

ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO

RICARDO CASCIATO CARLINI

**APLICAÇÃO DAS REDES NEURAIS ADAPTATIVAS NA PREVISÃO
DAS CURVAS TENSÃO DEFORMAÇÃO DE AÇOS**

São Paulo

2008

RICARDO CASCIATO CARLINI

**APLICAÇÃO DAS REDES NEURAIS ADAPTATIVAS NA PREVISÃO
DAS CURVAS TENSÃO DEFORMAÇÃO DE AÇOS**

Trabalho de Formatura apresentado à
Escola Politécnica da Universidade de
São Paulo

Área de concentração: Engenharia
Metalúrgica

Orientador: Prof. Dr. Ronald Lesley
Plaut.

São Paulo

2008

AGRADECIMENTOS

Ao Prof. Dr. Ronald Lesley Plaut, pela oportunidade e orientação na realização desse trabalho.

Aos amigos e em especial ao Daniel “Eek” Bae, pela ajuda para a conclusão do trabalho.

À Pamela, por ter me apoiado em todos os momentos que precisei.

E a todos que colaboraram direta ou indiretamente para a execução desse trabalho.

RESUMO

Com o avanço tecnológico na fabricação de metais, foram surgindo necessidades de maior controle das variáveis na conformação do material, como tensão, deformação, taxa de deformação e temperatura. Uma maneira de controlar essas variáveis é através de programas computadorizados.

Assim, este trabalho apresenta o programa NeuroSolutions,, uma ferramenta para desenvolver redes neurais adaptativas, explicando inicialmente suas funções e aplicando as redes desenvolvidas em diferentes aços e em diferentes condições, de acordo com os dados fornecidos pela literatura técnica.

LISTA DE FIGURAS

Figura 4.1 - Modelo de MacCulloch e Pitts.....	16
Figura 4.2 – Esquema de um neurônio artificial	17
Figura 4.3 – Organização em camadas	18
Figura 4.4 – Relação erro x pesos	21
Figura 5.1 – Arquitetura da rede Multilayer Perceptron	27
Figura 5.2 – Arquitetura de rede Generalized Feed Forward	27
Figura 5.3 – Arquitetura da rede Modular Neural	28
Figura 5.4 – Arquitetura da rede Jordan/Elman Network	29
Figura 5.5 – Arquitetura da rede PCA	29
Figura 5.6 – Arquitetura da rede RBF	30
Figura 5.7 – Arquitetura da rede Self Organizing Feature Map	31
Figura 5.8 – Arquitetura da rede Time-Lag Recurret	31
Figura 5.9 – Arquitetura da rede Recurret	32
Figura 5.10 – Arquitetura da rede CANFIS	33
Figura 5.11 – Arquitetura da rede Support Vector Machine	33
Figura 5.12 – Ícone Axon	34
Figura 5.13 – Ícone Bias Axon	34
Figura 5.14 – Ícone Linear Axon	35
Figura 5.15 – Ícone Sigmoid Axon	35
Figura 5.16 – Ícone Linear Sigmoid Axon	35
Figura 5.17 – Ícone Tah Axon	36
Figura 5.18 – Ícone Linear Tanh Axon	36
Figura 5.19 – Ícone Soft Max Axon	37
Figura 7.1 – inclinação positiva	53
Figura 7.2 – inclinação negativa	54
Figura 10.1 – Arquitetura da rede refinada – detalhes	64
Figura 10.2 – Arquitetura da rede refinada	64

LISTA DE TABELAS

Tabela 6.1 – Valor de r para a rede Multilayer Perceptron	41
Tabela 6.2 – Valor de r para Generalized Feed Forward	47
Tabela 6.3 – Valor de r para Modular Neural	48
Tabela 6.4 – Valor de r para Jordan / Elman	48
Tabela 6.5 – Valor de r para PCA	50
Tabela 6.6 – Valor de r para Self Organizing	50
Tabela 6.7 – Valor de r para Time Lag Recurrent	51
Tabela 6.8 – Valor de r para Recurrenet Network	51
Tabela 6.9 – Valor de r para CANFIS	51
Tabela 7.1 – Comparação de r com e sem o uso da inclinação da reta tangente.....	55
Tabela 8.1 – Comparação dos valores de r para diferentes aços	58
Tabela 8.2 – Melhores valores de r para os diferentes aços	59
Tabela 9.1 – Valores de r em função do refinamento – Generalized Feed Forward.....	60
Tabela 9.2 – Valores de r em função do refinamento – Jordan/Elman Network.....	61
Tabela 9.3 – Valores de r em função do refinamento – Modular Neural Network.....	62
Tabela 9.4 – Valores de r em função do refinamento – Multilayer Perceptron.....	62
Tabela 10.1 – Valores de entrada e saída, Aço Inox. 304	67
Tabela 10.2 – valores de entrada e saída, Aço Carbono Austenítico	68
Tabela 12.1 – Melhores valores de r para cada aço	76

LISTA DE GRÁFICOS

Gráfico 6.1 – Resultado Sigmoid Axon / Step	41
Gráfico 6.2 – Resultado Sigmoid Axon / Momentum	42
Gráfico 6.3 – Resultado Soft Max Axon / Momentum	43
Gráfico 6.4 – Resultado Linear Axon / Momentum	44
Gráfico 6.5 – Resultado Axon / Step	45
Gráfico 6.6 – Tanh Axon / Momentum	45
Gráfico 6.7 – Resultado Conjugate Gradient / Step	46
Gráfico 6.8 – Resultado Levenberg Marquardt / Momentum	46
Gráfico 6.9 – Resultado Tanh Axon / Quickprop	49
Gráfico 10.1 – Aço Inoxidável 304	65
Gráfico 10.2 – Aço Carbono Austenítico	66
Gráfico 10.3 - Gráfico de dispersão para o Aço Inox. 304	69
Gráfico 10.4 – Gráfico de dispersão da literatura	69
Gráfico 10.5 – Gráfico de dispersão do aço carbono austenítico	70
Gráfico 10.6 – Sensibilidade – Aço Inox 304.....	71
Gráfico 10.7 – Sensibilidade – Aço Carbono Austenítico	71
Gráfico 10.8 – Sensibilidade da temperatura – Aço Inox 304	72
Gráfico 10.9 – Sensibilidade da temperatura – Aço Carbono Austenítico	72
Gráfico 11.1 – Valores reais e simulados da RNE, Aço C-Mn	75
Gráfico 11.2 – Dispersão. Aço C-Mn	75

SUMÁRIO

1. INTRODUÇÃO	11
2. OBJETIVOS	12
3. ARTIGOS PUBLICADOS E FONTES DE DADOS	13
4. REDES NEURAIS ADAPTATIVAS (RNA)	14
4.1 INTRODUÇÃO ÀS REDES NEURAIS	14
4.2 OPERAÇÃO DE UMA REDE	14
4.3 O NEURÔNIO ARTIFICIAL E A REDE NEURAL	15
4.3.1 O neurônio artificial	16
4.4 A REDE NEURAL ADAPTATIVA (MULTILAYER PERCEPTRON)	17
4.5 DESENVOLVIMENTO DE APLICAÇÕES	19
4.5.1 Coleta de dados e separação em conjuntos.....	19
4.5.2 Configuração da rede	20
4.5.3. Treinamento	20
4.5.4. Teste	22
4.5.5. Integração da rede	23
4.6. APLICAÇÕES DE REDES NEURAIS ADAPTATIVAS	23
4.7 PROGRAMAS DISPONÍVEIS / UTILIZADOS	24
5. APRESENTAÇÃO DAS PARTES DE UMA RNA	26
5.1 ARQUITETURA	26
5.1.1 Multilayer Perceptron (MLP)	26
5.1.2 Generalized Feed Forward	27
5.1.3 Modular Neural Network	28
5.1.4 Jordan / Elman Network	29
5.1.5 Principal Component Analysis (PCA)	29
5.1.6 RBF/GRNN/PNN Network	30
5.1.7 Self Organizing Featura Map Network	31
5.1.8 Time-Lag Recurrent Network (TLRN)	31
5.1.9 Recurrent Network	32
5.1.10 CANFIS Network (Fuzzy Logic)	33
5.1.11 Support Vector Machine (SVM)	33

5.2 FUNÇÕES DE TRANSFERÊNCIA	34
5.2.1 Axon	34
5.2.2 Bias Axon	34
5.2.3 Linear Axon	35
5.2.4 Sigmoid Axon	35
5.2.5 Linear Sigmoid Axon	35
5.2.6 Tanh Axon	36
5.2.7 Linear Tanh Axon	36
5.2.8 Soft Max Axon	37
5.3 MÉTODOS DE APRENDIZADO	37
5.3.1 Conjugate Gradient	37
5.3.2 Levenberg Marquardt (LM)	38
5.3.3 Step	38
5.3.4 Delta Bar Delta	38
5.3.5 Momentum	39
5.3.6 Quickprop	39
6. APLICAÇÃO DAS REDES NEURAIS ADAPTATIVAS	40
6.1 APLICAÇÃO MULTILAYER PERCEPTRON	40
6.2 APLICAÇÃO GENERALIZED FEED FORWARD	47
6.3 APLICAÇÃO MODULAR NEURAL NETWORK	47
6.4 APLICAÇÃO JORDAN / ELMAN NETWORK	48
6.5 APLICAÇÃO PRINCIPAL COMPONENT ANALYSIS (PCA)	50
6.6 APLICAÇÃO SELF ORGANIZING FEATURE MAP NETWORK	50
6.7 APLICAÇÃO TIME-LAG RECURRENT NETWORK	50
6.8 APLICAÇÃO RECURRENT NETWORK	51
6.9 APLICAÇÃO CANFIS NETWORK (FUZZY LOGIC)	51
6.10 CONCLUSÕES PARCIAIS	52
7. USO DA INCLINAÇÃO DA RETA TANGENTE NOS DADOS DE ENTRADA.....	53
7.1 MÉTODO PARA OBTER A INCLINAÇÃO DA RETA	53
7.2 NOVA APLICAÇÃO DAS REDES NEURAIS ADAPTATIVAS	54
7.3 CONCLUSÕES PARCIAIS	55
8. APLICAÇÃO DAS REDES NEURAIS PARA AÇO CARBONO	57

8.1 APLICAÇÃO DAS REDES NEURAIS PARA O AÇO CARBONO AUSTENÍTICO.....	57
8.2 CONCLUSÕES PARCIAIS	58
9. REFINAMENTO DAS REDES	60
9.1 REFINAMENTO DA REDE GENERALIZED FEED FOWARD	60
9.2 REFINAMENTO DA REDE JORDAN/ELMAN NETWORK	61
9.3 REFINAMENTO DA REDE MODULAR NEURAL NETWORK	62
9.4 REFINAMENTO DA REDE MULTILAYER PERCEPTRON	62
9.5 ESCOLHA DA REDE FINAL	63
10. DETALHES DA REDE NEURAL SELECIONADA	64
10.1 ARQUITETURA DA REDE	64
10.2 ANÁLISE DOS RESULTADOS	65
10.2.1 Gráficos Comparativos	65
10.2.2 Tabelas de Saída	66
10.2.3 gráficos de dispersão	68
10.2.4 Sensibilidade dos Parâmetros	70
10.2.5 Influência da temperatura	72
10.3 CONCLUSÕES PARCIAIS	73
11. APLICAÇÃO DA RNA COM MAIS PARÂMETROS NA ENTRADA.....	74
11.1 RESULTADOS DA APLICAÇÃO DA RNA COM O NOVO PARÂMETRO	74
12. CONCLUSÃO	76
13. SUGESTÃO	78
REFERÊNCIAS	79
ANEXO 1	80
ANEXO 2	102
ANEXO 3	106
ANEXO 4	111
ANEXO 5	116
ANEXO 6	125
ANEXO 7	132

1. INTRODUÇÃO

Este trabalho de formatura, requisito fundamental para a conclusão do curso de Engenharia Metalúrgica da Escola politécnica da Universidade de São Paulo (EPUSP), apresenta um estudo sobre redes neurais adaptativas e, mais especificamente, sobre o programa NeuroSolutions, através de aplicações em aços de diferentes tipos.

O trabalho se apoiou em artigos publicados sobre o assunto e na versão shareware de programa de redes neurais adaptativas.

2. OBJETIVOS

O objetivo desse trabalho é obter a previsão do comportamento de aços com diferentes condições de temperatura, deformação e taxa de deformação, através do uso de redes neurais adaptativas, a partir dos dados disponíveis na literatura técnica.

3. ARTIGOS PUBLICADOS E FONTES DE DADOS

Este trabalho será desenvolvido com base nos dados obtidos nos artigos publicados no Journal of Materials Technology por P. D. Hodgson, L. X. Kong, C. H. J. Davies e D. C. Collison nos anos de 1999 e 2000 [1][2].

Os estudos mostram a previsão da deformação a quente em aços com o uso de um modelo de rede neural adaptativa. Em ambos os casos as previsões são feitas usando os dados de temperatura, tensão e deformação, método denominado ANN (Adaptative Neural Network) no artigo, e comparados com previsões que também levam em consideração, nos dados de entrada da rede, o coeficiente de correlação de Pearson, cujo resultado é a inclinação da reta tangente à curva tensão x deformação e é denominado IPANN (Integrated Phenominological Adaptative Neural Network)

O artigo de 1999 fez a análise de uma aço inoxidável 304 comercial, enquanto o artigo de 2000 analisou uma aço carbono austenítico, contendo 0,79% de carbono em peso.

Como resultados os estudos mostram um significativo aumento na precisão da RNA com o uso da inclinação da reta tangente sendo adicionado nos dados de entrada.

Os Artigos se encontram nos anexos 5 e 6.

4. REDES NEURAIAS ADAPTATIVAS (RNA).

O presente capítulo visa explicar sucintamente o conceito de Redes Neurais Adaptativas (RNA), mostrando sua origem, principais modelos utilizados e aplicações.

4.1 INTRODUÇÃO ÀS REDES NEURAIAS

As redes neurais artificiais consistem em um método de solucionar problemas, usando inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas, em um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através de funções matemáticas.

Uma rede neural artificial é composta por várias unidades de processamentos, cujo funcionamento é bastante simples. Estas unidades geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede.[3]

4.2 OPERAÇÃO DE UMA REDE

De forma geral, a operação de uma célula da rede se resume em:

- Dados são apresentados à entrada;

- Cada dado é multiplicado por um peso que indica sua influência na saída da unidade;
- É feita a soma ponderada dos dados que produz um nível de atividade;
- Se este nível excede um limite (threshold) a unidade produz uma saída.[3]

4.3 O NEURÔNIO ARTIFICIAL E A REDE NEURAL

Assim como o sistema nervoso, composto por bilhões de células nervosas, que é a sede da inteligência, o lugar onde se formam as idéias e do qual partem as ordens para a execução de movimentos e regulação de funções e estímulos, a rede neural artificial é formada por pequenos módulos, ou objetos, que simulam o funcionamento de um neurônio. Estes módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo, e gerando informações.[3]

4.3.1 O NEURÔNIO ARTIFICIAL

Atualmente, o modelo mais utilizado para explicar o funcionamento de uma rede neural é o do fisiologista Warren MacCulloch. Ele interpretou o funcionamento do neurônio biológico como sendo um círculo de entradas binárias combinadas por uma soma ponderada (com pesos) produzindo uma entrada efetiva:




Figura 4.1 - Modelo de MacCulloch e Pitts

No modelo geral de neurônios (fig. 4.1) as entradas $W_i U_i$ são combinadas resultando em uma função F , para produzir um estado de ativação do neurônio. As entradas chegam através dos dendritos, que são receptores dos estímulos transmitidos por outros neurônios, e tem um peso atribuído pela sinapse, que são junções interneurais.[3].

A função básica de um neurônio é somar as entradas e retornar uma saída, como mostra a figura 4.2.




Figura 4.2 – Esquema de um neurônio artificial

4.4 A REDE NEURAL ADAPTATIVA (MULTILAYER PERCEPTRON)

A rede neural adaptativa é um sistema de neurônios ligados por conexões sinápticas e dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos, que efetuam todo processo de classificação e ponderação dos estímulos, e neurônios de saída, que se comunicam com o exterior.

Existem várias formas de mostrar essa rede, mas a mais utilizada é a de Multilayer Perceptron, que foi concebida para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Um único perceptron ou uma combinação das saídas de alguns perceptrons poderia realizar uma operação, porém, seria incapaz de aprendê-la. Para isto são necessárias mais conexões, as quais só existem em uma rede de perceptrons dispostos em camadas, como mostra a figura 4.3, dessa forma os neurônios internos são de suma importância na rede neural, pois se provou que se torna impossível a resolução de

problemas lineares não separáveis, já que quanto mais camadas a rede possuir, mais trabalhado será o resultado de saída da rede.

Assim pode-se dizer que uma rede é composta por várias unidades de processamento. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. A inteligência da Rede Neural Artificial vem das interações entre as unidades de processamento da rede.




Figura 4.3 – Organização em camadas

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos e suas conexões são ajustados de acordo com os padrões apresentados, aprendendo de acordo com os exemplos apresentados. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Então a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação

programada, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.[4]

Usualmente as camadas são classificadas em três grupos:

- Camada de Entrada: onde os padrões são apresentados à rede;
- Camadas Intermediárias ou Ocultas: onde feita a maior parte do processamento, através das conexões ponderadas, podem ser consideradas como extratoras e características;
- Camada de Saída: onde o resultado final é concluído e apresentado.

De acordo com a arquitetura da rede neural, existe uma classificação conforme implementação, topologia, características de seus nós, regras de treinamento e tipos de modelos.

4.5 DESENVOLVIMENTO DE APLICAÇÕES

Existem certos procedimentos para a construção de uma rede neural consistente:

4.5.1 COLETA DE DADOS E SEPARAÇÃO EM CONJUNTOS

Os dois primeiros passos do processo para o desenvolvimento de redes neurais artificiais são de suma importância para diminuir a probabilidade de erros do sistema: a coleta de dados relativos ao problema; e a sua separação em um conjunto de treinamento, um conjunto de avaliação e um conjunto de testes. Esta tarefa requer uma análise cuidadosa sobre o problema para minimizar ambigüidades e erros nos dados.

Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema; devem cobrir operações normais ou rotineiras, exceções e as condições nos limites do domínio do problema.

Normalmente, os dados coletados são divididos em três categorias: dados de treinamento, usados para o treinamento da rede, dados de validação, utilizados para verificar a eficiência da rede quando a sua capacidade de generalização durante o treinamento, e podendo ser empregado como critério de parada do treinamento, e dados de teste, utilizados para verificar sua performance sob condições reais de utilização.

Geralmente, os dados são colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. É recomendável, se necessário, pré-processar estes dados, através de normalizações, escalonamento e conversões de formato para torná-los mais apropriados à sua utilização na rede.

4.5.2 CONFIGURAÇÃO DA REDE

O terceiro passo é a definição da configuração da rede, que pode ser dividido em três etapas:

- Seleção do paradigma neural apropriado à aplicação;
- Determinação da topologia da rede a ser utilizada – o numero camadas, o numero de unidades em cada camada, etc.
- Determinação de parâmetros do algoritmo de treinamento e função de ativação. Este passo tem um grande impacto na performance do sistema resultante.

4.5.3. TREINAMENTO

O quarto passo é o treinamento da rede. Nesta fase, segundo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. É importante

considerar, nesta fase, alguns aspectos tais como a inicialização de redes, o modo de treinamento e o tempo de treinamento.

Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos, em um intervalo definido. A escolha errada destes pesos pode levar a uma saturação prematura.

Para achar o melhor peso de cada conexão as redes utilizam um gráfico que relaciona os pesos com o erro, objetivando atingir o ponto de mínimo do gráfico, como na figura 4.4




Figura 4.4 – Relação erro x pesos

Quanto ao modo de treinamento, na prática é mais utilizado o modo padrão devido ao menor armazenamento de dados, além de ser menos suscetível ao problema de mínimos locais, devido à pesquisa de natureza estocástica que realiza.

Por outro lado, no modo “batch” se tem uma melhor estimativa do vetor gradiente, o que torna o treinamento mais estável. A eficiência relativa dos dois modos de treinamento depende do problema que está sendo tratado[4].

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada. Normalmente, o critério de parada utilizado é um número máximo de ciclos. Mas, devem ser considerados a taxa de erro médio por ciclo, e a capacidade de generalização da rede. Pode ocorrer que em um determinado instante do treinamento a rede comece a degenerar, causando o problema de “over-training”, ou seja, a rede se especializa em um conjunto de dados de treinamento e perde a capacidade de generalização[4].

O treinamento deve ser interrompido quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena, ou seja, menor que um erro admissível. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima[4].

4.5.4. TESTE

O quinto passo é o teste da rede. Durante esta fase o conjunto de teste é utilizado para determinar a performance da rede com dados que não foram previamente utilizados. A performance da rede, medida nesta fase, é uma boa indicação de sua performance real.

Devem ser considerados ainda outros testes como análise do comportamento da rede utilizando entradas especiais e análise dos pesos atuais da rede, pois se existirem valores muito pequenos, as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas (prunning). De modo inverso, valores substantivamente maiores que os outros poderiam indicar que houve over-training da rede[4].

4.5.5. INTEGRAÇÃO DA REDE

Finalmente com a rede treinada e avaliada, ela pode ser integrada em um sistema do ambiente operacional da aplicação. Além disso, o sistema deve periodicamente monitorar sua performance e fazer a manutenção da rede quando for necessário ou indicar a necessidade de re-treinamento[4].

Maiores detalhes podem ser encontrados no Anexo 1, com um passo a passo para a montagem, treinamento e teste de uma rede no NeuroSolutions.

4.6. APLICAÇÕES DE REDES NEURAI ADAPTATIVAS

As aplicações das redes neurais são inúmeras. A primeira introdução pode ser vista em prognósticos de mercados financeiros. Grupos de investimento conhecidos utilizam redes neurais para analisar parte do mercado financeiro e fazer suas seleções. Outras aplicações bem sucedidas das técnicas de redes neurais artificiais são: controle de processos industriais, aplicações climáticas, e identificação de fraude de cartões de crédito. Um caso famoso foi o Mellon Bank que instalou um sistema de detecção de fraudes de cartão de crédito implementado com técnicas de rede neurais e os prejuízos evitados pelo novo sistema conseguiu cobrir os gastos de instalação em seis meses. Vários outros bancos começaram a utilizar sistemas baseados em redes neurais para controlar fraudes de cartão de crédito. Estes sistemas tem a capacidade de reconhecer uso fraudulento com base nos padrões criados no passado com uma precisão melhor que em outros sistemas[4].

Outro exemplo de utilização de redes neurais para melhoria na tomada de decisões é no diagnóstico médico. Em um aprendizado, são submetidos uma série de diagnósticos de pacientes, de várias características, com vários sintomas e os resultados de seus testes. Também serão fornecidos os diagnósticos médicos para cada doença. Então quando forem apresentados os dados de um novo paciente,

com seus sintomas, a rede fornecerá um diagnostico para os novos casos. Isto essencialmente criará um sistema com o conhecimento de vários médicos e fornecerá um diagnostico inicial em tempo real a um médico. É importante mencionar que com isso o que se pretende é implantar uma ferramenta de auxilio ao médico, e não um programa que o substitua[4].

Outras aplicações[4]:

- análise e processamento de sinais;
- controle de processos;
- robótica;
- classificação de dados;
- reconhecimento de padrões em linhas de montagem;
- filtros contra ruídos eletrônicos;
- análise de imagens;
- análise de voz;
- avaliação de crédito;
- análise de aroma e odor

4.7 PROGRAMAS DISPONÍVEIS / UTILIZADOS

- Neuroimitador V3.1 para Windows 3.1 da Neuroma-RD Ltd: Ferramenta que permite á pesquisadores construir uma arquitetura arbitraria de rede neural e decidir parâmetros de neurônios envolvidos e conexões sinápticas.
- NeuroSolutions V5.0: Um ambiente de simulação orientado a objeto para redes neurais para estudos de sistemas distribuídos complexos difíceis de serem estudados apenas na teoria. Suas ferramentas de visualização permitem que o usuário verifique o comportamento da rede sem que seja necessário esperar até o fim de seu treinamento, alem de permitir que parâmetros sejam alterados durante a execução da mesma.

- Matlab V4.0.6: Uma ferramenta que utiliza a interface gráfica para construir, desenhar, visualizar, implementar e simular uma rede neural[5].
- Statistica: Ferramenta poderosa cuja principal função é a seleção do INTELLIGENT PROBLEM SOLVERS, que usando métodos de inteligência artificial, permite resolução de problemas com altíssimo grau de exigência, envolvidos m análise avançadas de Redes neurais, tais como selecionar a melhor arquitetura de redes, melhor subconjunto de variáveis, etc[6].

No caso, utilizou-se o programa NeuroSolutions, para desenvolver a rede neural adaptativa (NAP) utilizada.

5. APRESENTAÇÃO DAS PARTES DE UMA RNA [7]

Neste capítulo serão apresentadas as partes que formam uma RNA. Essas partes foram divididas em arquitetura, função de transferência e método de aprendizado.

Cada camada da rede possui camadas intermediárias. Essas camadas requerem uma função não linear para especificar o comportamento das camadas intermediárias. Cada camada ainda necessita de métodos de aprendizado. Assim, de acordo com as funções e métodos selecionados, são definidos os pesos de cada relação, que são continuamente mudados e corrigidos a cada treino.

Essa relação entre a arquitetura da rede, o método de aprendizado e a função de transferência é que define a velocidade de aprendizado da RNA. Se a taxa de aprendizado é muito pequena, o aprendizado demora muito tempo. Por outro lado, se o aprendizado é muito rápido os valores podem divergir

5.1 ARQUITETURA

As arquiteturas das redes serão apresentadas resumidamente, com destaque para suas vantagens e desvantagens e seu formato. Serão usados a função de transferência TanhAxon e o método de aprendizado Momentum, que são o padrão do programa.

5.1.1 MULTILAYER PERCEPTRON (MLP)

Podemos observar em destaque na figura 5.1, posições de entrada, a camada intermediária e a saída, mostrando uma configuração de uma rede linear. Também

estão em destaque a função de transferência (TanhAxon) e o método de aprendizado (Momentum), que serão melhor explicados após a apresentação das arquiteturas.




Figura 5.1 – Arquitetura da rede Multilayer Perceptron

A rede Multilayer Perceptron (MLP) utiliza mecanismo de feedforward, treinada com retropropagação (backpropagation). As principais vantagens dessa arquitetura é ser fácil de usar e poder ser usada para qualquer tipo de dados de entrada e saída. As desvantagens são a baixa velocidade de treinamento e a necessidade de um número maior de treinos.

5.1.2 GENERALIZED FEED FORWARD




Figura 5.2 – Arquitetura de rede Generalized Feed Forward

A Rede Generalized Feed Forward é uma generalização da rede MLP, com a diferença que as conexões podem pular uma ou mais camadas intermediárias. É esperado que essa rede resolva os problemas com maior eficiência, comparada à rede MLP.

5.1.3 MODULAR NEURAL NETWORK




Figura 5.3 – Arquitetura da rede Modular Neural

Podemos ver, em destaque na figura 5.3, que a arquitetura da rede Modular apresenta duas camadas intermediárias como padrão. Essa rede é um tipo especial da Multilayer Perceptron. O processamento é feito usando redes MLP em paralelo e recombina o resultado. Na teoria é esperado um aprendizado mais rápido, reduzindo o tempo e o número de treinos necessários.

5.1.4 JORDAN / ELMAN NETWORK




Figura 5.4 – Arquitetura da rede Jordan/Elman Network

A rede Jordan e Elman é mais uma evolução da Multilayer Perceptron, realimentando o sistema com mais de uma informação. A Elman Network (em destaque na figura 5.4) envia a informação da primeira camada intermediária para a entrada da rede, enquanto a Jordan Network envia os dados de saída, alimentando a rede com dados intermediários e de saída ao mesmo tempo.

5.1.5 PRINCIPAL COMPONENT ANALYSIS (PCA)




Figura 5.5 – Arquitetura da rede PCA

A rede PCA consiste em uma análise prévia, achando dados sem relação nos valores de entrada (em destaque na figura 5.5), repassando os dados de entrada previamente tratados para uma rede MLP.

5.1.6 RBF/GRNN/PNN NETWORK




Figura 5.6 – Arquitetura da rede RBF

A rede RBF (Radial Basis Function) é uma rede não linear que contém tipicamente apenas uma camada intermediária e usa funções de transferência gaussianas ao invés das funções sigmoidais padrão. É uma rede que, na teoria, deve aprender muito mais rápido que uma rede MLP. Essa rede deve ser usada quando há um número muito pequeno de dados, com menos de 100 exemplares. Como nesse trabalho foram usados mais de 100 exemplares essa rede não foi utilizada.

5.1.7 SELF ORGANIZING FEATURE MAP NETWORK




Figura 5.7 – Arquitetura da rede Self Organizing Feature Map

Assim como na rede PCA, a Self Organizing Feature Map Network (em destaque na figura 5.7) faz um tratamento prévio dos dados de entrada para em seguida alimentar uma rede MLP. Esse tratamento consiste em transformar os dados de entrada em matrizes, reduzindo a dimensão dos dados de entrada.

5.1.8 TIME-LAG RECURRENT NETWORK (TLRN)




Figura 5.8 – Arquitetura da rede Time-Lag Recurrent

A TLRN é uma rede do tipo MLP com a diferença que essa rede guarda os dados que estão sendo realimentados na entrada (em destaque na figura 5.8) e analisa como esses dados mudam com o tempo.

5.1.9 RECURRENT NETWORK




Figura 5.9 – Arquitetura da rede Recurrent

A Recurrent Network re-alimenta os dados da camada intermediária nela mesma, funcionando como uma memória entre os processamentos, comparando os dados anteriores com os instantâneos.

5.1.10 CANFIS NETWORK (FUZZY LOGIC)




Figura 5.10 – Arquitetura da rede CANFIS

A rede CANFIS (Co-Active Neuro-Fuzzy Inference System) é a união de uma rede de lógica difusa (Fuzzy Logic) com uma rede modular, com o objetivo de aproximar rapidamente e com precisão funções complexas.

5.1.11 SUPPORT VECTOR MACHINE (SVM)




Figura 5.11 – Arquitetura da rede Support Vector Machine

A rede SVM trabalha criando um espaço dimensional e separando os dados por classes nesses espaços, isolando as entradas perto dos limites superiores e inferiores. A SVM não utiliza as funções de transferência e os métodos de

aprendizado. Essa rede não pode ser usada para aproximações de função e não será utilizada neste trabalho.

5.2 FUNÇÕES DE TRANSFERÊNCIA

Essa parte do trabalho vai explicar as diferentes funções de transferência presentes no NeuroSolutions. As funções estão identificadas por ícones, que serão mostrados a seguir.

5.2.1 AXON



Figura 5.12 – Ícone Axon

A função Axon simplesmente faz a ligação entre a entrada e a saída de dados. É o primeiro membro da família Axon e as funções subseqüentes são as subclasses dessa função.

Cada subclasse terá um ícone (como o da figura 5.12) com um gráfico para sua identificação na rede.

5.2.2 BIAS AXON



Figura 5.13 – Ícone Bias Axon

A Bias Axon é uma função que analisa a tendência dos valores, dando como dados de saída os valores para os quais os dados de entrada estão se encaminhado.

5.2.3 LINEAR AXON



Figura 5.14 – Ícone Linear Axon

A Linear Axon implementa uma função linear e usa o gradiente dessa função para gerar o resultado.

5.2.4 SIGMOID AXON




Figura 5.15 – Ícone Sigmoid Axon

Essa função é aplicada em cada neurônio da camada, levando em conta proporções entre os dados de entrada e saída e a tendência dos dados. Essas proporções e tendências provêm da Linear Axon. Os valores para cada neurônio da camada variam entre zero e um.

5.2.5 LINEAR SIGMOID AXON




Figura 5.16 – Ícone Linear Sigmoid Axon

A Linear Sigmoid Axon substitui a parte intermediária da Sigmoid Axon por uma aproximação linear. Mas essa função pode ser descontínua, só conseguindo aprender quando é usada com a Back Sigmoid Axon. Por esse motivo essa função de transferência não será utilizada neste trabalho.

5.2.6 TANH AXON




Figura 5.17 – Ícone Tah Axon

A TanhAxon funciona aplicando uma função de tendência e outra de Tangente Hiperbólica em cada neurônio da camada. Com isso o valor do peso de cada neurônio na camada aumenta, variando entre -1 e 1.

5.2.7 LINEAR TANH AXON




Figura 5.18 – Ícone Linear Tanh Axon

Assim como a LinearSigmoidAxon essa função substitui a parte intermediária da tangente hiperbólica por uma função linear. É uma função que também não é indicada para aprendizado, necessitando do uso da BackTanhAxon para poder aprender. Portanto essa função não será utilizada.

5.2.8 SOFT MAX AXON



Figura 5.19 – Ícone Soft Max Axon

É uma função que interpreta os dados de saída como uma probabilidade, usando em seguida uma função de densidade de probabilidade para selecionar os melhores valores.

5.3 MÉTODOS DE APRENDIZADO

Assim como feito para as funções de transferência, serão mostrados os métodos de aprendizado disponíveis no NeuroSolutions.

5.3.1 CONJUGATE GRADIENT

O Conjugate Gradient é um método de segunda ordem, ou seja, usa a segunda derivada da curva que relaciona os pesos com os erros, achando o ponto de mínimo da curva (matriz Hessiana), tendendo a uma convergência muito mais rápida. O problema é que cada passo dado por esse algoritmo exige muito do computador e caso não exista uma concavidade com mínimo, da curva pesos x erro, o algoritmo pode divergir.

5.3.2 LEVENBERG MARQUARDT (LM)

O método LM é chamado método de pseudo segunda ordem pois aproxima a matriz Hessiana, utilizando uma aproximação de Gauss-Newton, que mantém a matriz Jacobiana e descarta as derivadas de segunda ordem do erro. A principal vantagem em relação às funções de segunda ordem é que mesmo que a curvatura não seja parabólica ocorre uma aproximação.

5.3.3 STEP

O método Step procura o ponto de mínimo de acordo com a informação do gradiente da curva, dando passos com valores pré-definidos em direção ao lado decrescente da curva pesos x erro. O problema é o pequeno tamanho dos passos, demorando muito para atingir boa precisão. Caso o passo pré-definido seja muito grande pode ocorrer divergência.

5.3.4 DELTA BAR DELTA

Este algoritmo é uma melhoria do Step. O método analisa os pesos e erros das camadas intermediárias, se os pesos correntes e passados tem o mesmo sinal (positivo ou negativo) o algoritmo segue no mesmo sentido, aumentando o tamanho do passo linearmente. Caso sejam encontrados sinais opostos o método toma o caminho contrário, diminuindo o tamanho do passo para não ocorrer divergência.

5.3.5 MOMENTUM

O método se comporta como o Step, seguindo no caminho onde o gradiente da curva pesos x erro decresce, mas agora com um fator de inércia p . Quanto maior o valor de p , menos a mudança no valor do gradiente afeta a mudança nos pesos. O maior benefício é a habilidade de frear o algoritmo no local de mínimo.

5.3.6 QUICKPROP

É um algoritmo que usa o gradiente e a derivada de segunda ordem em conjunto para acelerar a convergência.

6. APLICAÇÃO DAS REDES NEURAIS ADAPTATIVAS

Com as informações do Anexo 1, sobre como montar uma rede no NeuroSolutions e conhecendo as arquiteturas, funções de transferência e métodos de aprendizado disponíveis, foram aplicadas diferentes redes para os dados da tabela do anexo 2, do aço inoxidável 304. Comparando os valores de r encontrados e o formato dos gráficos, foram selecionadas as configurações que obtiveram os melhores resultados. As configurações que obtiveram resultados ruins foram descartadas.

Não foram utilizados os dados das inclinações das retas tangentes das curvas tensão x deformação no momento. Esse dado será usado posteriormente para comparação com os dados da literatura.

6.1 APLICAÇÃO MULTILAYER PERCEPTRON

Começamos os testes com a rede Multilayer Perceptron, que é a rede padrão do programa NeuroSolutions, mantendo o número de sub-camadas igual a um e 1000 ciclos de treinos (também valores padrão). Esses valores são os mesmos para todas as redes testadas nessa primeira fase. Foram alterados as funções de transferência e os métodos de aprendizado buscando o melhor resultado de r e dos gráficos.

Os resultados de r seguem na tabela 6.1.

Tabela 6.1 – Valor de r para a rede Multilayer Perceptron

Transfer\Learnig	Step	Momentum	ConjugateGradient
TanhAxon	0,605118247	0,562501571	0,534459768
SigmoidAxon	0,566110516	-0,53244766	-0,012527556
SoftMaxAxon	2,7153E-16	2,7153E-16	2,7153E-16
BiasAxon	0,599069633	-0,71717363	0,75093956
LinearAxon	0,715773325	0,648142832	
Axon	-0,44214352	0,742913629	
Transfer\Learnig	LevenbergMaquardt	Quickprop	DeltaBarDelta
TanhAxon	0,561627286	0,60724158	0,592986509
SigmoidAxon	0,575167524		
SoftMaxAxon	2,7153E-16		
BiasAxon	-0,029705911	0,68002135	0,579530515
LinearAxon		0,61910212	0,258017638
Axon		0,75375664	

Analisando os gráficos foi visto que algumas funções de transferência não se comportavam da maneira esperada, gerando um gráfico praticamente linear. Como pode ser visto nos gráficos a seguir.

Desired Output and Actual Network Output




Gráfico 6.1 – Resultado Sigmoid Axion / Step

Desired Output and Actual Network Output




Gráfico 6.2 – Resultado Sigmoid Axon / Momentum

Vemos nos gráficos 6.1 e 6.2 que a função de transferência Sigmoid Axon não consegue boa aproximação para os dados da tabela, portanto será descartada.




Gráfico 6.3 – Resultado Soft Max Axon / Momentum

A função Soft Max Axon também não se comportou de maneira adequada, como pode ser visto no gráfico 6.3, e foi descartada.




Gráfico 6.4 – Resultado Linear Axon / Momentum

Mais uma função, a Linear Axon, foi descartada, devido à diferença do gráfico com valores reais e o simulado, observado no gráfico 6.4.

Desired Output and Actual Network Output




Gráfico 6.5 – Resultado Axon / Step

E por último a função Axon, que também não vai seguir sendo testada por apresentar um gráfico, 6.5, que não corresponde á realidade.

O tipo de gráfico esperado para essas configurações é como o do gráfico 6.6.

Desired Output and Actual Network Output




Gráfico 6.6 – Tanh Axon / Momentum

Também ocorreram problemas com os métodos de aprendizado ConjugateGradient e Levenberg Marquardt, como visto nos gráficos 6.7 e 6.8.

Desired Output and Actual Network Output




Gráfico 6.7 – Resultado Conjugate Gradient / Step

Desired Output and Actual Network Output




Gráfico 6.8 – Resultado Levenberg Marquardt / Momentum

Assim foram descartadas essas quatro funções de transferência e os dois métodos de aprendizado.

6.2 APLICAÇÃO GENERALIZED FEED FORWARD

Seguindo a seqüência das redes, foi testada a rede Generalized Feed Forward, seguindo os mesmos métodos da rede anterior. Os resultados obtidos foram os da tabela 6.2.

Tabela 6.2 – Valor de r para Generalized Feed Forward

Transfer\Learnig	Step	Momentum	Quickprop	DeltaBarDelta
TanhAxon	0,759442536	0,5661899	0,732272923	0,563611338
BiasAxon	0,701757268	0,736694824	0,717351913	-0,186387744

As funções de transferência e os métodos de aprendizado apresentaram resultados próximos para esse tipo de rede neural. Há apenas um valor muito baixo da função BiasAxon, para o método DeltaBarDelta, mas como a aproximação para a função TanhAxon foi melhor, esse método será mantido para os próximos testes.

Como os gráficos seguiram o padrão desejado, não foi excluída nenhuma configuração.

6.3 APLICAÇÃO MODULAR NEURAL NETWORK.

A terceira rede testada foi a Modular Neural Network. Com ela foram obtidos os resultados da tabela 6.3.

Tabela 6.3 – Valor de r para Modular Neural

Transfer\Learnig	Step	Momentum	Quickprop	DeltaBarDelta
TanhAxon	0,75757466	0,67026208	-0,73940667	0,571970927
BiasAxon	-0,64487333	-0,44555012	0,12749812	-0,09264112

Houve grandes variações do valor de r e nos gráficos e essa arquitetura não forneceu um retorno confiável para a avaliação das funções de transferência e métodos de aprendizado, portanto não foram eliminadas nenhuma função e nenhum método.

Como alguns valores de r foram mais altos, comparados às redes testadas até agora, essa arquitetura será testada mais adiante com o uso da inclinação da reta tangente.

6.4 APLICAÇÃO JORDAN / ELMAN NETWORK

Como mostra a tabela 6.4, foram encontrados valores baixos de r para os métodos Step e Quickprop.

Tabela 6.4 – Valor de r para Jordan / Elman

Transfer\Learnig	Step	Momentum	Quickprop	DeltaBarDelta
TanhAxon	0,124256097	0,587677202	0,18310615	0,575744178
BiasAxon	0,300254745	-0,03545832	0,25358068	0,243095555

Além do baixo valor de r, os gráficos gerados para esses métodos fugiram dos valores reais, como pode ser visto, por exemplo, no gráfico 6.9.

Desired Output and Actual Network Output




Gráfico 6.9 – Resultado Tanh Axon / Quickprop

Por esse motivo, os métodos de aprendizado Step e Quickprop foram eliminados, seguindo apenas os métodos Momentum e DeltaBarDelta como os de melhor aproximação até o momento.

Como sobraram apenas dois métodos e duas funções, eles serão testados até o fim para todas as arquiteturas, supondo que esses são as melhores configurações para as redes. Se mesmo com essas configurações a arquitetura apresentar valores ruins, ela será descartada.

6.5 APLICAÇÃO PRINCIPAL COMPONENT ANALYSIS (PCA)

A rede PCA apresentou valores de r muito próximos, apenas o valor da função Tanh Axon, (tabela 6.5) com o método Delta Bar Delta, foi ruim. Mas como foi só esse valor que divergiu dos demais, a arquitetura será mantida.

Tabela 6.5 – Valor de r para PCA

Transfer\Learnig	Momentum	DeltaBarDelta
TanhAxon	0,583176255	-0,120043772
BiasAxon	0,459626625	0,583871884

6.6 APLICAÇÃO SELF ORGANIZING FEATURE MAP NETWORK

Essa arquitetura teve fraco desempenho com o método Delta Bar Delta, mas como o método Momentum apresentou valores razoáveis (tabela 6.6), a rede será mantida.

Tabela 6.6 – Valor de r para Self Organizing

Transfer\Learnig	Momentum	DeltaBarDelta
TanhAxon	0,49948612	0,174983307
BiasAxon	0,46385339	0,185425594

6.7 APLICAÇÃO TIME-LAG RECURRENT NETWORK

Como pode ser visto na tabela 6.7, os resultados dessa arquitetura foram péssimos para todas as configurações. Portanto essa arquitetura está descartada.

Tabela 6.7 – Valor de r para Time Lag Recurrent

Transfer\Learnig	Momentum	DeltaBarDelta
TanhAxon	-0,43424666	-0,146067458
BiasAxon	-0,40140293	-0,407630446

6.8 APLICAÇÃO RECURRENT NETWORK

Assim como a Self Organizing Feature Map, essa arquitetura apresentou valores ruins de r para o método Delta Bar Delta, mas valores razoáveis para o método Momentum e pelos mesmos motivos será mantida.

Tabela 6.8 – Valor de r para Recurrenet Network

Transfer\Learnig	Momentum	DeltaBarDelta
TanhAxon	0,55793591	0,132540479
BiasAxon	0,49547521	-0,177640552

6.9 APLICAÇÃO CANFIS NETWORK (FUZZY LOGIC)

Todas as configurações dessa arquitetura apresentaram resultados razoáveis de r, portanto a arquitetura foi mantida.

Tabela 6.9 – Valor de r para CANFIS

Transfer\Learnig	Momentum	DeltaBarDelta
TanhAxon	0,573249865	0,558275412
BiasAxon	0,529059686	0,437228657

6.10 CONCLUSÕES PARCIAIS

Com os resultados de todas as redes encontrados e discutidos, foram definidas as melhores funções de transferência TanhAxon e BiasAxon e os melhores métodos de aprendizado Momentum e DeltaBarDelta, que serão as únicas utilizadas para as próximas aplicações com diferentes dados.

Como observado, a arquitetura Time-Lag Recurrent Network (tabela 6.7) não apresentou resultado satisfatório e não será mais utilizada daqui em diante, seguindo as outras oito redes para melhor análise com outros dados.

7. USO DA INCLINAÇÃO DA RETA TANGENTE NOS DADOS DE ENTRADA.

Como visto na literatura[1][2], o uso da inclinação da reta tangente como dado de entrada melhora a precisão da rede neural adaptativa e aumenta a velocidade de seu aprendizado.

Para comprovar esse estudo, vamos utilizar as configurações que não foram descartadas no capítulo 6 e aplicá-las nos dados da tabela do anexo 2, mas agora utilizando a informação da inclinação da reta tangente.

7.1 MÉTODO PARA OBTER A INCLINAÇÃO DA RETA.

A inclinação da reta foi obtida traçando uma reta tangente ao ponto desejado e a partir de um ponto da reta tangente calcular a variação de altura da reta em função da distância, dividindo H por C , como indicado na figura 7.1.




Figura 7.1 – inclinação positiva.

Os valores da inclinação da reta podem ser negativos, caso a reta tangente seja decrescente, como mostra a figura 7.2.




Figura 7.2 – inclinação negativa

7.2 NOVA APLICAÇÃO DAS REDES NEURAIIS ADAPTATIVAS

Possuindo os valores das inclinações das retas tangentes em mãos (valores que podem ser encontrados na tabela do anexo 3), prosseguimos com as simulações feitas pelas redes neurais selecionadas no capítulo 6, mantendo o mesmo padrão nas aplicações.

O resultado das aplicações pode ser visto na tabela 7.1, que compara os dados de r obtidos com as redes utilizando a inclinação da reta tangente e sem a inclinação da reta tangente. Observamos claramente uma grande melhora na precisão em quase todas as configurações com o uso da inclinação da reta tangente.

Tabela 7.1 – Comparação de r com e sem o uso da inclinação da reta tangente

Rede		Tanh/Momentum	Tanh/DBD	Bias/Momentum	Bias/DBD
Multilayer Perceptron	Sem Reta Tg	0,562501571	0,592986509	-0,717173627	0,579530515
	Com Reta Tg	0,929575688	0,945662693	0,682830521	0,660439491
Generalized Feed Forward	Sem Reta Tg	0,5661899	0,563611338	0,736694824	-0,186387744
	Com Reta Tg	0,906057722	0,927030112	0,664396123	0,660332035
Modular Neural	Sem Reta Tg	0,670262075	0,571970927	-0,44555012	-0,09264112
	Com Reta Tg	0,903624244	0,945662693	0,682830521	0,660439491
Jordan/Elman Network	Sem Reta Tg	0,587677202	0,575744178	-0,035458315	0,243095555
	Com Reta Tg	0,929159917	0,923094673	0,676014516	0,695501072
PCA	Sem Reta Tg	0,583176255	-0,120043772	0,459626625	0,583871884
	Com Reta Tg	0,965950684	0,957610103	0,739488449	0,700991911
S-Organizing Feature Map	Sem Reta Tg	0,49948612	0,174983307	0,463853386	0,185425594
	Com Reta Tg	0,847542596	0,669932024	0,643617929	0,591718797
Recurrent Network	Sem Reta Tg	0,557935907	0,132540479	0,495475214	-0,177640552
	Com Reta Tg	0,85681319	0,159513988	0,545610276	0,654645401
Canfis Network	Sem Reta Tg	0,573249865	0,558275412	0,529059686	0,437228657
	Com Reta Tg	0,937704179	0,892392023	0,959437268	0,736663719

Também é possível observar uma grande vantagem da função TanhAxon sobre a BiasAxon. Por esse motivo Seguiremos daqui em diante utilizando apenas a função TanhAxon.

Prosseguindo com a busca pela melhor configuração de rede, foi observado que a maioria das configurações conseguiu um valor de r maior que 0,9, então, para selecionar as redes mais precisas, foram eliminadas as redes com r menor que 0,9 para a função TanhAxon. Com isso as redes Self-Organizing Feature Map e Recurrent Network não serão mais utilizadas.

7.3 CONCLUSÕES PARCIAIS

Foi comprovado, como observado na tabela 7.1, que o uso da inclinação da reta tangente gera um ganho significativo na precisão da rede neural adaptativa, acompanhando os resultados obtidos pela literatura.

A função de transferência Tanh Axon apresentou os melhores resultados para os dados utilizados e, portanto, segue como a única função não descartada e será utilizada para as próximas aplicações.

Ainda serão definidos o melhor método de aprendizado e a melhor arquitetura, com os dados obtidos nas aplicações do próximo capítulo.

8. APLICAÇÃO DAS REDES NEURAIIS PARA AÇO CARBONO

A literatura mostra que as redes neurais adaptativas podem ser utilizadas para vários tipos de simulações, portanto vamos aplicar as configurações selecionadas até o momento para outro tipo de aço, conformado a uma diferente taxa de deformação e diferentes temperaturas (dados na tabela do anexo 3).

Com os resultados que serão obtidos, será feita uma nova seleção entre as configurações até que seja encontrada a rede que obtenha a melhor precisão. Também objetivamos confirmar os dados da literatura e mostrar que a rede encontrada pode ser usada para diferentes materiais.

Como foi provado no capítulo 7, que o uso da inclinação da reta tangente melhora significativamente a precisão da rede, nas futuras aplicações serão sempre utilizados os valores da inclinação da reta tangente.

8.1 APLICAÇÃO DAS REDES NEURAIIS PARA O AÇO CARBONO AUSTENÍTICO

As configurações restantes do capítulo 7 foram aplicadas aos dados do anexo 3, mantendo sempre os mesmos padrões já utilizados.

Os resultados obtidos estão na tabela 8.1, comparados com os valores de r encontrados para o Aço Inoxidável 304.

Tabela 8.1 – Comparação dos valores de r para diferentes aços.

Rede		Tanh/Momentum	Tanh/DeltaBarDelta
Multilayer	Aço Carb	0,967617213	0,970172613
Perceptron	Aço Inox 304	0,929575688	0,945662693
Generalized	Aço Carb	0,897321815	0,949836669
Feed Foward	Aço Inox 304	0,906057722	0,927030112
Modular	Aço Carb	0,866119469	0,975686977
Neural	Aço Inox 304	0,903624244	0,945662693
Jordan/Elman	Aço Carb	0,884550454	0,962028686
Network	Aço Inox 304	0,929159917	0,923094673
PCA	Aço Carb	0,400018596	0,867303395
	Aço Inox 304	0,965950684	0,957610103
Canfis	Aço Carb	0,85565417	0,86073923
Network	Aço Inox 304	0,937704179	0,892392023

Os resultados da tabela 8.1 mostram alguma vantagem para o método de aprendizado Delta Bar Delta, em relação ao Momentum, então esse será o método utilizado daqui em diante, descartando o método Momentum.

Com o método de aprendizado e a função de transferência já definidos, falta ainda definir a arquitetura da rede. Para prosseguir com a melhoria na precisão, foram eliminadas as arquiteturas que apresentaram valor de r menor que 0,9 em algum (ou em ambos) dos aços (Inoxidável 304 ou Carbono) levando em conta apenas o método Delta Bar Delta já selecionado. Com isso as arquiteturas PCA e Canfis Network estão descartadas.

8.2 CONCLUSÕES PARCIAIS

Pôde ser observado nesse capítulo que as redes que melhor se adaptaram aos dados do aço inoxidável 304 também obtiveram bom desempenho para o aço carbono austenítico, mostrando que a rede pode ser utilizada para diferentes materiais e com diferentes variáveis como taxa de deformação e temperatura, como podemos observar na tabela 8.2, que mostra os melhores valores de r obtidos.

Tabela 8.2 – Melhores valores de r para os diferentes aços

Rede	Aço	Tanh/DeltaBarDelta
Multilayer Perceptron	Aço Carb	0,970172613
	Aço Inox 304	0,945662693
Generalized Feed Foward	Aço Carb	0,949836669
	Aço Inox 304	0,927030112
Modular Neural	Aço Carb	0,975686977
	Aço Inox 304	0,945662693
Jordan/Elman Network	Aço Carb	0,962028686
	Aço Inox 304	0,923094673

9. REFINAMENTO DAS REDES

As redes encontradas até agora já possuem uma precisão elevada, mas essa precisão pode ser melhorada, com pequenas mudanças.

O primeiro passo do refinamento da rede é o aumento do número de camadas intermediárias. Nem sempre um maior número de camadas intermediárias resulta em uma rede mais precisa, podendo o aumento de sub-camadas prejudicar o aprendizado da rede. Quanto menor o número de sub-camadas, mais simples é a rede e mais rápida é a simulação.

O segundo passo para o refinamento é o aumento do número de treinos da rede (maximum epochs). Mas também existe um limite para o aprendizado, caso o número de treinos seja excessivo ocorre o overtraining, quando a rede simplesmente memoriza o treino e não faz a generalização do problema, como explicado no capítulo 4.

9.1 REFINAMENTO DA REDE GENERALIZED FEED FOWARD.

Tabela 9.1 – Valores de r em função do refinamento – Generalized Feed Forward

Rede	Aço	Início	2 Camadas Interm	2000 Treinos	3000 Treinos
Generalized	Inox	0,927030112	0,883227749	0,951217382	0,862800742
Feed Foward	Carb.	0,949836669	0,887437259	0,970199575	0,95982803

No início temos o padrão de uma camada intermediária e 1000 treinos. Vemos pela tabela 9.1 que o uso de duas camadas intermediárias piora a precisão da rede. Seguimos então outro caminho para refinar a rede, aumentando o número de treinos para 2000, conseguindo uma melhor precisão. Seguindo com o aumento dos treinos, chegamos a 3000 treinos, mas temos uma piora do valor de r.

Portanto, para esta rede, obtemos o melhor resultado com 1 camada intermediária e 2000 treinos.

9.2 REFINAMENTO DA REDE JORDAN/ELMAN NETWORK

Tabela 9.2 – Valores de r em função do refinamento – Jordan/Elman Network

Rede	Aço	Início	2 Camadas Intern.	3 Camadas Intern.
Jordan/Elman Network	Inox	0,923094673	0,957030506	0,95851534
	Carb.	0,962028686	0,969004571	0,95427263
Rede	Aço	2 Camadas Int. 2000 Treinos	2 Camdas Int. 3000Treinos	2 Sub-cam 4000 treinos
Jordan/Elman Network	Inox	0,951402073	0,97202075	0,97465107
	Carb.	0,985929136	0,98091083	0,98129455

Para esta rede, vemos, pela tabela 9.2, que o uso de duas camadas intermediárias melhora o valor de r, mas que o uso do três camadas intermediárias piora a precisão da rede. Partimos então de duas camadas intermediárias e aumentamos os treinos para 2000, como visto na tabela 9.2, resultando em pequena diminuição de r para o aço inoxidável 304 e bom aumento de r para o aço carbono austenítico. Aumentando o número de treinos para 3000, vimos que a precisão da rede para o aço carbono cai um pouco, mas há bom aumento da precisão do aço 304. Tentamos mais um aumento para 4000 treinos e ocorreu um pequeno aumento de r, mas foi um aumento pequeno, a rede começa a ficar mais lenta com o aumento do número de treinos, portanto não vale a pena o pequeno ganho em precisão para o teste com 5000 treinos.

Essa configuração, então, ficou otimizada com o uso de 2 camadas intermediárias e 4000 treinos.

9.3 REFINAMENTO DA REDE MODULAR NEURAL NETWORK

Tabela 9.3 – Valores de r em função do refinamento – Modular Neural Network

Rede	Aço	Início	3 Camadas Int.	2000 Treinos
Modular Neural	Inox	0,94566269	0,947393777	0,935099
	Carb.	0,97568698	0,945450172	0,977482
Rede	Aço	3000 Treinos	4000 treinos	5000 Treinos
Modular Neural	Inox	0,97200857	0,94265558	0,926367
	Carb.	0,98388801	0,99138345	0,988228

A rede Modular Neural já começa com duas camadas intermediárias como padrão (veja item 5.1.3), então a primeira tentativa de refino foi aumentar esse número de subcamadas para três. Mas houve queda na precisão da rede, como observado pelo valor de r na tabela 9.3. Foi feito então o aumento do número de treinos para as 2 camadas intermediárias padrão. Houve aumento em ambos os aços para 2000, na tabela q, e 3000 treinos, visto na tabela 9.3. Para 4000 e 5000 treinos, a soma da precisão dos aços caiu, principalmente para o aço 304. Portanto a otimização dessa configuração foi obtida com 2 camadas intermediárias (padrão nessa arquitetura) e 3000 treinos.

9.4 REFINAMENTO DA REDE MULTILAYER PERCEPTRON

Tabela 9.4 – Valores de r em função do refinamento – Multilayer Perceptron

Rede	Aço	Início	2 Camadas Int.	3 Camadas Int
Multilayer Perceptron	Inox	0,96496799	0,960748125	0,97968
	Carb.	0,97017261	0,980407086	0,934891
Rede	Aço	2 Camadas Int 2000 Treinos	2 Camadas Int 3000 Treinos	2 Camadas Int. 4000 Treinos
Multilayer Perceptron	Inox	0,97286138	0,991747447	0,933365
	Carb.	0,98843448	0,999214587	0,983135

Para a rede Multilayer Perceptron (veja item 5.1.1) a adição de uma camada intermediária melhorou a precisão geral, mas com três camadas intermediárias a precisão caiu. Ficamos então com duas camadas intermediárias e aumentamos o número de treinos. Podemos ver o aumento do r para 2000 e 3000 treinos, mas com 4000 treinos o valor cai.

Obtemos os maiores valores de r com duas camadas intermediárias e 3000 treinos.

9.5 ESCOLHA DA REDE FINAL

A rede que obteve a melhor precisão foi a Multilayer Perceptron (tabela 9.4), utilizando a configuração de duas camadas intermediárias e 3000 treinos, com a função de transferência Tanh Axon e o método de aprendizado Delta bar Delta.

Essa é a rede que melhor se adaptou aos dados fornecidos, mostrando o valor de r mais próximo de um para ambos os aço. Essa rede pode servir para a simulação de outros aços, mas isso será visto mais adiante.

10. DETALHES DA REDE NEURAL SELECIONADA

Veremos agora detalhes da rede neural escolhida.

10.1 ARQUITETURA DA REDE




Figura 10.1 – Arquitetura da rede refinada - detalhes

As áreas indicadas na figura 10.1 são as funções de transferência e os métodos de aprendizado, a parte de baixo é a função TanhAxon e a parte superior, com as letras D-B-D, é o método de aprendizado DeltaBarDelta.




Figura 10.2 – Arquitetura da rede refinada

E na figura 10.2 acima, vemos, nas áreas selecionadas, a entrada de dados (esquerda), as camadas Intermediárias (centro) e a saída dos dados (direita).

10.2 ANÁLISE DOS RESULTADOS

Avaliando os resultados que a RNA nos proporciona, podemos saber a qualidade da rede, veremos a seguir os resultados.

10.2.1 GRÁFICOS COMPARATIVOS

Esses gráficos comparam os dados de saída da simulação da rede com os reais.




Gráfico 10.1 – Aço Inoxidável 304. $r = 0,991747447$




Gráfico 10.2 – Aço Carbono Austenítico. $r = 0,99214587$

Foi observado um valor elevado de r para ambos os aços, como pode ser conferido nos gráficos 10.1 e 10.2.

10.2.2 TABELAS DE SAÍDA

E temos as tabelas 10.1 e 10.2, com os dados de entrada, os valores previstos e valores reais, para os dois aços utilizados.

Tabela 10.1 – Valores de entrada e saída, Aço Inox. 304

Temp. (°C)	Incl. Reta	Deformação	Tensão (Mpa)	Tensão (Mpa) Output
850	1,954	0,17	205	204,362725
1250	-0,055	1,045	74	73,1768439
800	-0,415	1,898	320	315,732951
950	-0,032	0,886	212	209,00245
800	2,651	0,125	205	210,381372
950	0,252	0,443	204	203,013782
1150	0	0,693	118	120,354576
800	0,739	0,307	285	290,191777
1150	0,325	0,261	108	102,055432
1250	0,741	0,045	57	73,4774561
850	-0,023	1,239	285	289,113033
1150	0,155	0,398	115	111,321253
950	0,639	0,136	153	188,286096
950	0,096	0,591	210	207,081285
950	2,326	0,102	138	117,730663
800	0,082	0,818	325	321,268883
850	-0,133	1,807	275	281,255004
1250	-0,06	0,875	76	75,7312968

Tabela 10.2 – valores de entrada e saída, Aço Carbono Austenítico.

Temp (°C)	Incl	Def	Tensão (Mpa)	Tensão (Mpa) Output
1000	-0,098	2,5	113	111,669479
900	-0,137	1,5	172,7	170,443244
1100	-0,129	1,1	94,2	94,8618932
1100	-0,007	3,5	84,4	83,9660371
1100	0,015	3,1	86,5	84,4055127
900	-0,125	2,49	151,7	151,705569
1100	-0,086	0,91	97,7	95,0984497
1100	-0,129	1,1	94,2	94,8618932
900	-0,086	3,48	141,3	139,931445
1100	-0,007	3,5	84,4	83,9660371
900	-0,129	1,09	177,9	177,309206
800	-0,242	0,9	232	232,853591
1000	-0,098	2,3	113,4	112,939925
1100	-0,051	1,89	88,9	88,8112549
800	-0,171	1,5	221,5	224,830919
1000	-0,047	3,91	104,7	107,186212
800	-0,264	2,9	179,6	183,246785
1000	0,011	2,69	111,6	109,252577
900	-0,031	3,28	141,3	140,676346
800	0	3,89	160,5	158,407945
800	-0,357	2,71	186,6	189,382714
1000	0,425	0,3	120,3	121,959675
1100	0,07	2,68	88,9	84,765847
1000	-0,077	3,1	110,2	108,711851
900	-0,031	3,28	141,3	140,676346

A comparação entre os dados de entrada e saída das tabelas mostra a precisão da rede.

10.2.3 GRÁFICOS DE DISPERSÃO.

Esse tipo de gráfico mostra a precisão da rede para os valores testados

Foram observados os seguintes gráficos.




Gráfico 10.3 - Gráfico de dispersão para o Aço Inox. 304




Gráfico 10.4 – Gráfico de dispersão da literatura[1]

Como podemos ver no gráfico 10.3, os valores tendem a formar uma reta, mostrando grande precisão da rede, conforme foi encontrado no artigo[1] e visto no gráfico 10.4.




Gráfico 10.5 – Gráfico de dispersão do aço carbono austenítico

O artigo [2] não faz um gráfico de dispersão para comparar os valores, apenas é fornecido um valor de r de 0,990. Mas de acordo com o gráfico 10.5 e o valor de r encontrado ($r = 0,999214587$), podemos perceber a grande precisão da rede.

10.2.4 SENSIBILIDADE DOS PARÂMETROS

Obtemos também, através do NeuroSolutions, o quanto cada um dos dados de entrada influencia nos resultados, revelando qual parâmetro tem maior influência sobre a tensão.




Gráfico 10.6 – Sensibilidade – Aço Inox 304.




Gráfico 10.7 – Sensibilidade – Aço Carbono Austenítico.

Podemos concluir com esses gráficos (10.6 e 10.7) a grande importância da temperatura nos valores da tensão e também a importância do uso da inclinação da reta tangente como dado de entrada na RNA, com praticamente a mesma importância da deformação na sensibilidade da rede.

10.2.5 INFLUÊNCIA DA TEMPERATURA

Como foi visto, a temperatura é o parâmetro que mais influencia no valor da tensão, então veremos melhor a sua influência com os gráficos de sensibilidade em relação á temperatura.




Gráfico 10.8 – Sensibilidade da temperatura – Aço Inox 304.




Gráfico 10.9 – Sensibilidade da temperatura – Aço Carbono Austenítico.

Podemos observar que a temperatura tem grande influência no valor da tensão, mas os gráficos 10.8 e 10.9 mostram que essa influência vai diminuindo conforme a temperatura atinge valores mais altos.

É percebido nos gráficos que essa relação não é contínua, como o esperado. Isso ocorre porque os efeitos das outras variáveis se superpõe.

10.3 CONCLUSÕES PARCIAIS

Podemos observar uma grande precisão da rede para as entradas de dados de temperatura, deformação, inclinação da reta e tensão, conforme foi também observado nos artigos usados como base para esse trabalho, conforme foi observado nos gráficos do capítulo.

11. APLICAÇÃO DA RNA COM MAIS PARÂMETROS NA ENTRADA

Com o intuito de saber se essa rede pode dar resultados satisfatórios com a entrada de mais variáveis, foi feita a aplicação dessa RNA nos dados do livro "The Hot Deformation of Austenite", do autor John B. Ballance.

Os dados de entrada podem ser vistos na tabela do anexo 4 e o trecho do livro utilizado está no anexo 7.

A tabela anexa mostra dados dos gráficos de um aço C-Mn, com 0,59%C, 0,64%Mn, 0,35%Si, 0,012%S e 0,009%P, deformado a diferentes temperaturas e a taxas de deformação de 2 e 20mm s⁻¹. As unidades PSI e °F foram passadas para MPa e °C, para manter a relação com os artigos já utilizados.

O parâmetro inserido é a taxa de deformação, que não é mais fixa, sendo de 2mm s⁻¹ e de 20mm s⁻¹. Assim a precisão da rede vai ser testada para um tipo diferente de aço, com diferentes temperaturas, deformações e com diferentes valores de taxa de deformação.

11.1 RESULTADOS DA APLICAÇÃO DA RNA COM O NOVO PARÂMETRO

Os resultados obtidos foram excelentes, com grande precisão da rede, assim como visto para os dados anteriores.

O valor de r foi de 0,998313422. A precisão pode ser observada no gráfico

11.1




Gráfico 11.1 – Valores reais e simulados da RNE, Aço C-Mn, com $r = 0,998313422$

Também analisando o gráfico 11.2, da dispersão, percebe-se o comportamento muito próximo a uma reta, mais uma vez comprovando a qualidade da simulação.




Gráfico 11.2 – Dispersão. Aço C-Mn

12. CONCLUSÃO

O trabalho realizou uma análise detalhada das arquiteturas das redes (capítulo 5), métodos de aprendizado, funções de transferência, camadas intermediárias e número de treinamentos.

Essa análise foi feita de forma gradual, contando com apenas duas variáveis de entrada (temperatura e deformação) no início (capítulo 6), uma camada intermediária e uma saída.

Na sequência foram utilizadas três variáveis de entrada (temperatura, deformação e inclinação da reta tangente), com uma camada intermediária e uma saída, para dois diferentes tipos de materiais (capítulos 7 e 8).

Enfim, houve o refinamento das redes, tratando do número de camadas intermediárias e do número de treinos (capítulo 9), gerando uma arquitetura de rede otimizada (multilayer perceptron), com três variáveis de entrada, duas camadas intermediárias e uma saída, realizando 3000 treinos, utilizando a função de transferência TanhAxon e o método de aprendizado Delta Bar Delta. Essa rede foi então aplicada a um diferente material (capítulo 11), com quatro variáveis de entrada (temperatura, deformação, inclinação da reta tangente e taxa de deformação) com resultados excelentes, comprovando a qualidade da rede desenvolvida como pode ser visto nos valores de r para os 3 diferentes materiais, na tabela 12.1.

Tabela 12.1 – Melhores valores de r para cada aço.

Aço	r
Aço Inoxidável 304	0,991747447
Aço Carbono Austenítico	0,999214587
Aço C-Mn	0,998313422

Conforme observado nos artigos, foi comprovada a importância do uso da inclinação das retas tangentes nos valores de entrada da rede, resultando em um aumento do valor de r , como foi visto na tabela 7.1.

Os resultados obtidos mostram que essa ferramenta deve ser difundida e utilizada em grande escala, nas áreas acadêmicas, científicas e industriais, pois pode proporcionar ganhos na velocidade de desenvolvimento de novos projetos e grande economia gerada com a substituição parcial de testes práticos por simulações.

13. SUGESTÃO

Fica a sugestão da aplicação do presente trabalho para outras ligas metálicas, ferrosas e não ferrosas, bem como outros materiais não metálicos.

REFERÊNCIAS

- [1] HODGSON, P.D; KONG, L.X.; DAVIES, C.H.J. Journal of Materials Processing Technology 87, 1999, p. 131-138
- [2] HODGSON, P.D.; KONG, L.X.; COLLINSON, D.C Journal of Materials Processing Technology 102, 2000, p. 84-89
- [3] URABAYASHI, E.J. **Desenvolvimento de uma rede neural artificial para a previsão do comportamento constitutivo de uma liga de alumínio AFNOR 7020.** São Paulo, 2005.
- [4] Uma introdução às Redes Neurais. Disponível em
<<http://www.din.uem.br/ia/neurais>> Acesso em 09 nov 2008
- [5] Business Intelligence. Disponível em
<http://www.fenas.com.br/produtos_statistica.htm> Acesso em 09 nov. 2008
- [6] Neural Network Toolbox for Matlab. Disponível em
<<http://www.mathworks.com/products/neuralnet/>> Acesso em 09 nov. 2008
- [7] NeuroSolutions Help. Disponível em
<<http://www.neurosolutions.com/downloads/documentation.html>> Acesso em 11 nov. 2008.
- [8] BALLANCE, J.B. **The hot deformation of autenite.** New York: Metallurgical Society, AIME, 1977, p. 47-67
- [9] Estatística Multivariada. Disponível em
<http://www.criticanarede.com/cien_estatistica.html> Acesso em 09 nov. 2008.
- [10] O Que São as Redes Neurais Artificiais. Disponível em
<<http://www.cerebromente.org.br/n05/tecnologia/rna.htm>> Acesso em 11 nov 2008.
- [11] Redes Neurais Artificiais. Disponível em
<http://www.icmc.usp.br/~andre/researche/neural/index.htm>> Acesso em 11 nov 2008.

ANEXO 1

I. UTILIZAÇÃO DO NEUROSOLUTIONS

Esse anexo vai abordar a utilização do programa NeuroSolutions através de um exemplo prático de um aço inoxidável 304, mostrando todas as etapas para a montagem de uma rede neural.


I.a SELEÇÃO DE DADOS

A primeira etapa da utilização do NeuroSolutions é classificação dos dados. A tabela de dados deve ser inserida sem pular linhas ou colunas, como na figura abaixo.



	A	B	C	D	E	F
1	Temp	Tensão	Incl Reta	Deformação		
2	800	232	-0,242	0,9		
3	800	238,9	-0,178	0,71		
4	1100	89,2	-0,062	1,68		
5	1000	116,1	-0,116	1,91		
6	800	204,1	-0,278	2,31		
7	800	163,9	-0,128	3,5		
8	900	176,2	0,442	0,3		
9	1000	127,3	0,204	0,5		
10	900	148,3	-0,094	2,68		
11	900	155,2	-0,251	2,28		
12	800	240,7	0,05	0,5		
13	1000	104,7	-0,047	3,91		
14	1100	87,2	-0,059	2,49		
15	1000	130,8	-0,086	0,71		
16	1100	87,2	-0,125	2,9		
17	1100	97,7	-0,086	0,91		
18	900	172,7	-0,137	1,5		
19	1100	76,7	1,123	0,11		
20	900	158,7	-0,156	2,08		
21	800	177,9	-0,185	3,09		
22	900	144,8	-0,165	2,88		
23	900	167,4	-0,255	1,68		
24	1000	113	-0,098	2,5		
25	1000	123,8	-0,122	1,09		
26	1100	86,7	-0,043	3,29		
27	900	143	-0,074	3,07		
28	800	235,5	0,783	0,3		
29	1000	108,8	-0,007	3,51		
30	800	191,9	3,615	0,11		
31	900	179,7	-0,074	0,69		
32	900	179,7	-0,047	0,9		

Caso necessário os dados devem ser embaralhados, selecionando todas as linhas, menos a primeira. Clicando no botão do NeuroSolutions no Excel, Preprocess data e Randomize Rows.



Em seguida são selecionados os dados de entrada, no caso a temperatura, a tensão e a inclinação da reta.

Microsoft Excel - Generalized R					
Arquivo Editar Exibir Inserir Formatar Ferramentas					
Input Temp					
	A	B	C	D	E
1	Temp	Tensão	Incl Reta	Deformação	
2	800	232	-0.242	0,9	
3	800	238,9	-0.178	0,71	
4	1100	89,2	-0.062	1,68	
5	1000	116,1	-0.116	1,91	
6	800	204,1	-0.278	2,31	
7	800	163,9	-0.128	3,5	
8	900	176,2	0.442	0,3	
9	1000	127,3	0.204	0,5	
10	900	148,3	-0.094	2,68	
11	900	155,2	-0.251	2,28	
12	800	240,7	0.05	0,5	
13	1000	104,7	-0.047	3,91	
14	1100	87,2	-0.059	2,49	
15	1000	130,8	-0.086	0,71	
16	1100	87,2	-0.125	2,9	
17	1100	97,7	-0.086	0,91	
18	900	172,7	-0.137	1,5	
19	1100	76,7	1.123	0,11	
20	900	158,7	-0.156	2,08	
21	800	177,9	-0.185	3,09	
22	900	144,8	-0.165	2,88	
23	900	167,4	-0.255	1,68	
24	1000	113	-0.098	2,5	
25	1000	123,8	-0.122	1,09	
26	1100	86,7	-0.043	3,29	
27	900	143	-0.074	3,07	
28	800	235,5	0.783	0,3	
29	1000	108,8	-0.007	3,51	
30	800	191,9	3.615	0,11	

Selecionamos então o botão do NeuroSolutions, Tag Data, Column(s) As Input.

The screenshot shows the Microsoft Excel interface with the NeuroSolutions add-in menu open. The menu is displaying the 'Tag Data' option, which has opened a sub-menu. In the sub-menu, 'Column(s) As Input' is selected. The background Excel window shows a data table with columns labeled 'Temp', 'Tensão', 'Incl Reto', and 'Deformação'.

	Temp	Tensão	Incl Reto	Deformação
1	800	232	-0.242	0.9
2	800	238.9	-0.178	0.71
3	1100	89.2	-0.062	1.68
4	1000	116.1	-0.116	1.91
5	800	204.1	-0.278	2.31
6	800	163.9	-0.128	3.5
7	900	176.2	0.442	0.3
8	1000	127.3	0.204	0.5
9	900	148.3	-0.094	2.68
10	800	155.2	-0.251	2.28
11	800	240.7	0.06	0.5
12	1000	104.7	-0.047	3.91
13	1100	87.2	-0.059	2.49
14	1000	130.8	-0.086	0.71
15	1100	87.2	-0.123	2.9
16	1100	97.7	-0.086	0.91
17	900	172.7	-0.137	1.5
18	1100	76.7	1.123	0.11
19	900	156.7	-0.156	2.08
20	800	177.9	-0.185	3.09
21	900	144.8	-0.165	2.88
22	900	167.4	-0.255	1.68
23	1000	113	-0.098	2.5
24	1000	123.8	-0.122	1.09
25	1100	66.7	-0.043	3.29
26	900	143	-0.074	3.07
27	800	235.5	0.783	0.3

NeuroSolutions Menu:

- Preprocess Data
- Analyze Data
- Tag Data
 - Column(s) As Input
 - Column(s) As Desired
 - Column(s) As Symbol
 - Row(s) As Training
 - Row(s) As Cross Validation
 - Row(s) As Testing
 - Row(s) As Production
 - All Columns As Input
 - All Non-Numeric Columns A
 - All Rows As Training
 - Rows By Percentages...
 - Clear Tags...
 - Clear Column Tag
 - Clear Symbol Tag
 - Clear Row Tag
 - Clear All Tags
 - Select Cross-Section...
 - Refresh Tag Formats
 - Run Batch...
- Create/Open Network
- Create Data Files
- Train Network
- Test Network
- Apply Production Dataset
- New Batch...
- Batch Manager
- Goto Active Data Sheet
- Data Sheets...
- Goto Active Report
- Reports...
- Open Active Network
- Help

Agora os dados de saída, no caso a deformação, NeuroSolutions, Tag Data, Column(s) As Desired.

The screenshot shows a Microsoft Excel spreadsheet with the following data:

	A	B	C	D	E	F	G
	Temp	Tensão	Incl Ret	Deformação			
1							
2	800	232	-0.242	0.9			
3	800	238.9	-0.178	0.71			
4	1100	89.2	-0.062	1.68			
5	1000	116.1	-0.116	1.91			
6	800	204.1	-0.278	2.31			
7	800	163.9	-0.128	3.5			
8	900	176.2	0.442	0.3			
9	1000	127.3	0.204	0.5			
10	900	148.3	-0.094	2.68			
11	900	155.2	-0.251	2.28			
12	800	240.7	0.05	0.5			
13	1000	104.7	-0.047	3.91			
14	1100	87.2	-0.059	2.49			
15	1000	130.8	-0.086	0.71			
16	1100	87.2	-0.125	2.9			
17	1100	97.7	-0.086	0.91			
18	900	172.7	-0.137	1.5			
19	1100	76.7	1.123	0.11			
20	900	158.7	-0.156	2.08			
21	800	177.9	-0.185	3.09			
22	900	144.8	-0.165	2.89			
23	900	167.4	-0.255	1.68			
24	1000	113	-0.098	2.5			
25	1000	123.8	-0.122	1.09			
26	1100	86.7	-0.043	3.29			
27	900	143	-0.074	3.07			

The NeuroSolutions menu is open, showing the following options:


- Preprocess Data
- Analyze Data
- Tag Data
- Create/Open Network
- Create Data Files
- Train Network
- Test Network
- Apply Production Dataset
- New Batch...
- Batch Manager
- Goto Active Data Sheet
- Data Sheets...
- Goto Active Report
- Reports...
- Open Active Network
- Help

The 'Tag Data' option is selected, and the 'Column(s) As Desired' option is highlighted in the submenu.

Já temos as colunas, com os dados de entrada e saída, marcadas. Agora precisamos classificar as linhas.

As linhas devem ser divididas na proporção de 70% para treinamento, 15% para validação e 15% para teste.

Marcando as linhas de teste, clicamos em NeuroSolutions, Tag Data, Row(s) As Training.



NeuroSolutions, Tag Data, Row(s) As Cross Validation.

The screenshot shows the NeuroSolutions menu in Microsoft Excel. The 'Tag Data' option is selected, and the 'Row(s) As Cross Validation' sub-option is highlighted. The background shows a data table with columns A through G.

	A	B	C	D	E	F	G
1	Temp. (°C)	Tensão (Mpa)	Incl. Rota	Deformação ϵ			
76	1150	106	-0.041	1,388			
77	950	165	1	0,17			
78	800	330	-0.027	1,477			
79	850	265	-0.34	2,034			
80	850	286	0.041	0,898			
81	1150	118	-0.007	0,76			
82	800	303	0.458	0,432			
83	800	185	3.355	0,104			
84	950	184	-0.233	1,968			
85	950	198	0.321	0,375			
86	1250	70	0.344	0,17			

NeuroSolutions, Tag Data, Row(s) as Testing.

The screenshot shows the NeuroSolutions menu in Microsoft Excel. The 'Tag Data' option is selected, and the 'Row(s) as Testing' sub-option is highlighted. The background shows a data table with columns A through G.


	A	B	C	D	E	F	G
1	Temp. (°C)	Tensão (Mpa)	Incl. Rota	Deformação ϵ			
94	950	202	0.119	1,398			
95	950	177	-0.293	2,091			
96	1250	80	0.078	0,398			
97	1150	118	0.032	0,545			
98	1150	105	-0.072	1,523			
99	850	253	0.738	0,341			
100	950	211	-0.056	1,057			
101	1250	75	0.055	0,932			
102	800	331	-0.018	1,363			
103	850	280	0.156	0,67			
104	800	290	0.679	0,341			
105	850	205	1.954	0,17			
106	1250	74	0.055	1,040			
107	800	320	-0.415	1,638			
108	950	212	-0.032	0,896			
109	800	206	2.851	0,125			
110	950	204	0.252	0,440			
111	1150	118	0	0,993			
112	800	285	0.739	0,307			
113	1150	108	0.025	0,261			
114	1250	57	0.741	0,045			
115	850	285	-0.023	1,239			
116	1150	119	0.155	0,399			
117	950	183	0.639	0,736			
118	950	210	0.096	0,591			
119	950	190	2.326	0,102			
120	800	325	0.082	0,875			

Assim temos todos os dados já classificados. Lembrando que devemos selecionar toda a linha e toda a coluna para fazer a classificação, não apenas as células que possuem os dados.

Com os dados divididos, podemos iniciar a montagem da rede neural.

I.b Montagem da RNA

Novamente clicamos em NeuroSolutions, Create/Open Network, New Custom Network.



Abre-se a janela do NeuralBuilder. Podemos ver no quadro destascado na figura os tipos de redes disponíveis no programa, neste exemplo vamos selecionar a Multilayer Perceptron.

The screenshot shows a Microsoft Excel spreadsheet with the following data:

	A	B	C	D	E	F	G	H	I	J
1	Temp (°C)	Tensão (Mpa)	Incl. Reta	Deformação						
94	950	202	-0,119	1,398						
95	950	177	-0,293	2,091						
96	1250	80	0,078	0,398						
97	1150	118	0,032	0,545						
98	1150	105	-0,072							
99	850	253	0,738							
100	950	211	-0,056							
101	1250	75	-0,055							
102	800	331	-0,018							
103	850	280	0,156							
104	800	290	0,679							
105	850	205	1,954							
106	1250	74	-0,055							
107	800	320	-0,415							
108	950	212	-0,032							
109	800	205	2,651							
110	950	204	0,252							
111	1150	118	0							
112	800	285	0,739							
113	1150	108	0,325							
114	1250	57	0,741							
115	850	285	-0,023							
116	1150	115	0,155							
117	950	153	0,639							
118	950	210	0,096							
119	950	138	2,326							
120	800	325	0,082							
121	850	275	-0,133							

The NeuralBuilder window is open, showing a list of neural network models. The 'Multilayer Perceptron' model is selected. The window also displays a 'Neural Model' section with a welcome message and a 'Help' button.

Em seguida temos a tela informando a quantidade de camadas intermediária ou ocultas (Hidden Layers), destacada na figura. Mantemos apenas uma subcamada.

The screenshot shows a Microsoft Excel window titled "Microsoft Excel - Aço 304" with a menu bar (Arquivo, Editar, Exibir, Inserir, Formatar, Ferramentas, Dados, Janela, Ajuda, NeuroSolutions) and a toolbar. The active sheet is "Testing" with a selected cell at A850. The data table has the following columns: Temp. (°C), Tensão (Mpa), Incl. Rota, and Deformação. The rows are numbered 94 to 121. A dialog box titled "NeuralBuilder" is open, showing the "Multilayer" configuration. The dialog box includes a diagram of a neural network with 3 input nodes, 1 output node, and 1 hidden layer. The configuration fields are: Input PEs: 3, Output PEs: 1, Exemplars: 85, and Hidden Layers: 1. A text box at the bottom of the dialog box provides information about Multilayer perceptrons (MLPs).

	A	B	C	D	E	F	G	H	I	J
	Temp. (°C)	Tensão (Mpa)	Incl. Rota	Deformação						
94	950	202	-0,119	1,398						
95	950	177	-0,293	2,091						
96	1250	80	0,078	0,398						
97	1150	118	0,032	0,545						
98	1150	105	-0,072							
99	850	253	0,738							
100	950	211	-0,056							
101	1250	75	-0,055							
102	800	331	-0,018							
103	850	280	0,156							
104	800	290	0,679							
105	850	205	1,954							
106	1250	74	-0,055							
107	800	320	-0,415							
108	950	212	-0,032							
109	800	205	2,651							
110	950	204	0,252							
111	1150	118	0							
112	800	285	0,739							
113	1150	108	0,325							
114	1250	57	0,741							
115	850	285	-0,023							
116	1150	115	0,155							
117	950	153	0,639							
118	950	210	0,096							
119	950	138	2,326							
120	800	325	0,082							
121	850	275	-0,133							

NeuralBuilder

Multilayer

Input PEs: 3

Output PEs: 1

Exemplars: 85

Hidden Layers: 1

Multilayer perceptrons (MLPs) are layered feedforward networks typically trained with static backpropagation. Here you simply specify the number of hidden layers. These networks have found their way into countless applications requiring static pattern classification. Their main advantages are that they are easy to use, and that they can approximate any input/output map. The key disadvantages are that they train slowly, and require lots of training data (typically three times more training).

Help Close << >>

Na tela seguinte escolhemos o tipo de função de transferência da subcamada. No exemplo ficamos com a Tangente Hiperbólica.

The image shows a Microsoft Excel spreadsheet with data for a neural network simulation. The data is organized into columns: A (Temp. °C), B (Tensão Mpa), C (Incl. Reta), and D (Deformação). The rows are numbered 94 to 121. The NeuralBuilder dialog box is open, showing the configuration for 'Hidden Layer #1'. The 'Processing Elements' are set to 4. The 'Transfer' function is set to 'TanhAxon'. The 'Learning Rule' is set to 'N'. The 'Momentum' is set to 0.700000. The dialog box also includes a 'Help' button and 'Close' and '<<' '>>' navigation buttons.

	A	B	C	D	E	F	G	H	I	J
	Temp. (°C)	Tensão (Mpa)	Incl. Reta	Deformação						
94	950	202	-0.119	1,398						
95	950	177	-0.293	2,091						
96	1250	80	0.078	0,398						
97	1150	118	0.032	0,545						
98	1150	105	-0.072							
99	850	253	0.738							
100	950	211	-0.056							
101	1250	75	-0.055							
102	800	331	-0.018							
103	850	280	0.156							
104	800	290	0.679							
105	850	205	1,954							
106	1250	74	-0.055							
107	800	320	-0.415							
108	950	212	-0.032							
109	800	205	2,651							
110	950	204	0.252							
111	1150	118	0							
112	800	285	0.739							
113	1150	108	0.325							
114	1250	57	0.741							
115	850	285	-0.023							
116	1150	115	0.155							
117	950	153	0.639							
118	950	210	0.096							
119	950	138	2,326							
120	800	325	0.082							
121	850	275	-0.133							

Na mesma tela, logo abaixo temos o método de aprendizado que será utilizado (Learning Rule). Seleccionamos Momentum.

The screenshot shows a Microsoft Excel spreadsheet with data for 'Temp. (°C)', 'Tensão (Mpa)', 'Incl. Reta', and 'Deformação'. The NeuralBuilder dialog box is open, showing the 'Hidden Layer #1' configuration. The 'Learning Rule' dropdown is highlighted, showing options: Momentum, ConjugateGradient, LevenbergMarquardt, Quickprop, and DeltaBarDelta. The 'Momentum' option is selected.

	A	B	C	D	E	F	G	H	I	J
	Temp. (°C)	Tensão (Mpa)	Incl. Reta	Deformação						
94	950	202	-0,119	1,398						
95	950	177	-0,293	2,091						
96	1250	80	0,078	0,398						
97	1150	118	0,032	0,545						
98	1150	105	-0,072	1,398						
99	850	253	0,738	0,398						
100	950	211	-0,056	0,545						
101	1250	75	-0,055	0,398						
102	800	331	-0,018	1,398						
103	850	280	0,156	0,398						
104	800	290	0,679	0,398						
105	850	205	1,954	0,398						
106	1250	74	-0,055	1,398						
107	800	320	-0,415	1,398						
108	950	212	-0,032	0,398						
109	800	205	2,651	0,398						
110	950	204	0,252	0,398						
111	1150	118	0	0,398						
112	800	285	0,739	0,398						
113	1150	108	0,325	0,398						
114	1250	57	0,741	0,398						
115	850	285	-0,023	1,398						
116	1150	115	0,155	0,398						
117	950	153	0,639	0,398						
118	950	210	0,096	0,398						
119	950	138	2,326	0,102						
120	800	325	0,082	0,818						
121	850	275	-0,133	1,807						

Na próxima tela selecionamos as mesmas funções anteriores mas agora para a camada de saída.

Microsoft Excel - Aço 304

Arquivo Editar Exibir Inserir Formatar Ferramentas Dados Janela Ajuda NeuroSolutions

Testing 850

	A	B	C	D	E	F	G	H	I	J
1	Temp. (°C)	Tensão (Mpa)	Incl. Rota	Deformação						
94	950	202	-0.119	1,398						
95	950	177	-0.293	2,091						
96	1250	80	0.078	0,398						
97	1150	118	0.032	0,545						
98	1150	105	-0.072							
99	850	253	0.738							
100	950	211	-0.056							
101	1250	75	-0.055							
102	800	331	-0.018							
103	850	280	0.156							
104	800	290	0.679							
105	850	205	1.954							
106	1250	74	-0.055							
107	800	320	-0.415							
108	950	212	-0.032							
109	800	205	2.651							
110	950	204	0.252							
111	1150	118	0							
112	800	285	0.739							
113	1150	108	0.325							
114	1250	57	0.741							
115	850	285	-0.023							
116	1150	115	0.155							
117	950	153	0.639							
118	950	210	0.096							
119	950	138	2.326	0,102						
120	800	325	0.082	0,818						
121	950	275	0.122	1,987						

NeuralBuilder

Output Layer

Transfer: TanhAxon

Learning Rule: Momentum

Step Size: 0.100000

Momentum: 0.700000

Help Close << >>

This panel is used to specify the parameters a layer of processing elements (PEs). NeuroSolutions simulations are vector based for efficiency. This implies that each layer contains a vector of PEs and that the parameters selected apply to the entire vector. The parameters are dependent on the neural model, but all require a nonlinearity function to specify the behavior of the PEs. In addition, each layer has an associated learning rule and

Em seguida é escolhido o número máximo de treinos que a rede irá executar.

The screenshot shows a Microsoft Excel window titled "Microsoft Excel - Aço 304". The active sheet is "Testing" with a formula bar showing "850". The data table has the following columns: A (Temp. (°C)), B (Tensão (Mpa)), C (Incl. Rota), and D (Deformação). The rows are numbered 94 to 121. A dialog box titled "NeuralBuilder" is open, showing the "Supervised Learning Control" tab. The "Maximum Epochs" field is highlighted with a red box and contains the value "1000". The "Termination" section has "MSE" checked with a threshold of "0". The "Weight Update" section has "Batch" selected. The dialog box also contains explanatory text about the Maximum Epochs field and the MSE termination criterion.

	A	B	C	D	E	F	G	H	I	J
1	Temp. (°C)	Tensão (Mpa)	Incl. Rota	Deformação						
94	950	202	-0.119	1,398						
95	950	177	-0.293	2,091						
96	1250	80	0.078	0,398						
97	1150	118	0.032	0,545						
98	1150	105	-0.072	1,398						
99	850	253	0.738	0,398						
100	950	211	-0.056	1,398						
101	1250	75	-0.055	0,398						
102	800	331	-0.018	1,398						
103	850	280	0.156	0,398						
104	800	290	0.679	0,398						
105	850	205	1.954	0,398						
106	1250	74	-0.055	1,398						
107	800	320	-0.415	1,398						
108	950	212	-0.032	0,398						
109	800	205	2.651	0,398						
110	950	204	0.252	0,398						
111	1150	118	0	0,398						
112	800	285	0.739	0,398						
113	1150	108	0.325	0,398						
114	1250	57	0.741	0,398						
115	850	285	-0.023	1,398						
116	1150	115	0.155	0,398						
117	950	153	0.639	0,398						
118	950	210	0.096	0,398						
119	950	138	2.326	0,102						
120	800	325	0.082	0,818						
121	850	275	-0.133	1,807						
122	1250	75	0.000	0,398						

Podemos enfim finalizar a construção da rede.

Microsoft Excel - Aço 304

Arquivo Editar Exibir Inserir Formatar Ferramentas Dados Janela Ajuda NeuroSolutions

Testing 850

	A	B	C	D	E	F	G	H	I	J
	Temp. (°C)	Tensão (Mpa)	Incl. Reta	Deformação						
94	950	202	-0,119	1,398						
95	950	177	-0,293	2,091						
96	1250	80	0,078	0,398						
97	1150	118	0,032	0,545						
98	1150	105	-0,072	1,000						
99	850	253	0,738	0,000						
100	950	211	-0,056	1,000						
101	1250	75	-0,055	0,000						
102	800	331	-0,018	1,000						
103	850	280	0,156	0,000						
104	800	290	0,679	0,000						
105	850	205	1,954	0,000						
106	1250	74	-0,055	1,000						
107	800	320	-0,415	1,000						
108	950	212	-0,032	0,000						
109	800	205	2,651	0,000						
110	950	204	0,252	0,000						
111	1150	118	0	0,000						
112	800	285	0,739	0,000						
113	1150	108	0,325	0,000						
114	1250	57	0,741	0,000						
115	850	285	-0,023	1,000						
116	1150	115	0,155	0,000						
117	950	153	0,639	0,000						
118	950	210	0,096	0,000						
119	950	138	2,326	0,102						
120	800	325	0,082	0,818						
121	850	275	-0,133	1,807						

NeuralBuilder

Probe Configuration

Input: BarChart
☐ Training Set ☐ C.V. Set

Output: DataWriter
☐ Training Set ☐ C.V. Set


Desired: DataWriter
☐ Training Set ☐ C.V. Set

Error: DataGraph
☐ Training Set ☐ C.V. Set

Performance Measures
☐ General ☐ Classification ☐ Confusion Matrix ☐ ROC
☐ Training Set ☐ C.V. Set

Help Close << **Build**

Aparece então a arquitetura e configuração da rede criada pelo Neuro Solutions.




O formato dessa rede varia conforme as escolhas mostradas nesse processo.


Com a rede criada o passo seguinte é treinar a rede.

I.c Treinando a RNA.


Para iniciar o treinamento clicamos em NeuroSolutions, Train Network, Train.



Na tela que se abre podemos mudar o nome do treino, definir novamente o número de treinos que serão rodados e escolher um número de ciclos que o programa vai rodar a partir do momento em que não há melhorias no treino.




Após o término do treino, o programa abre um relatório (report) sobre o treino.



Com a rede treinada podemos agora testá-la.


I.d Teste de rede.

Novamente clicamos em NeuroSolutions, Test Network, Test.



Em seguida vemos o relatório do teste, mostrando em um gráfico os dados de saída que inserimos no programa (Deformação) e os dados de saída previstos pela rede (Deformação Output). O mais importante nesse caso é o quanto o r se aproxima de 1. Quanto mais próximo de 1 o r ficar, mais precisa é a rede.

Observamos também o quanto o gráfico da previsão da rede se aproxima do real.



ANEXO 2

Tabela Randomizada para o Aço Inoxidável 304 com taxa de def de 2,3mm s⁻¹

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
1150	101	-0,045	1,864
950	200	-0,136	1,523
850	285	0,087	0,795
950	206	0,119	0,5
850	287	0,005	1,114
1250	82	-0,046	0,523
1150	117	-0,082	1,068
1150	75	1,951	0,045
800	330	0,086	1,148
800	246	1,852	0,188
850	275	0,227	0,568
850	185	2,421	0,125
800	175	3,429	0,083
1150	88	0,892	0,091
800	320	0,166	0,693
850	272	-0,215	1,92
800	328	-0,05	1,579
1150	116	-0,09	1,193
1150	100	-0,05	1,977
800	215	2,581	0,131
1250	80	0,128	0,341
1250	72	-0,023	1,261
950	190	0,633	0,295
1250	71	0,009	1,398
1150	118	-0,056	0,852
800	310	0,336	0,545
950	180	0,967	0,227
1250	77	-0,064	0,818
850	267	0,441	0,443
800	237	2,022	0,18
850	284	-0,046	1,466
1150	100	-0,064	2,091
1250	71	0	1,511

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
1150	117	0,087	0,477
850	155	3,258	0,091
950	190	-0,212	1,852
950	205	-0,101	1,295
1150	98	-0,096	2,204
850	278	0,165	0,614
1250	78	0,193	0,295
800	325	-0,186	1,773
1150	95	0,548	0,148
1150	103	-0,027	1,636
950	194	-0,194	1,739
950	212	0,05	0,682
800	260	1,417	0,23
800	327	-0,059	1,67
1250	82	0,032	0,454
1250	81	-0,082	0,602
1250	77	-0,115	0,75
850	275	-0,101	1,693
800	328	0,08	1,045
1150	103	0,389	0,204
800	225	2,471	0,17
950	199	-0,165	1,625
950	212	0,009	0,807
950	208	-0,077	1,17
1150	102	-0,013	1,75
850	220	1,305	0,204
1250	75	-0,055	1
950	212	-0,045	0,977
850	245	-1,9	2,159
850	285	-0,037	1,341
1150	117	-0,068	0,977
850	233	1,141	0,25
1250	65	0,472	0,114
850	260	0,634	0,375
1250	73	-0,06	1,159
800	327	0,073	0,932
950	110	4,56	0,057
1250	80	-0,101	0,67

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
1150	112	0,27	0,329
800	331	0,069	1,261
850	285	0,014	1,011
1150	106	-0,041	1,386
950	165	1	0,17
800	330	-0,027	1,477
850	265	-0,34	2,034
850	286	0,041	0,898
1150	118	-0,007	0,75
800	303	0,458	0,432
800	185	3,355	0,104
950	184	-0,233	1,966
950	198	0,321	0,375
1250	70	0,344	0,17
1150	109	-0,038	1,307
850	245	0,931	0,295
800	270	1,176	0,261
950	162	-0,82	2,204
1250	75	0,271	0,227
1150	118	0,013	0,614
850	280	-0,073	1,568
950	202	-0,119	1,398
950	177	-0,293	2,091
1250	80	0,078	0,398
1150	118	0,032	0,545
1150	105	-0,072	1,523
850	253	0,738	0,341
950	211	-0,056	1,057
1250	75	-0,055	0,932
800	331	-0,018	1,363
850	280	0,156	0,67
800	290	0,679	0,341
850	205	1,954	0,17
1250	74	-0,055	1,045
800	320	-0,415	1,898
950	212	-0,032	0,886
800	205	2,651	0,125
950	204	0,252	0,443

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
1150	118	0	0,693
800	285	0,739	0,307
1150	108	0,325	0,261
1250	57	0,741	0,045
850	285	-0,023	1,239
1150	115	0,155	0,398
950	153	0,639	0,136
950	210	0,096	0,591
950	138	2,326	0,102
800	325	0,082	0,818
850	275	-0,133	1,807
1250	76	-0,06	0,875

ANEXO 3

Tabela com dados randomizados do Aço Carbono Austenítico, com 0,79% de carbono. Taxa de deformação de 10mm s⁻¹.

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
800	232	-0,242	0,9
800	238,9	-0,178	0,71
1100	89,2	-0,062	1,68
1000	116,1	-0,116	1,91
800	204,1	-0,278	2,31
800	163,9	-0,128	3,5
900	176,2	0,442	0,3
1000	127,3	0,204	0,5
900	148,3	-0,094	2,68
900	155,2	-0,251	2,28
800	240,7	0,05	0,5
1000	104,7	-0,047	3,91
1100	87,2	-0,059	2,49
1000	130,8	-0,086	0,71
1100	87,2	-0,125	2,9
1100	97,7	-0,086	0,91
900	172,7	-0,137	1,5
1100	76,7	1,123	0,11
900	158,7	-0,156	2,08
800	177,9	-0,185	3,09
900	144,8	-0,165	2,88
900	167,4	-0,255	1,68
1000	113	-0,098	2,5
1000	123,8	-0,122	1,09
1100	86,7	-0,043	3,29
900	143	-0,074	3,07
800	235,5	0,783	0,3
1000	108,8	-0,007	3,51
800	191,9	3,615	0,11
900	179,7	-0,074	0,69
900	179,7	-0,047	0,9

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
1100	97,7	0,074	0,5
1000	120,3	0,425	0,3
800	235,5	0,783	0,3
900	179,7	0,051	0,49
1000	106,4	-0,137	3,7
1000	130,8	-0,086	0,71
800	163,9	-0,128	3,5
800	204,1	-0,278	2,31
1100	88,9	0,094	2,09
800	162,2	-0,114	3,7
900	153,5	2,684	0,11
1000	113,4	-0,098	2,3
1100	86,7	-0,043	3,29
1100	88,9	0,07	2,68
800	210	-0,292	2,09
900	164	-0,196	1,89
900	141,3	-0,086	3,48
900	179,7	-0,074	0,69
900	143	-0,074	3,07
1000	127,3	-0,078	0,9
1100	83,7	0,023	3,87
800	221,5	-0,171	1,5
900	179,7	0,051	0,49
1000	111,6	0,035	2,9
900	167,4	-0,255	1,68
800	228,5	-0,171	1,1
800	238,9	-0,178	0,71
800	240,7	0,05	0,5
900	155,2	-0,251	2,28
800	179,6	-0,264	2,9
1000	108,8	-0,082	3,29
800	162,2	-0,114	3,7
900	151,7	-0,125	2,49
800	170,9	-0,242	3,29
800	170,9	-0,242	3,29
1100	84,4	-0,059	3,68
800	195,3	-0,314	2,5
1000	112,7	-0,078	2,09

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
800	228,5	-0,171	1,1
800	214,5	-0,185	1,91
1000	102,9	1,906	0,11
900	137,8	-0,015	3,84
1000	123,1	-0,118	1,31
1100	88,9	-0,051	1,89
1100	97,7	0,074	0,5
1000	116,9	-0,079	1,68
800	186,6	-0,357	2,71
1000	120,3	-0,094	1,5
1100	97,7	0,007	0,71
900	158,7	-0,156	2,08
800	195,3	-0,314	2,5
1100	97,7	0,007	0,71
900	173,4	-0,125	1,31
800	177,9	-0,185	3,09
1100	87,2	-0,059	2,49
1000	110,2	-0,077	3,1
1100	90,7	-0,118	1,29
1100	83,7	0,023	3,87
1000	116,9	-0,079	1,68
800	210	-0,292	2,09
900	137,8	-0,015	3,84
1100	76,7	1,123	0,11
1100	90,7	0,33	0,3
800	214,5	-0,185	1,91
900	179,7	-0,047	0,9
1000	108,8	-0,082	3,29
1000	111,6	0,011	2,69
1100	89,8	-0,003	1,48
1000	111,6	0,035	2,9
800	191,9	3,615	0,11
1100	88,9	0,094	2,09
800	218	-0,207	1,68
800	225	-0,15	1,31
1100	90,7	-0,118	1,29
900	164	-0,196	1,89
1000	116,1	-0,116	1,91

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
1100	88	0,011	2,3
1100	84,4	-0,059	3,68
1000	123,1	-0,118	1,31
1000	127,3	-0,078	0,9
1100	90,7	0,33	0,3
1100	88	0,011	2,3
1000	106,4	-0,137	3,7
800	218	-0,207	1,68
1000	102,9	1,906	0,11
900	176,2	0,442	0,3
900	148,3	-0,094	2,68
900	137,8	-0,047	3,67
1100	89,8	-0,003	1,48
1000	127,3	0,204	0,5
900	177,9	-0,129	1,09
900	137,8	-0,047	3,67
1100	89,2	-0,062	1,68
800	225	-0,15	1,31
900	153,5	2,684	0,11
1100	87,2	-0,125	2,9
900	173,4	-0,125	1,31
1000	108,8	-0,007	3,51
900	144,8	-0,165	2,88
800	160,5	0	3,89
1100	86,5	0,015	3,1
1000	123,8	-0,122	1,09
1000	112,7	-0,078	2,09
1000	120,3	-0,094	1,5
1000	113	-0,098	2,5
900	172,7	-0,137	1,5
1100	94,2	-0,129	1,1
1100	84,4	-0,007	3,5
1100	86,5	0,015	3,1
900	151,7	-0,125	2,49
1100	97,7	-0,086	0,91
1100	94,2	-0,129	1,1
900	141,3	-0,086	3,48
1100	84,4	-0,007	3,5

Temperatura (°C)	Tensão (Mpa)	Incl. Reta Tg	Deformação (mm)
900	177,9	-0,129	1,09
800	232	-0,242	0,9
1000	113,4	-0,098	2,3
1100	88,9	-0,051	1,89
800	221,5	-0,171	1,5
1000	104,7	-0,047	3,91
800	179,6	-0,264	2,9
1000	111,6	0,011	2,69
900	141,3	-0,031	3,28
800	160,5	0	3,89
800	186,6	-0,357	2,71
1000	120,3	0,425	0,3
1100	88,9	0,07	2,68
1000	110,2	-0,077	3,1
900	141,3	-0,031	3,28

ANEXO 4

Tabela com dados randomizados do Aço C-Mn, com 0,59%C, 0,64%Mn, 0,35%Si, 0,012%S e 0,009%P, com taxa de deformação de 2mm s⁻¹ e 20mm s⁻¹.

Temp. (°C)	Tx Def (mm s ⁻¹)	Deformação (mm)	Tensão (MPa)	Incl. Reta Tg
899	2	0,684	178,5742139	-0,085
1199	20	0,608	84,80551471	0,01
1199	2	0,4	41,36854376	-0,012
899	20	0,456	219,9427577	0
1099	2	0,684	59,98438845	0,015
1099	20	0,038	102,7318837	1,766
899	20	0,304	218,5638062	0,17
1199	20	0,038	56,5370098	1,905
899	20	0,418	221,3217091	0
799	2	0,284	228,2164664	0,19
1099	2	0,124	55,84753407	0,345
1199	20	0,38	82,73708752	0,04
799	2	0,404	234,421748	-0,015
999	2	0,204	132,37934	0,07
899	20	0,342	219,9427577	0,07
799	20	0,684	288,2008549	-0,035
1199	2	0,04	27,57902917	0,7
1099	20	0,19	130,3109128	0,245
1099	20	0,38	137,2056701	0,033
1199	2	0,124	35,85273792	0,155
799	20	0,646	288,2008549	-0,03
999	20	0,038	119,9687769	2,057
699	2	0,368	303,3693209	-0,205
999	20	0,342	179,9531654	0,11
699	2	0,4	301,9903694	-0,215
699	2	0,24	317,1588355	-0,328
1099	20	0,646	137,2056701	0,015
799	2	0,552	231,6638451	-0,055
699	2	0,164	330,2588743	-0,445
899	2	0,48	193,7426799	-0,21
1099	2	0,516	62,05281564	-0,05
1199	20	0,076	65,50019429	0,34
899	2	0,404	196,5005829	-0,16
699	20	0,494	301,9903694	-0,19
799	20	0,152	266,1376315	0,59
999	2	0,04	99,97398075	1,641
1099	20	0,342	136,5161944	0,09
899	2	0,24	199,9479615	0,13
1199	2	0,164	38,61064084	0,13
1199	20	0,646	84,80551471	0,015
899	2	0,368	199,9479615	-0,06
699	20	0,646	297,1640393	-0,035
899	2	0,592	182,7110683	-0,195

Temp. (°C)	Tx Def (mm s ⁻¹)	Deformação (mm)	Tensão (MPa)	Incl. Reta Tg
1099	2	0,164	58,60543699	0,22
899	2	0,04	133,0688158	2,13
1199	20	0,532	83,42656325	0,055
699	2	0,48	297,1640393	-0,14
799	2	0,04	133,0688158	2,13
899	2	0,516	189,6058256	-0,23
899	2	0,64	179,9531654	-0,115
699	20	0,456	304,7482724	-0,21
1199	2	0,204	40,67906803	0,085
999	20	0,646	177,8847382	-0,07
999	20	0,266	173,7478838	0,215
699	20	0,266	326,8114957	-0,35
1199	20	0,114	68,94757293	0,25
899	20	0,076	176,5057867	1,197
699	20	0,304	322,6746413	-0,36
799	2	0,08	178,5742139	1,468
1199	2	0,48	40,67906803	-0,052
699	20	0,342	315,779884	-0,33
1099	20	0,532	137,8951459	0,01
899	20	0,646	210,9795732	-0,12
1099	20	0,152	126,1740585	0,26
899	20	0,532	217,1848547	-0,13
899	20	0,266	215,1164275	0,16
1099	20	0,494	137,8951459	0,01
799	2	0,324	230,9743693	0,18
699	2	0,08	331,6378258	0,625
999	20	0,608	181,3321168	-0,038
899	20	0,038	151,6846604	2,914
1199	20	0,57	84,80551471	0,02
999	20	0,076	141,3425245	0,945
699	20	0,152	315,779884	-0,545
1099	20	0,608	139,2740973	0,015
1199	2	0,404	40,67906803	-0,04
999	2	0,64	112,3845439	0
799	20	0,266	285,4429519	0,19
699	2	0,64	289,5798063	-0,1
999	2	0,124	126,8635342	0,415
1099	2	0,4	64,12124283	-0,025
999	2	0,552	112,3845439	-0,035
1099	20	0,684	137,2056701	0,03
1199	20	0,494	82,73708752	0,02
999	20	0,456	181,3321168	-0,007
799	20	0,114	254,4165441	1,078
1199	2	0,592	39,9895923	-0,013
999	2	0,324	129,6214371	-0,2
799	2	0,204	219,2532819	0,425
899	2	0,164	192,3637285	0,415
999	2	0,592	112,3845439	-0,005
999	20	0,418	181,3321168	0,03
799	20	0,304	288,2008549	0,17
699	2	0,204	322,6746413	-0,403

Temp. (°C)	Tx Def (mm s ⁻¹)	Deformação (mm)	Tensão (MPa)	Incl. Reta Tg
899	2	0,08	169,6110294	0,976
699	20	0,684	295,7850879	-0,03
799	20	0,608	288,8903306	-0,015
699	20	0,038	291,6482335	6,086
999	20	0,494	181,3321168	0
1199	2	0,684	41,36854376	0
699	2	0,404	299,2324665	-0,16
999	2	0,164	131,0003886	0,22
799	20	0,228	280,6166218	0,21
1199	20	0,342	81,35813606	0,07
1199	20	0,266	79,9791846	0,11
899	20	0,608	213,7374761	-0,115
1099	2	0,64	59,29491272	0,006
1099	2	0,284	62,74229137	0,03
799	20	0,57	288,8903306	-0,025
899	20	0,152	199,9479615	0,51
699	2	0,516	294,4061364	-0,13
1099	2	0,592	57,22648553	-0,04
699	20	0,114	355,0800006	-0,32
1199	2	0,324	42,74749522	0,015
799	2	0,48	233,7322722	-0,025
799	20	0,038	186,8479226	3,576
699	20	0,076	316,4693598	1,562
899	20	0,19	206,1532431	0,42
899	2	0,204	197,1900586	0,24
799	2	0,64	228,2164664	-0,1
1099	2	0,24	62,05281564	0,095
999	20	0,152	162,0267964	0,49
699	20	0,38	312,3325054	-0,295
1099	2	0,324	64,12124283	0,02
1199	20	0,456	83,42656325	0,045
899	2	0,4	198,56901	-0,13
799	20	0,418	289,5798063	-0,25
799	20	0,342	288,8903306	0,05
999	20	0,38	179,9531654	0,06
899	2	0,124	153,0636119	0,681
1199	20	0,684	84,80551471	0,005
799	20	0,19	275,100816	0,455
899	2	0,284	200,6374372	0,04
699	2	0,552	292,3377092	-0,12
1099	2	0,368	64,12124283	-0,01
999	2	0,24	132,37934	0
999	20	0,684	176,5057867	-0,07
899	20	0,228	211,6690489	0,3
999	20	0,228	170,9899809	0,28
799	2	0,368	233,0427965	0,105
899	20	0,114	190,2953013	0,75
799	20	0,38	289,5798063	-0,2
1099	20	0,076	115,8319225	0,575
699	20	0,228	333,0167773	-0,345
1099	2	0,08	50,33172824	0,365

Temp. (°C)	Tx Def (mm s ⁻¹)	Deformação (mm)	Tensão (MPa)	Incl. Reta Tg
1099	20	0,114	121,3477284	0,35
1199	2	0,552	39,9895923	-0,01
1099	20	0,456	137,8951459	0,01
999	2	0,404	116,5213983	-0,125
699	2	0,592	293,7166607	-0,125
799	20	0,076	231,6638451	1,638
699	2	0,04	313,0219811	2,705
999	2	0,48	115,8319225	-0,095
899	20	0,38	219,9427577	0,06
1099	20	0,304	135,1372429	0,065
1199	2	0,64	40,67906803	0
1199	2	0,368	42,05801949	-0,015
1199	2	0,516	39,9895923	-0,04
899	20	0,684	128,2424857	-0,135
999	2	0,284	131,0003886	-0,11
999	2	0,368	124,795107	-0,235
1199	20	0,19	75,84233022	0,18
1099	2	0,552	60,67386418	-0,055
999	2	0,516	113,7634953	-0,032
1099	20	0,266	135,1372429	0,08
1099	20	0,418	137,8951459	0,015
699	2	0,284	311,6430297	-0,36
1099	2	0,204	62,05281564	0,125
1199	20	0,418	82,73708752	0,04
999	2	0,4	120,6582526	-0,29
699	2	0,684	286,1324277	-0,09
799	20	0,456	289,5798063	0
699	2	0,324	306,8166995	-0,22
699	20	0,57	298,5429908	-0,06
899	2	0,552	186,1584469	-0,25
799	2	0,24	224,079612	0,32
999	20	0,304	176,5057867	0,15
699	2	0,124	336,4641559	-0,22
999	2	0,684	112,3845439	0,005
799	20	0,532	289,5798063	-0,03
1199	20	0,228	77,22128168	0,13
1199	2	0,24	42,05801949	0,032
799	2	0,164	209,6006217	0,949
999	20	0,19	166,1636508	0,34
899	20	0,57	215,1164275	-0,08
799	2	0,516	233,0427965	-0,06
699	20	0,418	307,5061753	-0,288
799	2	0,124	184,7794955	0,976
1099	2	0,404	63,4317671	-0,031
699	20	0,608	298,5429908	-0,045
899	20	0,494	218,5638062	-0,055
1099	20	0,57	137,8951459	0,02
699	20	0,19	339,2220588	-0,039
1099	20	0,228	132,37934	0,14
799	2	0,684	226,8375149	-0,095
899	2	0,324	202,0163887	-0,01

Temp. (°C)	Tx Def (mm s ⁻¹)	Deformação (mm)	Tensão (MPa)	Incl. Reta Tg
1199	2	0,284	43,43697095	0,02
1199	2	0,08	34,47378647	0,28
699	20	0,532	299,9219423	-0,12
799	2	0,592	230,9743693	-0,085
799	2	0,4	233,0427965	0,06
999	20	0,114	153,0636119	0,685
1099	2	0,48	62,05281564	-0,028
999	20	0,532	180,6426411	-0,015
1199	20	0,304	80,66866033	0,065
799	20	0,494	289,5798063	-0,005
999	20	0,57	181,3321168	-0,027
1199	20	0,152	72,39495158	0,223
999	2	0,08	116,5213983	0,61
1099	2	0,04	42,05801949	0,855

ANEXO 5

The prediction of the hot strength in steels with an integrated phenomenological and artificial neural network model

P.D. Hodgson ^a, L.X. Kong ^{a,*}, C.H.J. Davies ^b

^a School of Engineering and Technology, Deakin University, Geelong, Victoria 3217, Australia

^b Department of Materials Engineering, Monash University, Clayton, Victoria 3168, Australia

Abstract

The hot torsion data of a commercial 304 stainless steel has been analysed with an integrated phenomenological-artificial neural network model (IPANN), developed from the Estrin–Mecking (EM) phenomenological model and a back-propagation artificial neural network (ANN) model. In order to predict the flow stress in this model, the work-hardening coefficient and its product with the stress were used as inputs, along with strain, temperature and strain rate. The Pearson correlation coefficient was used to evaluate the performance and terminate the simulation of the IPANN model, whilst the standard errors were employed to quantitatively compare the accuracy of different models. The IPANN model is able to predict the distribution of flow stress more accurately in the work-hardening and dynamic recrystallisation regimes in comparison with the original EM and ANN models. The training speed is significantly improved and the test of the model is satisfactory, if reasonable training data is provided. In addition, by using the phenomenological model as training data, the IPANN model may be used for extrapolation. © 1999 Elsevier Science S.A. All rights reserved.

Keywords: Hot rolling; IPANN model; Work-hardening; Dynamic recrystallisation; Extrapolation

1. Introduction

Heavy industrial processes are now being controlled to greater degrees as both technology (e.g. computer power, software systems, measurement systems) and market requirements (e.g. quality, product dimensional control) increase. The hot rolling of steel is a particular example where there have been noted improvements in on-line control systems and off-line predictive tools to enable the mill to achieve the gauge tolerances required by the market. The entire process is now highly engineered to improve dimensional control and to potentially introduce greater flexibility.

For hot rolling, the product thickness is predominantly controlled through accurate knowledge of the forces during rolling. This arises from the mill housing and rolls acting like springs under the loads experienced in hot rolling. This elastic deformation must be accounted for to give the required thickness of the final

plate or strip. Under these conditions, and assuming perfectly elastic spring behaviour with no offset, the thickness h of the strip after a rolling pass is given by:

$$h = \frac{P}{S} + g \quad (1)$$

where P is the load, S is the mill spring constant and g is the mill gap. The force is the variable that will change most for a given rolling stand, as the other parameters are essentially mill constants. The force can be modelled in a number of ways, although most models take the form:

$$P = k_m A Q \quad (2)$$

where k_m is hot strength, A is the contact area and Q is a factor reflecting the geometric contribution. The hot strength of the steel, which is a measure of its resistance to the imposed deformation conditions, becomes the critical parameter and is the subject of the current work. The hot strength is the integral of the stress σ over the deformation path. Hence, Eq. (2) requires a constitutive model relating stress to the deformation conditions: strain, strain rate and temperature.

* Corresponding author. Fax: +61 3 52272167; e-mail: Lkong@Deakin.Edu.Au




Fig. 1. Back error propagation network with one hidden layer.

There are a number of approaches that have been used to model this force. Kocks and Mecking [1] and Estrin and Mecking [2] proposed a phenomenological model for the macroscopic plasticity of metals to describe the plastic flow in different models of continuous deformation and athermal work-hardening. Recently the introduction of artificial intelligence methods such as artificial neural networks (ANN) has also led to alternative models being proposed. Hodgson et al. [3] investigated and compared the performance of individual models such as phenomenological [1,2,4,6], empirical [5] and ANN [7,8] models to predict the flow stress of an austenitic stainless steel. The current paper presents the development of an integrated phenomenological and ANN model that is able to more accurately simulate the strength distribution in comparison with the predictions performed by either the phenomenological or the ANN model. The

performance of various types of models is compared with laboratory data of the stress–strain behaviour of a commercial austenitic stainless steel.

2. Experimental

A commercial 304 austenitic stainless steel (0.047C–1.15Mn–0.39Si–18.6Cr–8.8Ni–0.23Mo–0.4Cu) was supplied in hot rolled plate form. Torsion samples with a gauge length of 20 mm and a diameter of 5.3 mm were prepared from the plate and tested in the BHP Hot Torsion machine [6]. The test program involved heating to 1150°C, then holding for 5 min, followed by a deformation of 0.3 at a strain rate of 2.3 s^{-1} to obtain a uniform recrystallised grain size. The samples were then cooled to the test temperature and held for 20 s to allow temperature equalisation, prior to deformation.

All samples were tested to failure at strain rates from 0.23 to 23 s^{-1} and temperatures from 800 to 1250°C. Most of the testing was performed at 2.3 s^{-1} , with only a limited number of samples tested at the other strain rates. The data were converted from torque-twist to stress (σ)–strain (ϵ) using conventional methods [5]. No allowance was made for deformation heating in the analysis and it is noted that this would be substantial at higher strain rates and lower temperatures. However, the complexity of the torsion test makes this difficult to account for using current modeling tools.






Fig. 2. Measured and predicted stress strain curves at a strain rate of 2.3 s^{-1} (phenomenological model).



(a)



(b)

Fig. 3. Comparison of prediction and measurement with the phenomenological model: (a) full data set, $\varepsilon = 2.24$; (b) truncated data set, $\varepsilon = 1.2$.

3. Model development


The phenomenological models developed by Mecking and Kocks [1] and Estrin and Mecking [2] have been found to provide the best fit [6,9] compared with other models of this type. This is an internal variable model using the dislocation density as the single variable. In the Kocks and Mecking (KM) model for dynamic loading ($\dot{\varepsilon} = \text{constant}$), the work-hardening rate θ defined as the slope of the stress-strain curve, is [1]:

$$\theta = \theta_0 \left(1 - \frac{\sigma}{\sigma_s} \right) \quad (3)$$


where $\theta_0 = \alpha G b k_1 / 2$ is independent of strain rate and depends on temperature through the temperature dependence of G and σ_s is the saturation stress in the absence of dynamic recrystallisation. Estrin and Mecking developed the KM model further and found [2],

$$\theta \sigma = A - B \sigma^2 \quad (4)$$

which after integration, takes the form:



(a)



(b)

Fig. 4. Comparison of prediction and measurement with the ANN model: (a) full data set, $\varepsilon = 2.24$; (b) truncated data set, $\varepsilon = 1.2$.




Fig. 5. Comparison of prediction and measurement with the IPANN model: (a) full data set, $\varepsilon = 2.24$; (b) truncated data set, $\varepsilon = 1.2$.

$$\sigma = [\sigma_s^2 + (\sigma_0^2 - \sigma_s^2) \exp(-2B\varepsilon)]^{1/2} \quad (5)$$

where σ_0 is the initial stress when $\varepsilon = 0$ and A, B are constants which are a function of Zener Hollomon parameter, Z ($Z = \dot{\varepsilon} \exp Q_{\text{def}}/RT$) [6].

The training algorithm of the artificial neural networks (ANN) used in this work was back error propagation, which has been successfully employed in the modelling of plate rolling processes [7,8]. Fig. 1 shows the scheme of a three-layer network used in this work, where W and V represent the synaptic weights

[10,11]. The nodes are fully interconnected to every node in the neighbouring layers. Each node has multiple inputs coming from either the outputs of other nodes or the outside environment. The processing node calculates a weighted sum of the inputs and utilises the weighted sum as an argument to calculate the output through a threshold function. There are two stages during the training procedure of the back-propagation learning: forward propagation, in which the data propagate from the input layer to output layer, and error back-propagation in which the synaptic weights are updated and fed back until a pre-defined error between the predicted outputs and target outputs is reached.

The software used was NNMODEL developed by Neural Fusion. One hidden layer was used with the hidden nodes being optimised as four times the number of the input nodes plus one. The inputs initially used in Ref. [3] were strain, strain rate and temperature, whilst the output was the flow stress.

As indicated in Ref. [3], when using the ANN model, it is difficult to predict the steep variation in stress with strain at low strains compared with the rest of the curve. However, in the phenomenological models discussed above, the work-hardening rate (θ) and the square root product of θ and stress σ are directly related to the stress and can thus more readily account for the low strain behaviour. Therefore, if θ and $\sqrt{\theta\sigma}$ are introduced as two further inputs in the ANN model, information on the variation of stress with the strain can be used to train the model, and incorporated with other inputs used in the ANN model [3]. As this ANN model implements the work-hardening rate developed in the phenomenological models, it is termed an Integrated Phenomenological-ANN (IPANN) model. In this IPANN model, five inputs—strain, strain rate, temperature, work-hardening rate, θ and the square root product of the work-hardening rate and stress of $\sqrt{\theta\sigma}$ were used.

4. Results and discussion

4.1. Phenomenological model

The agreement of the phenomenological model with the experimental data is discussed in more detail in Ref. [6]. Figs. 2 and 3 shows some examples of the agreement between the model and the data. The experimental curves exhibit a peak stress, followed by gradual work softening towards steady state. It is clear that there is generally good fit for much of the work-hardening region, although some curves show a general offset (e.g. 950°C). At very low strains the model does not accurately predict the work-hardening

Table 1
Standard errors for all predictions in Figs. 3–7

$\epsilon_{\max}$	EM		ANN		IPANN		IPANN (training)		IPANN (test)	
	S_{Error}	Fig.	S_{Error}	Fig.	S_{Error}	Fig.	S_{Error}	Fig.	S_{Error}	Fig.
2.24	12.3044	3(a)	9.1859	4(a)	3.9135	5(a)	2.8952	6	7.9730	6
1.20	8.5900	3(b)	4.6542	4(b)	2.1760	5(b)	2.6293	7	3.3554	7

behaviour for test conditions of high temperatures and low strain rates (i.e. low Z) [6]. However, the level of agreement for most strains is high over the work-hardening range.

The deviation at larger strains is due to dynamic recrystallisation which was not incorporated into the simple version of the model described by Eq. (3). Whilst there have been attempts to model this behaviour, the model is still not sufficiently generalised for comparison over the full temperature range.

4.2. ANN model

Two cases for the data were considered during fitting for the ANN model. In the first case the full data set for each deformation condition was examined (Fig. 4(a)) at a strain rate of 2.3 s^{-1} . In this case the stress–strain curve is complicated by the occurrence of dynamic recrystallisation at high strains which leads to flow softening. Whilst this can occur under some deformation conditions it is not very common in industrial metal working processes such as rolling. Hence the data were also reduced for some of the models to strains from 0 to 1.2 as shown in Fig. 4(b). This represents the work-hardening regime for most deformation conditions. It also represents a typical upper end of strain for an individual rolling pass. Thirteen hidden nodes were contained in the hidden layer. The correlation coefficient between predicted and measured data was 0.9923.

4.3. IPANN model

The IPANN model was initially trained in the same way as the ANN model, i.e. for the full data set and for the strains up to 1.2 with the strain rate of 2.3 s^{-1} (Fig. 5(a, b)). The five inputs described above and twenty-one hidden nodes in a hidden layer were used to train the output stress. The Pearson correlation coefficient, R^2 was used in the same way as for the ANN model to evaluate the model's performance. It was observed that the strength was predicted in both the ANN and the IPANN models with higher accuracy at high strain values, particularly, as shown in Figs. 4 and 5 when compared with the EM model (Fig. 3). The correlation coefficient achieved high values in all trainings within a low number of training steps.

4.4. Model comparison

The individual models all gave reasonably good agreement with the measured data over the range of strain conditions that would be expected in hot rolling. Under the data conditions chosen, the ANN and IPANN models gave better agreement for the dynamic recrystallisation region of the stress–strain curve, with the IPANN model being able to provide more accurate predictions in the full region from work-hardening to dynamic recrystallisation.

When considering types of constitutive models there are a number of other factors that need to be considered, in particular the final application and the data limitations. For set-up purposes in a rolling mill it is necessary for the model to operate over the full range of deformation conditions and for it to be readily-adapted using mill data. For off-line predictive models, however, the need is generally to be able to predict to reasonable accuracy, e.g. within 5%, over a much wider range of deformation conditions. A particular issue in both cases is that the laboratory testing methods used to generate the data are often quite limited with respect to strain rate in particular, and for some methods, strain. Hence, there is the issue of extrapolation.

If each of the models above is considered there are clear examples where phenomenological models can form the basis for off-line models, which offer enhanced extrapolative power. As they are based on a mechanistic understanding it is possible to use relatively limited laboratory data. The other advantage of this formulation is that it can be applied in an on-line control environment within conventional adaptation schemes although to the best of the authors' knowledge, the EM formulation has not been used for on-line control to date.

The ANN is heavily constrained by the data it is trained with, and at low strains it is difficult to predict the steep variation in stress with strain compared with the rest of the curve. Attempts to remove particular data sets from the learning exercise and then to predict these curves led to large errors, particularly when the data were for strain rates and temperatures outside of the training range. The ANN model cannot provide any prediction beyond the boundary data set used for training. At the same time, however, the power of this

Table 2
Comparison of R^2 of ANN and IPANN models

Iteration No.	$\dot{\epsilon}$: 2.3; $\epsilon_{\max}$: 1.2		$\dot{\epsilon}$: 2.3; $\epsilon_{\max}$: 2.24		$\dot{\epsilon}$: 0.23, 2.3, 23; $\epsilon_{\max}$: 2.24	
	ANN	IPANN	ANN	IPANN	ANN	IPANN
1000	0.9963	0.9984	0.9918	0.9975	0.9332	0.9507
2000	0.9967		0.9920	0.9982	0.9836	0.9605
4000	0.9973		0.9923		0.9897	0.9770
10 000					0.9905	0.9978

technique to 'learn' from the mill process is potentially much greater than that of the phenomenological model.

The disadvantages encountered by individual models may be overcome with the IPANN model. The model provides greater flexibility and higher accuracy to the prediction. It can also potentially incorporate other parameters, such as composition. The prediction of the IPANN model is generally to within 5%, as shown in Fig. 5. The stress is accurately predicted for the data corresponding to strain from 0 to 1.2 (Fig. 5(b)) whilst there

IPANN model can extrapolatively predict and then be modified with further incoming data during on-line control.

While the Pearson correlation coefficient has been used as a criterion to evaluate the model performance and to terminate the simulation for ANN and IPANN models, the standard errors (S_{Error}) between the measured and predicted stresses were analysed to quantitatively compare the accuracy of the three models discussed. The standard errors (S_{Error}) defined here are:

$$S_{\text{Error}} = \sqrt{\frac{1}{n(n-2)} \left[n \sum \sigma_p^2 - \left(\sum \sigma_p \right)^2 - \frac{\left[n \sum \sigma_m \sigma_p - \left(\sum \sigma_m \sum \sigma_p \right) \right]^2}{n \sum \sigma_m^2 - \left(\sum \sigma_m \right)^2} \right]} \quad (6)$$

are few points dispersed closely along the accuracy zone for the prediction of the full data set (Fig. 5(a)). In addition, if the phenomenological model is used as training data outside of the experimental data, the

where σ_m is the measured stress, σ_p is the predicted stress and n is the number of the measured data used for simulation. As shown in Table 1, the IPANN model achieved much higher accuracy in comparison with the




Fig. 6. Comparison of measured and IPANN-predicted strength ($\epsilon_{\max} = 2.24$; $\dot{\epsilon} = 0.23, 2.3, 23 \text{ s}^{-1}$).




Fig. 7. Comparison of measured and IPANN-predicted strength ($\epsilon_{\max} = 1.2$; $\dot{\epsilon} = 2.3 \text{ s}^{-1}$).

phenomenological and ANN models in both full data set and truncated data set simulations. Of the three models, the phenomenological model presented the highest prediction error, particularly for the full data set, partly because a dynamic recrystallisation model was not introduced into the simulations. This is shown in Figs. 2 and 3(a), where the saturation stress was used in the work recovery regime after the stress reached the peak stress. However, even with the truncated data set, which is mostly in the work-hardening region, the standard errors of the phenomenological model are still the highest. The accuracy of the ANN model is between that of the phenomenological and IPANN models.

As indicated above, the IPANN model more accurately predicts the flow stress with the introduction of work-hardening rate ($\dot{\theta}$) and the square root product of $\dot{\theta}$ and stress σ ($\sqrt{\dot{\theta}\sigma}$) developed from the KM and EM models into the model as two inputs as they represent the trend of the variation of flow stress. In Table 1, it is observed that with the IPANN model, the prediction for the truncated data set is more accurate than that for the full data set. This is partly due to the higher accuracy of the phenomenological model in the work-hardening range. Therefore, the higher the accuracy of the phenomenological model, the higher the accuracy of the IPANN model over the full range. It is necessary to indicate here that the information provided by the phenomenological model in the IPANN model is the trend of the variation of the stress–strain curve, not the exact relationship. With the application of the simple phenomenological model discussed in this work, the trend of the variation of stress with strain over the dynamic recrystallisation regime has not been well predicted, leading to a relatively low accuracy of the IPANN model within this region. An exception to the accurate prediction with the IPANN model during the test of the models, is the training and test of the full data set at temperatures from 800 to 1250°C and at strain rates from 0.23 to 23 s^{−1}, where a high deviation was observed. This will be discussed in detail in the following section.

The training speed is an important aspect for the application of an ANN model to an on-line control system if the training results are fed back to manipulate the ongoing process. The IPANN model not only predicts the stress more accurately but also achieves a pre-selected accuracy, indicated by Pearson's correlation coefficient, within fewer iteration steps because the incorporation of the phenomenological model into the ANN provides more information about the influence of the deformation conditions on the stress distribution. Table 2 shows the R^2 for all of the simulations of IPANN model reported in this work compared with those for the ANN model. Generally, the IPANN model reaches a high accuracy at a low number of iterations and this then improves with further training.

By contrast, however, the accuracy of the ANN model is barely improved after achieving a certain value, particularly if this value is a high one, which indicates that the ANN model with only three inputs is not able to fully represent the constitutive characteristics. The incorporation of other parameters such as those used in the IPANN model reported in this work and the grain size and composition of the steel will likely be able to improve the prediction with the ANN model.

4.5. Testing of the IPANN model

As discussed above, the IPANN model provides a more accurate estimate of the stress over the full data set with the use of all experimental data for training in comparison with the phenomenological and ANN models. In Fig. 6, half of the data was used for training while the other half was used as a test set. It is observed that after the training had achieved the required accuracy, the prediction of the test data set was in good agreement with the experimental data. The only exception is the test of the data at 1150°C and strain rate 0.23 s^{−1}. The possible explanation for this error is that the amount of training data at strain rates 0.23 and 23 s^{−1} is not sufficient to predict the stress distribution and thus the prediction is based on the information provided at a strain rate 2.3 s^{−1} and the lack of the capability of extrapolation with the use of the ANN model. Due to this, the test accuracy is much less than the training accuracy indicated by the standard errors in Table 1. However, it is possible to postulate that the test accuracy will improve with the provision of training data at the boundary conditions of temperatures and strain rates, as seen from the test result for a strain rate of 2.3 s^{−1}. If the experimental data at these boundary conditions are not supplied, the phenomenological prediction can be used. In this case, the IPANN will be able to be used as an extrapolative model to predict the flow stress.

This can be illustrated in Fig. 7 by using truncated data for a strain of 1.2 at a strain rate 2.3 s^{−1} and for temperatures of 800, 950 and 1250°C, which represented the conditions of the boundary temperatures and an intermediate temperature. The prediction of both training and test was not as accurate as that in Fig. 5(b) where all data were used for training, although the test accuracy is almost as high as the training accuracy (Table 1). From the information provided in Figs. 6 and 7 and Table 1, it is verified that the appropriate provision and extraction of training data improves the training and test accuracy and reduces the training time. The more the training data, the longer is the time used to train, although the accuracy improves accordingly. Therefore, the optimisation of the training data, including the number and set used for training becomes important for both off-line prediction and on-line control.

5. Conclusions

Models of differing complexity and physical basis were fitted to hot torsion data for a commercial stainless steel. The Estrin–Mecking phenomenological model proved an accurate representation of the stress–strain behaviour in the work-hardening regime, and is highly suitable for extrapolation outside the laboratory test conditions. The ANN provided a good fit to much of the data but is heavily constrained by the data that it is trained on. In addition, it can only be used for interpolation, which limits its use when predicting actual process behaviour from laboratory tests. An integrated phenomenological–ANN model was, therefore, developed.

The IPANN model has the following advantages in comparison with phenomenological and ANN models:

1. It is able to predict more accurately stress in both the work-hardening regime and the dynamic recrystallisation region, and in particular performs well if the training data set is limited to a narrow range.
2. The training speed improves and satisfactory accuracy is achieved within fewer iterations.
3. The prediction accuracy with test data improves if an appropriate training data set is provided.

With the use of the phenomenological model as training data, the IPANN may be developed to extrapolatively predict the flow stress. In this case, the provision of an as accurate-as-possible prediction from the phenomenological model becomes important, as the deviation will influence the precision of the IPANN model over the whole range. As the three models have been applied to only a limited set of experimental data, the technique needs to be testified with more general data.

Acknowledgements

The authors wish to thank BHP for access to the laboratory test data described in this work. They also acknowledge the assistance of Mr David Collinson, formerly of BHP research and currently at Ajax Technology Centre.

References

- [1] F. Kocks, H. Mecking, Kinetics of flow and strain-hardening, *Acta Metall.* 29 (1981) 1865–1875.
- [2] Y. Estrin, H. Mecking, A unified phenomenological description of work-hardening and creep based on one-parameter models, *Acta Metall.* 32 (1984) 57–70.
- [3] P.D. Hodgson, D.C. Collinson, C.H.J. Davies, L.X. Kong, The application of phenomenological, empirical and ANN models to the predication of hot strength in steels, IPMM'97, Australasia-Pacific Forum on Intelligent Processing and Manufacturing of Materials, Brisbane, July 1997 (in press).
- [4] A. Laasraoui, J.J. Jonas, Prediction of flow stresses at high temperatures and strain rates, *Metall. Trans. A.* 22A (7) (1991) 1545–1558.
- [5] N.D. Ryan, H.J. McQueen, Dynamic recovery and strain hardening in the hot deformation of type 317 stainless steel, *Mater. Sci. Technol.* 81 (1986) 259–272.
- [6] P.D. Hodgson, The development of a constitutive model for the hot deformation of 304 Austenite stainless steel, IPMM'97, Australasia-Pacific Forum on Intelligent Processing and Manufacturing of Materials, Brisbane, July 1997 (in press).
- [7] A. Gorni, The application of neural networks in the modeling of plate rolling processes (JOM-e), *J. Min. Met. Mater. Soc. (electronic supplement)* 49 (4) (1997).
- [8] Y.J. Hwu, Y.T. Pan, J.G. Lenard, A comparative study of artificial neural networks for the prediction of constitutive behaviour of HSLA and carbon steels, *Steel Res.* 67 (1996) 59–66.
- [9] D.C. Collinson, P.D. Hodgson, C.H.J. Davies, The effect of carbon content on the constitutive modeling of steel, IPMM'97, Australasia-Pacific Forum on Intelligent Processing and Manufacturing of Materials, Brisbane, July 1997 (in press).
- [10] E. Rich, K. Knight, *Artificial Intelligence*, McGraw Hill, NY, 1991.
- [11] B. Muller, *Neural Networks—An Introduction*, Springer Verlag, Berlin, 1995.

ANEXO 6

Extrapolative prediction of the hot strength of austenitic steels with a combined constitutive and ANN model

L.X. Kong^{a,*}, P.D. Hodgson^a, D.C. Collinson^b

^a*School of Engineering and Technology, Deakin University, Geelong, Vic. 3217, Australia*

^b*Ajax Technology Centre, 336 Glenferrie Rd, Malvern, Vic. 3144, Australia*

Received 26 October 1998

Abstract

An integrated phenomenological and artificial neural network (IPANN) model developed previously by Hodgson et al. [P.D. Hodgson, L.X. Kong, C.H.J. Davies, J. Mater. Process. Technol. 87 (1999) 132–139] significantly improves the accuracy of the prediction of the hot strength of a commercial 304 stainless steel in comparison with either the phenomenological or the ANN model because of the integration of information developed from a phenomenological constitutive model. In the present work, the Estrin–Mecking constitutive model [Y. Estrin, H. Mecking, Acta Metall. 32 (1984) 57–70] was combined with the IPANN model to predict extrapolatively the hot strength of a plain-carbon austenitic steel with a carbon content of 0.79 wt.%, deformed at temperatures from 900 to 1100°C and at strain rates between of 1 and 30 s⁻¹. The ANN model was able to predict the hot strength over a wider range of deformation conditions using the experimental data and the data from the physical model as ANN training data set. Although, the prediction is not as accurate as if a complete experimental data set had been available, the technique does provide an accurate approach to predict extrapolatively the hot strength of steels with the ANN model. © 2000 Elsevier Science S.A. All rights reserved.

Keywords: Constitutive model; Artificial neural networks; Extrapolation; Hot strength; Dynamic-recrystallisation

1. Introduction

In hot rolling the thickness of the product is controlled predominantly through accurate knowledge of the force during rolling. The hot strength of the steel, which is a measure of its resistance to the imposed deformation conditions and is the integral of the stress, σ , over the deformation path, becomes the critical parameter in this prediction [1].

There are a number of approaches that have been used to model this situation. Kocks and Mecking [3] and Estrin and Mecking [2] proposed a phenomenological model to describe the plastic flow in different models of continuous deformation and a thermal work-hardening. Hodgson et al. [4] investigated and compared the performance of individual models such as phenomenological, empirical and artificial neural network (ANN) models to predict the flow stress of an austenitic stainless steel. Based on this, an integrated phenomenological and ANN model was developed [1,5] that is


able to more accurately predict the strength than either the phenomenological or ANN models over the range of laboratory data. However, due to the limitations involved with the ANN model, it could not be used to extrapolate beyond the training data without the introduction of large errors.

In this work, the stress–strain curves of an austenitic steel are firstly analysed with constitutive models to predict the hot strength for the deformation conditions tested. The IPANN model developed in [1] is then used to predict the strength for a wide range of deformation conditions using combined experimental and Estrin–Mecking (EM) model data as training inputs.

2. Experimental results

A steel with carbon addition of 0.79 wt.% was deformed over a range of conditions: at temperatures from 800 to 1100°C; and at strain rates from 0.1 to 100 s⁻¹. The stress–strain relationship for the steel deformed at a strain rate of 10 s⁻¹ is presented in Fig. 1, and shows working hardening to a peak stress, followed by work softening. The degree of

* Corresponding author. Tel.: +61-3-5227-3309; fax: +61-3-5227-2167.
E-mail address: lkong@deakin.edu.au (L.X. Kong)

Fig. 1. Stress-strain behaviour at a strain rate of 10 s^{-1} .

softening varies with the deformation conditions. At high Z (Z is the Zener–Hollomon parameter: $Z = \dot{\epsilon} \exp(Q_{\text{def}}/RT)$; and Q_{def} , the activation energy, is 244 kJ mol^{-1} [5]), there is a sharp peak, indicating rapid dynamic-recrystallisation, whilst at high temperatures the peak becomes very broad. The complexity of this trend makes the constitutive models to be discussed in the next section difficult to generalise accurately to cover both the work-hardening and dynamic-recrystallisation regimes.

3. Constitutive model and prediction

Predicting stress-strain curves for ANN models beyond the deformation conditions used for training is unreliable and dangerous. As indicated in a previous study [5], even a distribution between two given values is difficult to be predicted if no intermediate information is provided. However, the boundary information contains the most information given that no trend is known outside the boundary points. In Fig. 2, the information of function $y(i)$ varying between $i-1$ and $i+1$ is given. It is obvious that the prediction of y within the bounding points will be much easier than outside as there are infinite variation possibilities for y beyond $i-1$ and $i+1$. The objective in developing the constitutive model is therefore to provide a more accurate definition to y outside the boundary of the available data.




Fig. 2. Interpolation and extrapolation with the ANN.

According to the Kocks and Mecking (KM) model [3] there is a linear relationship between the work-hardening coefficient $\theta = d\sigma/d\epsilon$ and the flow stress in most of the work-hardening regime is given by

$$\theta = \theta_0 \left(1 - \frac{\sigma}{\sigma_s}\right) \quad (1)$$

where $\theta_0 = \alpha G b k_1 / 2$, which is independent of strain rate and depends on temperature through the temperature dependence of the shear modulus G ; and $\sigma_s = \alpha G b (k_1/k_2)$, which is the saturation stress in the absence of dynamic-recrystallisation. Estrin and Mecking [2] further modified the KM model and established that

$$\theta \sigma = A - B \sigma^2 \quad (2)$$

which after integration becomes

$$\sigma = [\sigma_s^2 + (\sigma_0^2 - \sigma_s^2) \exp(-2B\epsilon)]^{1/2} \quad (3)$$

where σ_0 is the initial stress when $\epsilon=0$ and A and B are constants that are functions of the Zener–Hollomon parameter. From Eq. (2) the saturation stress is obtained through

$$\sigma_s = \text{sqrt}\left(\frac{A}{B}\right) \quad (4)$$

which is shown in Fig. 3 for the data in Fig. 1.

Rewriting Eq. (3) yields


$$\ln(\sigma_s^2 - \sigma^2) = \ln(\sigma_s^2 - \sigma_0^2) - 2B\epsilon \quad (5)$$

The optimum initial stress σ_0 and constant B are then obtained from curve-fitting $\ln(\sigma_s^2 - \sigma^2)$ versus ϵ (Fig. 4).

The EM model considers only the work-hardening region. The Avrami equation is incorporated with Eq. (3) to predict work softening by dynamic-recrystallisation

$$\begin{aligned} \sigma^{\text{EM}} &= [\sigma_s^2 + (\sigma_0^2 - \sigma_s^2) \exp(-2B\epsilon)]^{1/2}, & \epsilon < \epsilon_c \\ \sigma &= \sigma^{\text{EM}} - X(\sigma^{\text{EM}} - \sigma_{ss}), & \epsilon \geq \epsilon_c \end{aligned} \quad (6)$$

where σ_{ss} is the steady-state stress and X is the fraction recrystallised at a specific strain, defined by

Fig. 3. EM model analysis ($\dot{\epsilon}=10 \text{ s}^{-1}$).




Fig. 4. Optimum initial stress and constant B ($\dot{\epsilon}=10\text{ s}^{-1}$).

$$X = \frac{\sigma_{EM} - \sigma}{\sigma_s - \sigma_{ss}} = 1 - \exp(-a(\epsilon - \epsilon_c)^b) \quad (7)$$

$$\ln(-\ln(1-X)) = \ln a + b \ln(\epsilon - \epsilon_c) \quad (8)$$

Eq. (6) is, therefore, a modified EM model incorporating dynamic-recrystallisation. Plots of $\ln(-\ln(1-X))$ versus $\ln(\epsilon - \epsilon_c)$ for $\epsilon > \epsilon_c$ were used to determine constants a and b (Fig. 5) for the deformation conditions of a strain rate of 10 s^{-1} and temperatures from 800 to 1100°C. The ϵ_c is the critical strain that is often replaced by peak strain, ϵ_p , due to the difficulty in accurately determining this quantity in some tests.

The constants in Eqs. (6) and (7) can be determined from Figs. 3–5. The model performance obtained from substituting the constants in Eq. (6), and incorporating the Avrami equation for dynamic-recrystallisation is shown in Fig. 6. There is good prediction in both the work-hardening and dynamic-recrystallisation regions.

In Fig. 7, the plot of saturation stress σ_s versus $\log(Z)$ shows an example of the constants in Eqs. (6) and (7) related to the material-dependent constant, Z . In this case, the saturation stress σ_s can be expressed as




Fig. 5. Determination of constant a and b in Eq. (7).




Fig. 6. Comparison of experiment results and modified EM predictions with optimum values for every case.

$$\sigma_s = m_1 (\log(Z))^{n_1} = 0.0082 \times (\log(Z))^{4.02} \quad (9)$$

After correlating all constants with $\log(Z)$, a generalised modified EM model was obtained to test the extrapolative performance. Only the data for 900, 1000 and 1100°C were used for model development. The stress–strain curves for temperatures 800 and 1200°C were predicted and compared with measurements. Fig. 8 shows a comparison of the measurement values with the predicted values for a strain rate of 10 s^{-1} , where it is seen that the stress for a temperature 800°C is predicted accurately, although its information was not used for model generation.

4. ANN model and prediction

The supervised multi-layer feed-forward network was used with the standard back-propagation algorithm, which has been discussed in previous work [1,5]. The predictive ability of the EM model suggests that the work-hardening rate (θ) and the square-root product of θ and stress σ are directly related to the stress. Therefore, in the IPANN






Fig. 7. Curve fitting of the saturation stress.



(a)



(b)

Fig. 8. Extrapolation using the modified EM model: (a) without modelling of dynamic-recrystallisation; (b) with modelling of dynamic-recrystallisation.

model, six inputs, i.e., strain, strain rate, temperature, work-hardening rate θ ; the square-root product of the work-hardening rate and the stress of $\sqrt{\theta\sigma}$, and $\log(Z)$ were used.

The techniques for the selection of a criterion to stop the training, training data preparation and the selection of the training algorithm, used in previous work [5], were also employed here. However, instead of developing techniques to improve prediction accuracy, this work focuses on how to develop a scheme to use ANN models for extrapolation. Here, then, the IPANN model was modified by the introduction of the prediction from the phenomenological model as the complementary training data set.

Fig. 9 shows the data scheme for the ANN extrapolative model used in this work. The experimental data between $(T'_{min}, \dot{\epsilon}'_{min})$ and $(T'_{max}, \dot{\epsilon}'_{max})$ were available, whilst the prediction needed to cover the range between $(T_{min}, \dot{\epsilon}_{min})$ and $(T_{max}, \dot{\epsilon}_{max})$. The experimental data for deformation conditions at temperatures of 900, 1000 and 1100°C and strain rates of 1, 10 and 30 s⁻¹ were used to develop the modified EM model and from this model the prediction of the stress-strain behaviour for the deformation conditions of tempera-




Fig. 9. Data scheme for ANN training to achieve extrapolative prediction.

tures from 800 to 1200°C was performed to provide training data outside of the shaded area (i.e. the boundary information). The prediction for a strain rate beyond that of the experimental data can be performed in the same way, although only varying temperature is considered in the present paper.

The experimental data at 1000°C and predictions from the modified EM model at 800 and 1200°C were used for training with the strain rate remaining at 1, 10 and 30 s⁻¹ (the same as in experimental conditions). The prediction is very accurate at 1000 and 1100°C, whilst there is a higher error for 800 and 900°C (Fig. 10), the higher error at 800°C being due to error in the phenomenological model, Fig. 8b. At 900°C, the larger difference between the saturation and steady-state stresses observed experimentally is not obtained from the model. The reason for this is that the training data used at temperatures 1000 and 1200°C has slow dynamic-recrystallisation with little difference between the saturation and steady-state stresses, Fig. 11. Representative training data and more information are therefore required to improve the accuracy of ANN predictions, in which there are sudden changes in the output data, as can be seen from Fig. 12. The




Fig. 10. Comparison of experimental data with ANN extrapolative prediction using training data from phenomenological model for temperatures at 800 and 1200°C.




Fig. 11. Dynamic-recrystallisation behaviour at different temperatures.

technique of optimising training data has been discussed in detail in a previous work [5], the selection of training data being very important for the accuracy of the IPANN model.

However, the accuracy of the phenomenological model becomes even more important if its prediction is used as training data for an ANN model, as its error will have a twofold effect on the final ANN prediction. For example, if the predictions with the EM model in Fig. 8a were used to train an IPANN model, the strain–stress behaviour would not be predicted precisely in the region beyond the critical/peak strain because dynamic-recrystallisation has not been incorporated in the EM model at this stage. Therefore, the more accurate is the phenomenological model used for the training of the IPANN model, the more precise is the prediction of the IPANN model for other levels of deformation. This




Fig. 12. Comparison of experimental results with ANN extrapolative prediction using experimental data as training data with only 1200°C predictions from the modified EM model.

then introduces a dilemma with this approach, as the need to use a more precise phenomenological model reduces the need for the IPANN. However, even a less accurate phenomenological model output as part of the training set markedly increases the extrapolative ability of the IPANN model. Once on-line data are available, the power of the IPANN will increase rapidly.

As experimental data for temperatures from 800 to 1100°C is available, the IPANN prediction with these data and data at 1200°C from the phenomenological model was performed. Fig. 12 compares the IPANN prediction with experimental results. The prediction is more accurate than that with dispersed training data or/and more training data from phenomenological model, e.g. Fig. 10. This indicates that although the initial extrapolative prediction with the IPANN model is not very accurate, the prediction accuracy can be improved by the employment of more experimental data, which will be available once more experimental work on rolling is conducted.

5. Discussion and model comparison

From the above analyses of the experimental data for steel with a carbon content of 0.79 wt.%, it is observed that both the phenomenological model and the IPANN model can accurately predict the strain–stress behaviour over the work-hardening and dynamic-recrystallisation regimes. However, the accuracy is dependent on the degree of model generalisation for the phenomenological model and the selection of training data for the IPANN model.

In the conventional EM model, only the work-hardening region is modelled and consequently the prediction of the hot flow stress after the peak strain involves a large error, see Fig. 8a. With the modified EM model, which incorporated dynamic-recrystallisation, the behaviour in both the work-hardening and dynamic-recrystallisation regimes were predicted, precisely, except for 800°C, where the dynamic-recrystallisation is not well fitted with the Avrami equation.

Although the EM model predictions with optimum value for the parameters in Eqs. (2)–(7) are able to accurately predict the strain–stress behaviours over the whole range, it is the generalised modified EM model that is more useful in interpolatively and extrapolatively predicting the hot strength of steels, especially for possible on-line and off-line control of the rolling processes. As the phenomenological model is based on a mechanistic understanding it is possible to be generated using relatively limited laboratory data [4]. Fig. 8b shows the extrapolative power of the modified EM model, in which the predicted stress at a temperature of 800°C is very accurate using the information developed from the modified EM model can be used for training the IPANN model without sacrificing significantly prediction accuracy.

Initial extrapolative prediction with the IPANN model is dependent largely on the accuracy of the constitutive models. From Fig. 10 it is observed that IPANN does provide the extrapolative capability to predict the strain–stress behaviour beyond the available experimental data using the scheme outlined in Fig. 9. Comparing Fig. 10 with Fig. 12, it is observed that the extrapolative prediction can be improved with techniques such as providing more experimental training data, as it is not as accurate as an ANN prediction with complete experimental data. The prediction with the IPANN model described in this work is more concerned with the model development rather than with the improvement of the predictive accuracy that will be investigated in future work.

The most advantageous feature of the IPANN model over constitutive models in extrapolative prediction is that the IPANN can easily incorporate further experimental or mill rolling data with the existing model. If boundary information, such as those for temperatures at 800 and 1200°C discussed in this work, is available from experimentation, the data can be simply used as training data to replace the data from modified EM prediction. The IPANN prediction would then be improved, as shown in Fig. 12. In contrast, the constitutive implementation of further experimental data will need tedious calculation, as outlined previously in the constitutive analysis, and a generalised constitutive model is more likely to create greater error than that of the IPANN prediction.

The error analysis of the predictions with both EM phenomenological model and IPANN model is summarised in Table 1. It is seen that the prediction with the conventional EM model is the least accurate due to the lack of the incorporation of a dynamic-recrystallisation model, whilst the IPANN model with experimental training data is the most accurate model. It is interesting and encouraging to find that the IPANN extrapolative prediction is nearly as good as that of the two constitutive predictions with an incorporated dynamic-recrystallisation model, where the accuracy of case 2 was affected by the high error at low stresses. Therefore, the IPANN extrapolative model is an excellent prospect for development of an on-line control system.

Table 1
Error analysis of different model prediction

	R^2	S_{error}	Figures
Generalised EM model (case 1)	0.936	17.56	Fig. 8a
Modified EM with optimum parameters (case 2)	0.984	9.00	Fig. 6
Generalised modified EM model (case 3)	0.983	9.1	Fig. 8b
IPANN extrapolation (case 4)	0.981	9.7	Fig. 10
IPANN prediction with experimental data (case 5)	0.990	6.9	Fig. 11

6. Conclusions

The IPANN model developed previously by Hodgson et al. [1,5] has been employed successfully in this work to predict extrapolatively the hot strength of an austenitic steel. With the incorporation of the modified EM phenomenological model into the IPANN model, both the work-hardening and dynamic-recrystallisation regimes were predicted accurately. In comparison with constitutive predictions, the IPANN model presented a similar degree of accuracy but possessed a higher level of flexibility. In addition, further experimental data can be incorporated easily with the IPANN model to significantly improve the accuracy of the phenomenological model. The more accurate is the training data used, the more accurate is the IPANN prediction.

The accuracy of the phenomenological model significantly influenced that of the prediction of the IPANN model at the initial stage in terms of its extrapolation function if the data from the phenomenological model was used to train the model. The data set within the work-hardening regime therefore had a greater accuracy whilst the data set for the full deformation region was less accurate even with the inclusion to the dynamic-recrystallisation model. Generally there was a greater error in prediction in the region of dynamic-recrystallisation.

In conclusion, the IPANN model reported in this work is able to extrapolatively and accurately predict the hot strength of steels in both the work-hardening and dynamic-recrystallisation regimes with the implementation of a phenomenological model as training data. The provision of training data with high accuracy at the boundary conditions is very important due to the incapability of the extrapolation of the neural networks. As the aim of this project is to develop an on-line control system, the accuracy of the prediction will improve with the replacement of the data from phenomenological model with ongoing feedback from the mill data.

References

- [1] P.D. Hodgson, L.X. Kong, C.H.J. Davies, Prediction of hot strength in steels with an integrated phenomenological and artificial neural network model, *J. Mater. Process. Technol.* 87 (1999) 132–139.
- [2] Y. Estrin, H. Mecking, A unified phenomenological description of work hardening and creep based on one-parameter models, *Acta Metall.* 32 (1984) 57–70.
- [3] F. Kocks, H. Mecking, Kinetics of flow and strain-hardening, *Acta Metall.* 29 (1981) 1865–1875.
- [4] P.D. Hodgson, D.C. Collinson, C.H.J. Davies, L.X. Kong, The application of phenomenological, empirical and ANN models to the prediction of hot strength in steels, *IPMM'97*, Brisbane, Australia, 1997, pp. 961–967.
- [5] L.X. Kong, P.D. Hodgson, D.C. Collinson, Modelling the effect of carbon content on hot strength of steels using a modified artificial neural network, *ISU Int.* 38 (1998) 1121–1129.

ANEXO 7




Fig. 19. Effect of vanadium and holding time on the hot strength of 0.14 C - 1.25 Mn steels. Rolling strain rate 7 s^{-1} . Soaking temperature 1100°C (55).




Fig. 20. The upgrading of mild and Nb steels by accelerated cooling after rolling (79).

The high-temperature flow behavior has been investigated for six C-Mn steels with compositions ranging from 0.01% C to 0.9% C. The temperature has been varied from 1100 to 2200°F (600 to 1200°C) and the strain rate has been varied from 0.5 s^{-1} to 140 s^{-1} to encompass the wide range of industrial processing rates and temperatures. These experiments have been conducted on a Cam Plastometer compression testing machine. This machine deforms the steel at a constant true strain rate which is very important for hot-working studies since the material is rate sensitive. Also, the compression test is closely related to the mainly compressive rolling or forging process. The results show that dynamic recrystallization is occurring during austenite deformation. The flow stress decreases with increasing temperature except in the two-phase ferrite plus austenite region where the reverse is true. The flow stress increases with increasing strain rate. In the austenite region the flow stress is nearly independent of the carbon level, whereas in the ferrite region the stress increases rapidly with increasing carbon level.

Murray John Stewart
Head, Metal Forming Section
Canada Centre for Mineral and Energy Technology
Ottawa, Canada

HOT DEFORMATION OF C-MN STEELS FROM
 1100 TO 2200°F (600 TO 1200°C) WITH
CONSTANT TRUE STRAIN RATES FROM 0.5
TO 140 s^{-1}

Introduction

There have been a number of studies over the past twenty-five years on the hot-working strength levels of carbon steels at strain rates near those encountered in industrial forming processes (1-11). For the calculation of metal working loads the flow behavior must be known at the temperature and strain rate of the process. Also, in such operations as rolling and forging the individual deformation cycles are usually less than twenty per cent, hence for the force analysis the flow curve at very low strains is required. Prior studies have concentrated on the steady-state or peak flow stresses with less regard for the low strain region which is often the most important from a practical point of view.

The most common testing methods have been either torsion (1-11) or compression (12-22) testing to determine the true stress-true strain relationship. Torsion testing has the advantage of being able to produce large strains at a constant strain rate but this strain and strain rate are not uniform throughout the cylindrical specimen, which complicates the analysis. The torsion test is excellent, however, for determining the optimum forming temperature (22) using ductility as the formability criteria. The compression test has the advantage of homogeneous deformation throughout the test specimen up to a strain of about 0.7 (50% reduction in height). Beyond this strain it is increasingly more difficult to estimate the bulging of the specimen sides by normal lubrication techniques. Also, when the upsetting is done on special machines (22, 13, 16) the true strain rate can be maintained constant throughout the deformation. The compression test also closely duplicates the deformation mode of rolling or forging which are mainly compressive in nature. Ductility values cannot be obtained from the compression test, so for certain applications data may be required from both types of tests.

This current paper concerns the compressive flow behavior of carbon steels in the austenite phase, the ferrite plus austenite phase region, and for comparison, the ferrite plus cementite phase region. Since data from various studies are often conflicting due to variations in material preparation and chemistry or due to different testing techniques a wide range of carbon levels, temperatures, and strain rates have been studied. The individual stress-strain curves are presented to show the flow stress at low strains.

Experimental Procedure

Material Preparation

Six C-Mn steels were studied as listed in Table I.

Table I. Chemical Analysis of the Steels
Tested (weight per cent)

Steel Number	Heat.	C	Mn	Si	S	P
1	9109	0.01	0.19	0.15	<0.005	<0.002
2	9110	0.03	0.62	0.32	0.014	0.004
3	9111	0.19	0.64	0.31	0.013	0.004
4	9112	0.38	0.64	0.34	0.014	0.006
5	9113	0.59	0.64	0.35	0.012	0.006
6	9114	0.90	0.73	0.46	0.012	0.009

The steel was air induction melted and sand cast into 50-lb (23 kg) slabs 2.5 in. (63.5 mm) thick. These slabs were hot rolled from a soaking temperature of 2190°F (1200°C) to a final thickness of 0.88 in. (22 mm). Cylindrical compression specimens 0.500 in. (12.7 mm) in diameter by 0.770 in. (19.6 mm) in height were machined from the hot-rolled plates with the cylindrical axis perpendicular to the rolling plane. The compression axis is therefore in the direction of the rolling compressive deformation.

A single V-shaped groove was machined into the flat specimen ends to act as a reservoir for the molten glass lubricant during the upsetting. The optimum groove was 0.012 in. (0.30 mm) deep, 0.030 in. (0.76 mm) in from the specimen edge, and with a 60 degree included V-angle.

Testing Method

The compression testing was conducted using a constant true strain rate Cam Plastometer that is fully described in a previous publication (23). The deformation is controlled by a shaped cam to give the constant true strain rate and the cam rotational speed determines the true strain rate. The specimens are heated in a separate furnace for one hour at the testing temperature prior to the transfer to the machine load frame. The specimen and dies are contained in a special radiation shield to prevent a temperature drop during the transfer before the deformation. The die materials used were either silicon nitride, silicon carbide, or titanium carbide in a nickel matrix.

The load-time data from the plastometer load-cell is recorded on a transient recorder. This recorder stores the digital equivalent of the load as a function of time and four to six hundred data points are recorded to define the load-time curve. This information is transferred on paper tape to a computer to obtain the true-stress true-strain relationship. This method gives an excellent resolution at all strains.

Experimental Results

The experimental true-stress true-strain curves are presented in Figures 1 through 6 for steels 1 to 6 respectively. Due to current testing machine limitations the data for the lowest and highest strain rates are not as complete as for the 2 or 20 s^{-1} rates. The tests were all conducted to a total compressive strain of 0.7 (50% reduction in height). This reduction is controlled by the cam height.

The flow curves have been adjusted if barreling occurred during the upsetting. An empirical factor to correct the stress was developed by upsetting identical specimens to the same strain but changing the end lubrication. This resulted in a series of flow curves as a function of the degree of barreling. The barreling was characterized by the maximum cross-sectional area and comparing this to the ideal area if no barreling occurred (24). The maximum correction factor that was required was a five per cent reduction in the apparent flow stress. Generally, the correction was one or two per cent.

No correction has been made for adiabatic heating that occurs at the higher strain rates. Temperature rises in excess of 100°F (40°C) have been observed at the lower temperatures and higher strain rates.

Discussion

Flow Curves

There are three types of true-stress true-strain curves observed for these steels.

- (a) A gradually increasing flow stress rising to a steady-state stress value with no peak in the curve. This is the general behavior for the ferrite phase with low carbon levels at the strain rates studied. This is shown for example by steel 1 or 2 at 1290°F (700°C) and a 2 s^{-1} strain rate. This is generally regarded as indicating a dynamic recovery mechanism of hot working is occurring (25, 11). The high stacking fault energy of the ferrite allows

easy migration of the ferrite subgrains during working and new grains are not nucleated. The existing ferrite grains are elongated as shown in Fig. 7 for steel 2 deformed at 1295°F (700°C), showing that recrystallization has not occurred for these deformation conditions.

- (b) The flow stress increasing to a broad peak and then decreasing to a steady-state value is the general behavior of the austenite phase at all carbon levels (25, 11). This is shown for example by the flow curves at 2010°F (1100°C) or 2190°F (1200°C) for steel 1 or 2 at a 2 s^{-1} strain rate. Up to the peak in the curve, dynamic recovery only occurs, and then at the peak, dynamic recrystallization begins to occur, resulting in a drop in the flow stress to a steady-state value. Recrystallization occurs since austenite has a low stacking fault energy which results in small subgrains with dense boundaries which nucleate new austenite grains. The steady state flow results from a balance between the buildup of the subgrain network and the growth of recrystallized grains (26).

The strain at which the start of dynamic recrystallization occurs decreases with an increase in temperature or a decrease in strain rate (26). The temperature effect can be clearly seen by observing the curves at 1830°F (1000°C) and 2190°F (1200°C) for steel 1 at a 2 s^{-1} strain rate in Fig. 1. Several flow curves for steel 4 have been reported in Fig. 8 to show clearly the increase in the peak strain with increasing strain rate. It should be noted that the time for the start of recrystallization decreases with increasing strain rate even though the strain increases.

- (c) Dynamic recrystallization has been shown to occur in ferrite (11), also, at low stresses. Using a peak in the flow curve as the criteria for dynamic recrystallization, this appears to occur in steel 1 at 1290°F (700°C) at the 0.5 s^{-1} strain rate. At higher strain rates the peak does not appear for this steel, at least not within the strain region studied.

A rapidly increasing flow stress up to a sharp peak at a low strain and then a gradually decreasing stress, to a steady-state value is the type of behavior seen for the higher-carbon steels (4, 5, and 6) at 1290°F (700°C). Under these conditions the initial pre-worked structure consists of ferrite plus pearlite. It has been shown (27, 28) that hot deformation of pearlite results in very rapid spheroidization during working, resulting in a drop in the flow stress. To illustrate, Fig. 9 is an optical micrograph of several former pearlite colonies

(steel 2) after deforming at 1290°F (700°C) with a 2 s⁻¹ strain rate showing the spheroidized pearlite. The degree of work softening is a strong function of the carbon level in the steel as shown in Fig. 10 which is a plot of selected stress-strain curves for a strain rate of 20 s⁻¹ at 1290°F (700°C). Steel 1 shows the dynamic recovery type curve as discussed previously since there is little or no pearlite present. As the carbon level, and hence the pearlite content, increases, the peak becomes much sharper and the extent of work softening increases. There is still, however, a significant difference in the steady-state flow stress after spheroidization with a change in carbon level.

Temperature Effect

The effect of the working temperature on the maximum flow stress is shown in Fig. 11 for steels 1, 3, and 5. The ferrite-austenite transformation region is also shown on these curves as determined from a dilatometer study with slow cooling rates. Some scatter in the results is observed which is caused by such factors as: adiabatic heating, slight chemical variations leading to differences in the amount of each phase present at certain temperatures, inaccuracies due to balling, and differences in the initial grain sizes due to different testing and therefore soaking temperatures.

The lower carbon level steels 1, 2 and 3 show a large inflection in the curve through the two-phase region resulting in the flow stress changing very little over a wide hot-working temperature range. The reason for this is that the austenite would be stronger than the ferrite at the same temperature and strain rate (7,8). This could be expected since there are less slip systems available in the austenite, the diffusivity in the austenite is about 1/400th that of the ferrite, and the stacking fault energy in the austenite is lower, causing the subgrain size to be smaller than in the ferrite.

This lack of a strength increase with a decreasing temperature can be commercially exploited by working the high-temperature ferrite rather than the normal austenite and thus conserve heating energy and prolong roll or die life. Care must be taken, however, not to finish the hot working in a region of ferrite plus austenite since this can result in a mixed ferrite grain size. Fig. 12 shows this type of structure for steel 3 worked at 1470°F (800°C) in the two-phase region and air cooled. The coarse grains are possibly due to the deformed ferrite recrystallizing and growing to a larger size after deformation and during cooling. The fine grains are possibly from the deformed fine-grained austenite transforming at lower temperatures to fine-grained ferrite.

A reduced working temperature does not have a significant benefit in lowering the applied working forces in the high-carbon steels as seen in Fig. 11. The strengthening effect of the carbide phase counteracts the effect of the softer ferrite phase when considering either the peak stress or the steady-state stress.

Carbon Level Effect


The carbon level as discussed above has a large effect on the flow stress at low temperatures, (ferrite plus cementite) and a small effect at high temperatures in the austenite. Fig. 13 shows the effect of carbon on the peak stress and the steady state stress at various temperatures. At 1190°F (600°C) the stress increases with carbon content as expected due to the hardening effect of the cementite. This effect is not as pronounced after spheroidization. At 1830°F (1000°C) or 2190°F (1200°C) there appears a small increase in the stress at low-carbon levels but the stress level is not sensitive to the carbon level at the higher levels. There is possibly a slight decrease in stress with increasing carbon level as observed previously (8) and attributed to a higher self-diffusion rate of iron at higher carbon levels. At 1470°F (800°C) the stress rises rapidly up to 0.4% C and then becomes almost constant. This is because at 1470°F (800°C) the steels with greater than 0.4% C are single-phase austenite. Below 1470°F (800°C) the steel is either a mixture of ferrite plus austenite or completely ferrite. The ferrite as discussed previously will lower the flow stress.

Conclusions

- (a) The hot-working flow behavior has been shown for carbon steels in the austenite, ferrite plus austenite, and the ferrite plus cementite phase regions.
- (b) Three types of hot-working flow curves which are dependent on the phases present prior to testing have been shown to occur during working.
- (c) The flow stress decreases with increasing temperature except in the two-phase ferrite plus austenite region for the low-carbon steels where the strength is relatively independent of temperature.
- (d) The hot-working strength of the ferrite plus cementite mixture increases with increasing carbon content, whereas the strength of the austenite phase is relatively insensitive to the carbon level.
- (e) The degree of work softening due to spheroidization increases with increasing carbon level.

1. Crossard, C. and Tamhankar, R., "High-Temperature Deformation of Steels: A Study of Equicohesion, Activation Energies, and Structural Modifications," Transactions of the Metallurgical Society of AIME, Vol. 212, December 1958, pp. 718-730.
2. Crossard, C. and Blatin, P., "Premiers Résultats de Recherches sur la Déformation des Aciers à Chaud Mise au Point d'un Appareillage Spécialement Étudié," Revue de Metallurgie, Vol. 55, No. 6, 1958, pp. 573-594.
3. Crossard, C. and Blatin, P., "Evolution de la Structure de l'Acier sous l'effet de la Déformation Plastique à Chaud," Mémoires Scientifiques Rev. Metallurg., Vol. 56, No. 3, 1959, pp. 283-300.
4. Reynolds, R. A., and Tegart, W. J. McG., "The Deformation of Some Pure Irons by High Speed Torsion Over the Temperature Range 700-1250°C," Journal of the Iron and Steel Institute, Vol. 200, December 1965, pp. 1044-1059.
5. Onikara, Y., Nakamura, T. and Sakai, S., "Temperature and Strain Rate Dependence of Flow Stress in Metals and Alloys," Transactions ISIJ, Vol. 12, 1972, pp. 36-44.
6. Onikara, Y., Nakamura, T., and Sakai, S., "Steady State Torsional Deformation and Restoration Process in Metals and Alloys," Transactions ISIJ, Vol. 12, 1972, pp. 207-216.
7. Robbins, J. L., Wegmann, R., Shepard, O. C., and Sherby, O. D., "Torsion Testing as a Means of Assessing Ductility at High Temperatures," Journal of Metals, Vol. 2, No. 2, June 1967, pp. 271-299.
8. Robbins, J. L., Shepard, O. C., and Sherby, O. D., "Torsional Ductility and Strength of Iron-Carbon Alloys at Elevated Temperatures," Transactions of ASM, Vol. 60, 1967, pp. 205-210.
9. Sellars, C. M., and Tegart, W. J. McG., "A Relation entre la Résistance et la Structure dans la Déformation à Chaud," Mémoires Scientifiques Rev. Metallurg., Vol. 58, No. 9, 1966, pp. 731-746.
10. Hodgkiss, F. A., "A Torsion Test for Use in Metalworking Studies," Journal of the Institute of Metals, Vol. 91, 1962-63, pp. 267-273.
11. Glover, G. and Sellars, C. M., "Recovery and Recrystallization During High Temperature Deformation of α -Iron," Metallurgical Transactions, Vol. 4, March 1973, pp. 765-775.
12. Alder, J. F. and Phillips, V. A., "The Effect of Strain Rate and Temperature on the Resistance of Aluminum, Copper, and Steel to Compression," Journal of the Institute of Metals, Vol. 53, 1954-55, pp. 80-86.
13. Cook, P. M., "True Stress-Strain Curves for Steel in Compression at High Temperatures and Strain Rates, For Application to the Calculation of Load and Torque in Hot Rolling," Proceedings of Conference on Properties of Materials at High Rates of Strain, Institution of Mech. Engineers, London, 1957, pp. 86-97.
14. English, A. T. and Backofen, W. A., "Recrystallization in Hot-Worked Silicon-Iron," Transactions of the Metallurgical Society of AIME, Vol. 230, April 1964, pp. 396-407.
15. Younger, A. and Cockcroft, M. G., "The Warm Working of Armo Iron," Metal Treatment and Drop Forging, Vol. 31, August 1964, pp. 296-306.
16. Ivry, J. L. and Jones, J. J., "Hot Compression of Armo Iron and Silicon Steel," Transactions of the Metallurgical Society of AIME, Vol. 242, August 1968, pp. 1619-1626.
17. Samanta, S. K., "The Dynamic Compression Testing of Steels at Elevated Temperatures," Advances in Machine Tool Design and Research 1970, Pergamon Press, Oxford, 1970, pp. 827-853.
18. Miller, T., "The Visco-Plastic Dynamic Behaviour of Iron and Nickel at Elevated Temperatures," Acta Metallurgica, Vol. 19, July 1971, pp. 691-699.
19. Imatigson, J-P., and Jones, J. J., "Flow Stress and Structural Change During the Transient Deformation of Armo Iron and Silicon Steel," Acta Metallurgica, Vol. 19, October 1971, pp. 1053-1061.
20. Imatigson, J-P., and Jones, J. J., "The Deformation of Armo Iron and Silicon Steel in the Vicinity of the Critical Temperature," Acta Metallurgica, Vol. 22, October 1974, pp. 1235-1247.
21. Douglas, J. R. and Allen, T., "Flow Stress Determination for Metals at Forging Rates and Temperatures," Transactions of the ASME, Vol. 97, February 1975, pp. 66-76.
22. The Forgeability of Steels, The Timken Roller Bearing Company, Third Edition, Canton, Ohio.
23. Stewart, M. J., "Constant True Strain Rate Compression: The Cam Plastometer," Canadian Metallurgical Quarterly, Vol. 13,

- No. 3, July-Sept. 1974, pp. 503-509.
24. Suzuki, H., Hashizume, S., Yabuki, Y., Ichihara, Y., Nakajima, S., and Kamochi, K., "Studies of the Flow Stress of Pearls and Alloys," *ET of the Institute of Industrial Science, The University of Tokyo*, Vol. 18, No. 3, March 1968.
 25. Jonas, J. J., Sellars, C. M., and Tegart, W. J. McG., "Strength and Structure under Hot-Working Conditions," *Metallurgical Reviews*, Vol. 14, 1969, pp. 1-24.
 26. Luton, M. J. and Sellars, C. M., "Dynamic Recrystallization in Nickel and Nickel-Iron Alloys During High Temperature Deformation," *Acta Metallurgica*, Vol. 17, August 1969, pp. 1033-1043.
 27. Robbins, J. I., Shepard, O. C., and Shethy, O. D., "Accelerated Spheroidization of Eutectoid Steels by Concurrent Deformation," *Journal of the Iron and Steel Institute*, Vol. 202, October 1964, pp. 804-807.
 28. Pagetson, B. and Pineau, A., "Acceleration of Pearlite Spheroidization by Thermomechanical Treatment," *Journal of the Iron and Steel Institute*, Vol. 209, December 1971, pp. 991-998.






FIG. 3. True-stress true-strain curves for Steel 3.




FIG. 4. True-stress true-strain curves for Steel 4.




FIG. 5. True-stress true-strain curves for Steel 5.




Fig. 6. True-stress true-strain curves for Steel 6.




Fig. 7. Microstructure of Steel 2 deformed at 1290°F showing the elongated ferrite grains. 160X.




Fig. 8. True-stress true-strain curves for Steel 4 at 1830°F for the strain rates shown.






Fig. 9. Microstructure of Steel 2 deformed at 1290°F and 2 s^{-1} strain rate showing the spheroidized structure, 2000X.



Fig. 10. True-stress true-strain curves at 1290°F and 20 s^{-1} strain rate for the various carbon levels.







Fig. 11. The peak stress versus temperature for a 2×10^{-3} strain rate for Steels 1, 3 and 5.

Fig. 12. Microstructure of Steel 3 deformed at 1470°F in the ferrite plus austenite region showing the mixed grain size.






Fig. 13. The peak and steady-state stresses at various temperatures versus the carbon level.

Oral Discussion to the Paper by Stewart

M. J. Luton, McGill University: I would like to ask about the shape of the flow curves which you showed for deformation in the ferrite region. They seemed to indicate that at the higher strain rates, such as above 2 S^{-1} and going up to your very high rates, that you did get a steady-state flow region up to about 0.5 strain. The question is, were those curves compensated in some way for adiabatic heating, or, if they weren't, do you think that the fact that you reach an apparent steady-state flow could be due to adiabatic heating?

M. J. Stewart (author's reply): I think you've made a very valid point on that. I think it's very dependent on the actual strain rate. At the higher strain rate, it is probably more of an apparent steady state. The steady state would probably not be reached in those cases until higher strain because of the increase in temperature as you go along.

Luton: The reason I brought it up is that in the low-carbon steels we looked at in the alpha-plus-gamma region, we found that we did not get a true steady state until we were beyond 0.8 true strain. Our strain rates were sufficiently low that we did not get adiabatic heating. This would suggest that one would expect that the strain to reach the steady state would be much higher at higher strain rates.

Stewart: Up to 20 S^{-1} strain rate, I don't think it's too significant. When you get up to 140 S^{-1} , the temperature rises very rapidly, so it must have an effect on it.

A. T. Davenport, Republic Steel Research Center: You showed that carbon content had a strong effect upon your flow stress. You mentioned that when the pearlite was spheroidized, it also showed a strong effect upon the flow stress. How do you rationalize that effect with the understanding which we have, that at room temperature the pearlite, particularly up to about 0.28 C level, has a very small, if any, effect upon yield strength?

Stewart: I'm not sure I agree with that. I do observe a rapid increase in flow stress, even at the low carbon levels. Whatever the significance, I observe that. I thought that in low-carbon steels the pearlite increased the flow stress.

W. J. McG. Tegart, BHP: You've got a fairly wide range of rates and temperatures in the austenite. Is it possible to put your data in a parametric equation in terms of strength as a function of strain rate, temperature, and strain?

Stewart: I have done some of this, and it does seem possible to achieve a good fit. I have not really carried this very far, but it might be useful to do so.