveis numéricas, sem que seja imposto qualquer modelo preconcebido. É uma abordagem revolucionária, que contrasta com a filosofia hoje consagrada para o tratamento de dados, a computação programada, que requer algoritmos rigorosamente detalhados para processá-los. Ela apresenta diversas vantagens em relação a outras técnicas de modelamento e controle, como regressão estatística, sistemas especialistas e, talvez, modelos matemáticos.

No caso específico da laminação de chapas grossas da COSIPA, a utilização de redes neurais apresentou bons resultados no modelamento de perfil térmico de placas durante seu reaquecimento, prevenção do defeito ponta alta, cálculo do descarte do esboço ao se utilizar o sistema CPC e na determinação de esquemas de passe para otimizar a planicidade do esboço final. Isto revelou que esta técnica é uma promissora ferramenta para o desenvolvimento dos modelos que se fazem necessários para a automação do processo de laminação.

Os exemplos práticos aqui mostrados permitiram concluir que a técnica de redes neurais encontra aplicações viáveis no modelamento dos processos de laminação a quente. Ainda foi possível constatar que ela é superior à regressão estatística, particularmente no caso do modelamento da ponta alta e no cálculo do descarte do esboço ao se utilizar o sistema CPC, onde o modelamento matemático formal é complicado.

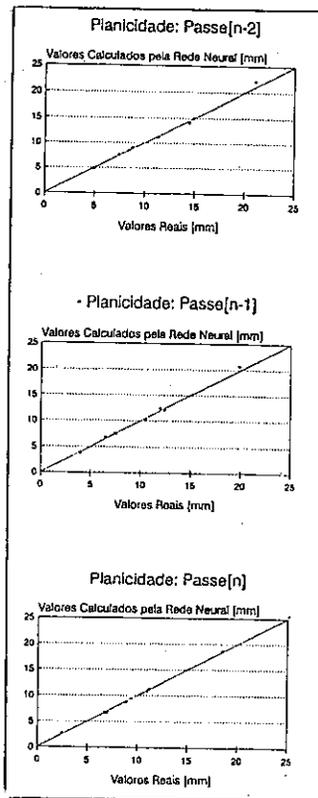


Figura 9: Grau de ajuste gráfico obtido pelas redes neurais que calculam os passes de acabamento, visando otimização da planicidade.

- BIBLIOGRAFIA

1. GORNI, A.A. Micro Sistemas, Novembro 1993, 14-25.

2. GORNI, A.A. Micro Sistemas, Dezembro 1993, 14-17.
3. REUTER, M.A. & VAN DEN VENTER, J.S.J. A ser publicado em Chemical Engineering Science, 1993.
4. OTSUKA, Y. e outros. Tetsu-to-Hagané, 77(10):1539-1543, August 1991.
5. REUTER, M.A. e outros. Metallurgical Transactions B, 23B(10):643-650, October 1992.
6. KOMINAMI, H. e outros. Nippon Steel Technical Report, 49:34-38, April 1991.
7. BULSARI, A. e outros. Scandinavian Journal of Metallurgy, 21(3):146-150, 1992.
8. ASANO, K. e outros. Kawasaki Steel Technical Report, 26:38-45, June 1992.
9. OLIVEIRA, J.B. e outros. In: SEMINÁRIO DE LAMINAÇÃO. Anais. Associação Brasileira de Metalurgia e Materiais, Porto Alegre, 1992, 319-335.
10. GORNI, A.A. In: I SEMANA DE CONFORMAÇÃO (METAL FORMING WEEK). Anais. Associação Brasileira de Metalurgia e Materiais, Joinville, 1993, 267-286.
11. HATTORI, S. e outros. Hitachi Review, 41(1):31-38, 1992.
12. ANON. Integrating a Neural Network and Expert System for Machine Diagnosis. Carnegie Group Report, 1991. 4 p.
13. DONADILLE, C. e outros. La Revue de Metallurgie - CIT, 89(10):892-894, Octobre 1992.
14. WATANABE, M. e outros. Nippon Steel Technical Report, 53:29-34, April 1992.
15. LANNA, J.A. e outros. In: SEMINÁRIO DE PROJETOS METALÚRGICOS. Anais. Associação Brasileira de Metais, Volta Redonda, 1984, 84-102.
16. GORNI, A.A. e outros. In: SEMINÁRIO DE LAMINAÇÃO. Anais. Associação Brasileira de Metalurgia e Materiais, Porto Alegre, 1992, 299-318.
17. REIS, J.S.S. e outros. In: SEMINÁRIO DE LAMINAÇÃO. Anais. Associação Brasileira de Metalurgia e Materiais, Porto Alegre, 1992, 365-378.
18. REIS, J.S.S. e outros. In: 48º CONGRESSO ANUAL DA ASSOCIAÇÃO BRASILEIRA DE METALURGIA E MATERIAIS. Anais. Rio de Janeiro, 1993.