

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

LEONES CONTINI JÚNIOR

**MODELAGEM DE CURVAS DE FLUXO PLÁSTICO
DE UM AÇO BIFÁSICO UTILIZANDO INTELIGÊNCIA
ARTIFICIAL**

SÃO CARLOS - SP
2022

LEONES CONTINI JUNIOR

MODELAGEM DE CURVAS DE FLUXO PLÁSTICO DE UM AÇO BIFÁSICO
UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de São Carlos para obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Oscar Balancin

São Carlos - SP
2022



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Engenharia Mecânica

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Leones Contini Junior, realizada em 21/01/2022.

Comissão Julgadora:

Prof. Dr. Oscar Balancin (UFSCar)

Prof. Dr. Jose Benaque Rubert (UFSCar)

Prof. Dr. José Benedito Marcomini (USP)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) - Código de Financiamento 001.
O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Mecânica.

DEDICATÓRIA

A minha esposa Silvia e aos meus filhos Mariana e Leonardo.

AGRADECIMENTO

Gostaria de agradecer em primeiro lugar a Deus, por me conceder saúde e sabedoria para seguir sempre em frente.

Aos meus pais, Darcy e Leones (*in memoriam*), pela minha vida e pelo apoio na minha formação intelectual, com a qual consegui chegar até aqui.

Ao meu orientador Prof. Dr. Oscar Balancin, pela oportunidade e todos os conhecimentos compartilhados.

Aos meus colegas e professores da Pós-Graduação em Engenharia Mecânica da UFSCAR, em especial ao professor e coordenador Prof. Dr.-Ing. Carlos Eiji Hirata Ventura, pela amizade e ensinamentos.

Agradeço a CAPES pelo apoio a este trabalho.

“A menos que modifiquemos à nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo”. (Albert Einstein)

RESUMO

Os dados utilizados para o desenvolvimento deste trabalho foram obtidos a partir de uma pesquisa anterior, em que amostras de um aço inoxidável super duplex com matriz ferrítica e partículas dispersas de austenita foram deformadas com ensaios de torção nas temperaturas de 900°C a 1200°C com taxas de deformação variando de 0,01 s⁻¹ a 10 s⁻¹. Os resultados desses experimentos foram apresentados na forma de curvas de escoamento plástico com temperatura e taxa de deformação constantes. As formas das curvas dependem da temperatura e da taxa de deformação e variam com a fração volumétrica de austenita, uma vez que em materiais bifásicos o fluxo plástico é mais complexo que em materiais monofásicos. Utilizou-se os dados deste ensaio para construir uma planilha com quatro colunas. As três primeiras colunas contêm os atributos de entrada (temperatura, taxa de deformação e deformação) e a quarta a resistência imposta pelo material ao ser deformado (tensão). Esses dados foram submetidos a dois algoritmos de aprendizagem de máquina, sendo um constituído de uma rede neural rasa (RNA) e outro de uma rede neural com um sistema especialista (ANFIS). Após o processo de aprendizagem de máquina, as curvas de escoamento plástico foram reconstruídas e comparadas com as obtidas experimentalmente. Foi feita a predição de curvas em condições não medidas experimentalmente e discutem-se os resultados obtidos. A capacidade de ambos os algoritmos de reconstruir as curvas de fluxo plástico do aço inoxidável super duplex foram associadas a mudanças nas formas das curvas de fluxo e evolução da microestrutura.

Palavras-chave: Conformação. Rede Neural. Fuzzy. Modelo.

ABSTRACT

The data used for the development of this work were obtained from previous research, in which samples of a super duplex stainless steel with ferritic matrix and dispersed austenite particles were deformed with torsion tests at temperatures from 900°C to 1200°C with strain rates ranging from 0.01 s⁻¹ to 10 s⁻¹. The results of these experiments were presented in the form of plastic flow curves with constant temperature and strain rate. The shapes of the curves depend on temperature and strain rate and vary with the volumetric fraction of austenite, since in two-phase materials the plastic flow is more complex than in single-phase materials. Data from this trial were used to build a spreadsheet with four columns. The first three columns contain the input attributes (temperature, strain rate and strain) and the fourth the resistance imposed by the material when deformed (stress). These data were submitted to two machine learning algorithms, one consisting of a shallow neural network (ANN) and the other of a neural network with an expert system (ANFIS). After the machine learning process, the plastic flow curves were reconstructed and compared with those obtained experimentally. Curves were predicted under conditions not measured experimentally and the results obtained are discussed. The ability of both algorithms to reconstruct the plastic flow curves of super duplex stainless steel was associated with changes in the shape of the flow curves and microstructure evolution.

Keywords: *Forming. Neural Network. Fuzzy. Model.*

LISTA DE FIGURAS

Figura 1	Microestrutura típica de um aço inoxidável duplex.....	17
Figura 2	Curvas de escoamento plástico (a) para o aço 0,25% C a 1100°C e (b) para o Ferro-Armco a uma taxa de deformação de 0,0015 s ⁻¹	19
Figura 3	Curva de tensão versus deformação de um material que se recupera dinamicamente.....	20
Figura 4	Curva de escoamento típica de materiais que sofrem recristalização dinâmica.....	21
Figura 5	Variações encontradas de acordo com os ensaios realizados de curvas tensão vs. deformação.....	24
Figura 6	Representação esquemática da arquitetura de rede com uma camada oculta.....	26
Figura 7	Modelo de um neurônio artificial.....	27
Figura 8	Modelo de Métodos de Defuzzyficação.....	29
Figura 9	Representação esquemática da arquitetura de rede da ANFIS.....	30
Figura 10	Estado de tensões observado na região central do corpo de prova submetido à torção.....	32
Figura 11	Região útil da amostra submetida a um esforço de torção. (a) Antes da aplicação do esforço e (b) depois de aplicado o momento torsor.	32
Figura 12	Curvas de escoamento plástico obtidas nos ensaios de torção a quente do aço inoxidável duplex.....	34
Figura 13	Curvas de escoamento plástico obtidas experimentalmente mostrando apenas as regiões de deformação plástica.....	45
Figura 14	Evolução do RMSE com o número de neurônios na camada escondida (a) e evolução do RMSE com a evolução do processo de aprendizagem de máquina (b).....	47
Figura 15	Curvas de escoamento plástico calculadas com a RNA juntamente com as respectivas curvas experimentais.....	48
Figura 16	Curvas relacionando os dados experimentais com os dados de saída da RNA. Nestes diagramas utilizaram-se os dados normalizados.....	49
Figura 17	Evolução do RMSE com a arquitetura da ANFIS.....	53
Figura 18	Resultados do processo de aprendizado de máquina com modelagem ANFIS.....	55
Figura 19	Valores previstos para a tensão em 950°C, 1050°C e 1150°C com taxa de deformação igual a 1s ⁻¹	56
Figura 20	Dependência da tensão, com a temperatura e taxa de deformação em log para uma deformação igual a 0,5.....	57

LISTA DE TABELAS

Tabela 1	Composição química de aço inoxidável duplex.....	18
Tabela 2	Variações da fração volumétrica em (em %) de austenita nos aços A e B em função da temperatura de reaquecimento.....	23
Tabela 3	Composição química do aço UNS S32760 (% em massa).....	31
Tabela 4	Vinte primeiros pontos de dados obtidos com taxa de deformação de $0,01s^{-1}$	35
Tabela 5	Valores de parâmetros estatísticos determinados a partir do processo de aprendizagem.....	50
Tabela 6	Evolução dos índices de avaliação em função dos tipos e números de funções de pertinência.....	51
Tabela 7	Valores de parâmetros estatísticos determinados a partir do processo aprendizagem.....	56

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVO	16
3	REVISÃO DA LITERATURA	16
3.1	AÇOS INOXIDÁVEIS DUPLEX	16
3.2	O PROCESSO DE DEFORMAÇÃO A QUENTE	18
3.3	MUDANÇAS MICROESTRUTURAIS DURANTE O PROCESSO DE DEFORMAÇÃO.	20
3.4	DEFORMAÇÃO PLÁSTICA DE AÇOS INOXIDÁVEIS.....	22
3.5	REDE NEURAL ARTIFICIAL: INTELIGÊNCIA ARTIFICIAL.....	24
3.5.1	Sistema de Inferência Fuzzy Baseado em Rede Adaptativa	28
4	MATERIAIS E MÉTODOS	31
4.1	MATERIAL	31
4.2	ENSAIOS MECÂNICOS.....	31
4.3	PREPARAÇÃO DOS DADOS	34
4.4	MODELAGEM UTILIZANDO UMA REDE NEURAL ARTIFICIAL	36
4.5	MODELAGEM UTILIZANDO UMA ANFIS	40
5	RESULTADOS E DISCUSSÃO	45
5.1	CURVAS DE ESCOAMENTO PLÁSTICO	45
5.2	MODELAGEM COM REDE NEURAL ARTIFICIAL	46
5.3	MODELAGEM COM ANFIS	50
6	CONCLUSÕES	59
	REFERÊNCIAS	61

1. INTRODUÇÃO

Atualmente, estão ocorrendo transformações nos meios de produção industrial para substituir as operações manuais ou mecanizadas por procedimentos robóticos controlados por inteligência artificial (IA) (ZHONG et al., 2017; BRANCA et al., 2020). Modelos matemáticos com diferentes arquiteturas computacionais estão sendo formulados para calcular com precisão os parâmetros operacionais. Valores de parâmetros como a posição da peça que está sendo deformada durante o processamento metalúrgico a quente, velocidade de deslocamento das ferramentas e temperatura da peça podem ser capturados com boa precisão por sensores inseridos nas máquinas e transferidos para programas de computador através da internet das coisas (IoT). No entanto, o comportamento plástico dos materiais não pode ser determinado diretamente nos meios de produção.

Normalmente, o comportamento plástico à quente de materiais metálicos é determinado em escala de laboratório na forma de curvas de tensão de fluxo plástico (LOURENÇO et al., 2001; EL-SHENAWY, 2020), e modelos constitutivos são estabelecidos para caracterizar o comportamento de deformação em alta temperatura de metais e ligas.

Para estabelecer relações constitutivas entre tensão, deformação, taxa de deformação e temperatura diferentes abordagens foram desenvolvidas (LIN; CHEN, 2011). Algumas delas são modelos fenomenológicos, em que um modelo empírico como uma representação matemática é usado para descrever a correlação entre os parâmetros plásticos sob uma ampla gama de condições de trabalho. A modelagem das curvas de tensão de fluxo pode ser realizada após a determinação dos parâmetros da equação constitutiva, levando-se em consideração que eles são dependentes de deformação. Este procedimento tem sido aplicado para diferentes materiais com bom desempenho (KINGKLANG; UTHAISANGSUK, 2016; LIN et al., 2014).

Por enquanto, é bem conhecido que os aços inoxidáveis ferríticos monofásicos amolecem por intensa recuperação durante a deformação (LONGFEI; WANGYUE; ZUING, 1994; CASTAN; MONTHEILLET; PERLADE, 2013) enquanto os de austenita monofásica, com energias de falha de empilhamento relativamente baixas, amolecem por recristalização dinâmica, após alguma quantidade de endurecimento e recuperação dinâmica (DEHGHAN-MANSHADI; HODGSON, 2008; BELADI; CIZEK; HODGSON, 2010). Nestes aços inoxidáveis ferríticos monofásicos quando a

deformação é conduzida com temperatura e taxa de deformação constantes, a tensão de fluxo aumenta no regime de endurecimento por trabalho inicial e depois torna-se constante na fase de ferrita; em contraste, a tensão atinge um máximo antes de diminuir para um estado estacionário na fase de austenita (JORGE JR.; REGONE; BALANCIN, 2003). Materiais como esses, que possuem comportamentos plásticos bem conhecidos e parametrizados, permitem a aplicação de modelos fenomenológicos - equilíbrio entre a geração e aniquilação de discordâncias e/ou a equação de Avrami - para descrever matematicamente seu comportamento.

No entanto, existem materiais que têm um comportamento plástico mais complexo, como ligas de duas fases, como os aços inoxidáveis duplex. Sob condições de processamento a quente, os aços inoxidáveis duplex ferrítico-austeníticos consistem em partículas de austenita embutidas em uma matriz de ferrita. Quando as duas fases são deformadas juntas, a diferença marcante no comportamento de amolecimento da austenita e da ferrita leva à partição de deformação desigual entre essas fases, e a distribuição desta não é mais uniforme, com concentração inicial na fase alfa mais macia. Neste estágio, a deformação é principalmente acomodada pela fase mais macia e a recuperação dinâmica na ferrita é acelerada com um aumento gradual na desorientação entre os subgrãos vizinhos (CIZEK; WYNNE, 1997) e gradualmente convertida em contornos de alto ângulo através da absorção contínua de discordâncias (HAGHDADI et al., 2017).

Em deformação maior, a carga é transferida para a austenita, dando origem ao acúmulo de discordâncias até o início do DRX. No entanto, devido à limitação no número de contornos de austenita/austenita e à deformação limitada transferida para a austenita, a evolução da DRX na austenita é marcadamente suprimida (IZA-MENDIA et al., 1998; PINOL-JUEZ; IZA-MENDIA; GUTIÉRREZ, 2000). Como consequência, dependendo dos mecanismos que controlam a deformação plástica, a curva de tensão de fluxo assume diferentes formas (JORGE JUNIOR; REIS; BALANCIN, 2011).

Além dos mecanismos de endurecimento e de amaciamento que atuam em cada uma das fases constituintes e da partição de deformações, o comportamento plástico do aço inoxidável bifásico depende da fração volumétrica, distribuição e morfologia da austenita na matriz de ferrita e da natureza da interface entre estas fases. A fração volumétrica da austenita depende da temperatura de deformação, aumentando à medida que a temperatura diminui (JORGE JUNIOR; REIS;

BALANCIN, 2011; PATRA et al., 2016). Durante a deformação, os gradientes de deformação e o fluxo de tensões também podem ser alterados pela ação de mecanismos como o cisalhamento local ou deslizamento na fronteira da interfase (IZA-MENDIA et al., 1998) e a mudança da coerência entre a interface austenita e ferrita (BALANCIN; HOFFMANN; JONAS, 2012, JORGE JUNIOR; REIS; BALANCIN, 2011). Após alguma deformação, com a transferência de tensão para a fase austenítica, pode ocorrer fragmentação dessas partículas. Conseqüentemente, a construção de modelos constitutivos de base física para descrever o comportamento plástico desses materiais necessita de mais investigações.

Avanços recentes em processos de aprendizado de máquina geraram uma alternativa realista para modelar as curvas de tensão de fluxo plástico de metais e ligas usando técnicas de redes neurais artificiais (RNA). A RNA pode aprender com exemplos e reconhecer caminhos em uma série de dados de entradas e saídas sem qualquer conhecimento prévio de sua natureza e inter-relações. Este método tem sido aplicado para diferentes materiais com bom desempenho (REDDY et al., 2013; KUMAR; KARMAKAR; NATH, 2020). Além disso, um tipo de técnica de inteligência artificial combinando redes neurais e as capacidades de aprendizagem do sistema de inferência de lógica difusa (lógica *fuzzy*) pode ser usado para estabelecer relações de mapeamento precisas entre dados de entrada e saída (JANG, 2013).

Os sistemas *fuzzy* utilizam um método matemático para introduzir o conhecimento humano subjetivo nos processos reais. O *Adaptive Neural Fuzzy Inference System* (ANFIS) tem sido aplicado para diferentes materiais com bom desempenho (CHEN et al., 2017; VAFAEENEZHAD et al., 2016). Algumas dessas pesquisas comparam a aptidão atingida por IA com aquela obtida com modelos fenomenológicos (HAGHDADI et al., 2013; HAN et al., 2013, KUMAR; KARMAKAR; NATH, 2020] e outras com os modelos constitutivos de base física (CHEN et al., 2017). Independentemente do tipo de modelo utilizado, os dados obtidos indicaram melhor *ajuste* com IA. Uma vez que esses algoritmos não postulam nenhuma expressão matemática específica e podem ser facilmente estabelecidos com base em dados experimentais, o presente trabalho tem como objetivo avaliar uma possível modelagem das curvas de deformação plástica e prever o comportamento da deformação em alta temperatura do aço inoxidável super duplex sem considerar a evolução da fração de volume de austenita com a temperatura em declínio.

2. OBJETIVO

Este trabalho tem como objetivo obter um modelo matemático que gere curvas de escoamento plástico semelhantes e bem próximas às curvas experimentais de um material em que os mecanismos plásticos que atuam durante a deformação não são totalmente conhecidos.

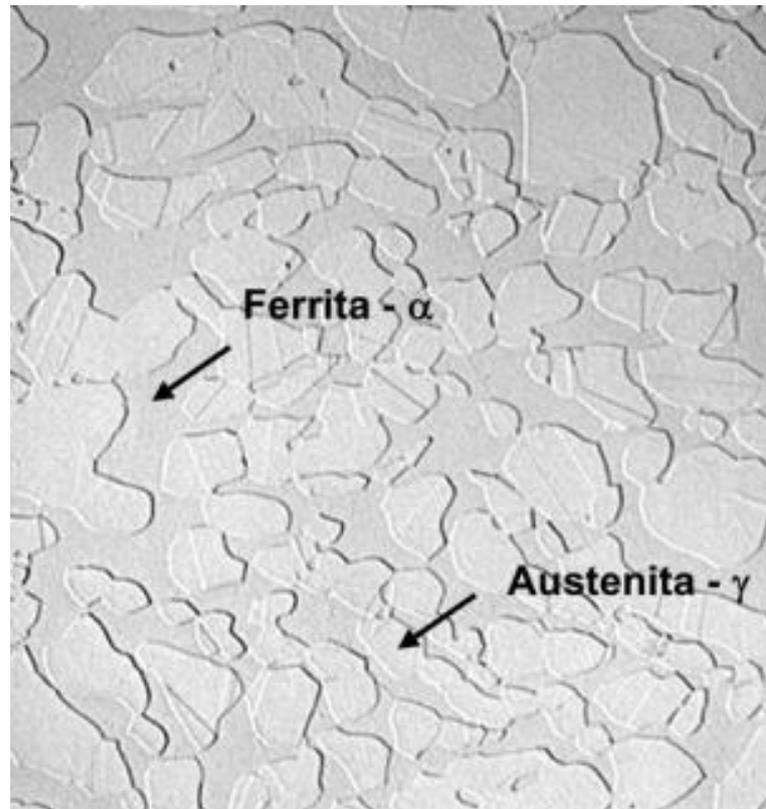
3. REVISÃO DA LITERATURA

3.1. AÇOS INOXIDÁVEIS DUPLEX

O aço inoxidável duplex originou-se na década de 30 na França, e desde então várias patentes foram concedidas após o desenvolvimento de diferentes ligas de aços inoxidáveis duplex. Por exemplo, em 1937 materiais denominados “Novas Ligas” foram patenteados após descoberta de que adição de cobre como elemento de liga aumentava a resistência à corrosão destes materiais quando expostos a um meio agressivo (KAHAR, 2017).

Os aços inoxidáveis duplex apresentam uma microestrutura laminada, policristalina, composta por 35-55% de matrix ferrítica e 45-65% de ilhas de austenita (Figura 1). O equilíbrio de frações volumétricas de austenita e ferrita, próximo de 50% das fases, resulta em um comportamento intermediário entre os aços austeníticos e ferríticos, em que as propriedades mecânicas dos aços inoxidáveis duplex se caracterizam pela combinação do alto valor de alongamento da austenita com o elevado limite de escoamento da matrix ferrítica, resistência à corrosão, além de boa tenacidade e ductilidade (SENATORE et al., 2007).

Figura 1. Microestrutura típica de um aço inoxidável duplex.



Fonte: Senatore et al. (2007).

Os aços inoxidáveis duplex são constituídos por baixos teores de carbono, quantidades significativas de cromo (18-27%), níquel (4-7%), molibdênio (0-4%), além de silício, manganês e nitrogênio em concentrações menores. Níquel, carbono e nitrogênio são tidos como elementos de liga estabilizadores da austenita (gama gênicos) enquanto cromo, molibdênio e silício são caracterizados como elementos estabilizadores da ferrita (alfagênicos) (SENATORE et al., 2007). A variação no teor dos elementos de liga que compõem os aços inoxidáveis duplex permite separá-los em aço inoxidável duplex de baixa liga, aços inoxidáveis duplex de média liga, aços inoxidáveis de alta liga (super duplex) e aços inoxidáveis de hiper liga (KAHAR, 2017).

Organizações internacionais de normatização como a *American Society for Testing and Materials* (ASTM), *Society of Automotive Engineers* (SAE) e a *American Iron Steel Institute* (AISI) desenvolveram um sistema de numeração *Unified Numbering System* (UNS), visando correlacionar a composição química dos aços inoxidáveis com suas respectivas propriedades mecânicas. A Tabela 1 mostra a

divisão das quatro classes de aços inoxidáveis duplex de acordo com a composição de alguns de seus principais elementos de liga (KAHAR, 2017).

Tabela 1. Composição química de aço inoxidável duplex.

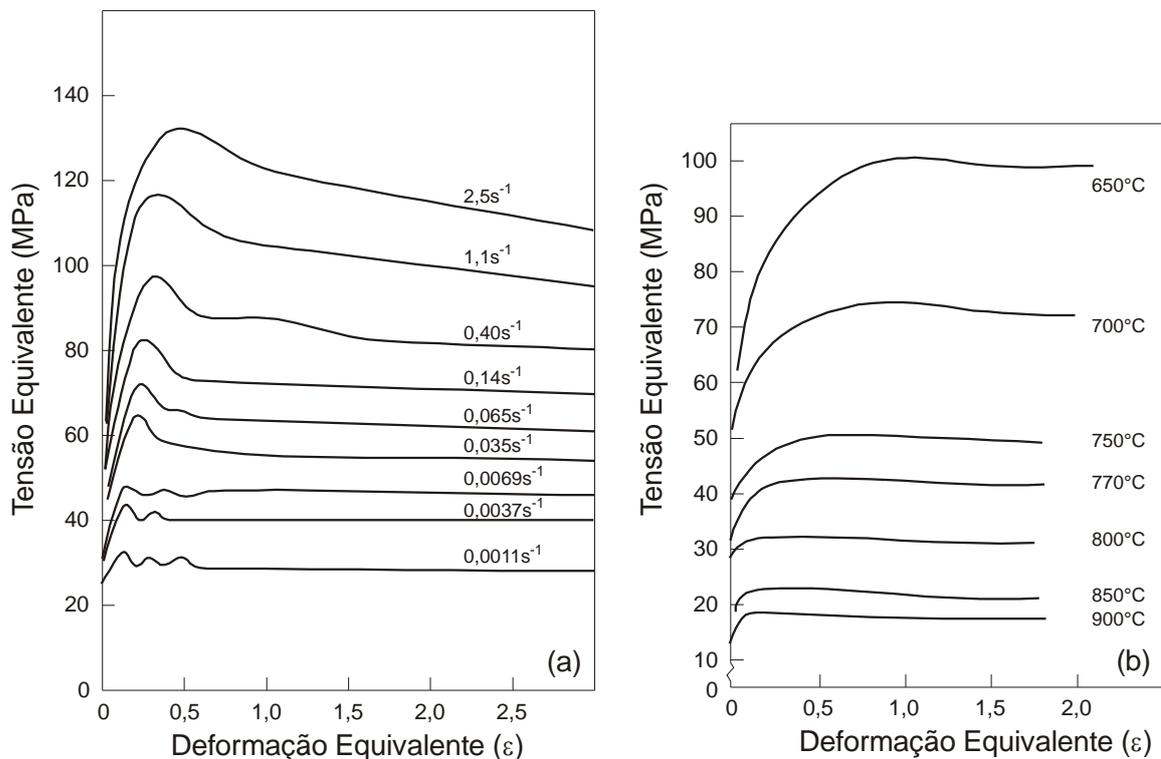
Tipo	UNS	Cr %	Ni %	Mo %	N₂ %
Baixa liga	S 32304	20-24	1-5	0,1-0,3	0,1-0,22
Média liga	S 31803	21-23	4,5-6	2,5-3,5	0,1-0,22
Super duplex	S 32750	24-29	4,5-8	2,7-4,5	0,1-0,35
Hiper duplex	S 32707	27	6,5	5	0,4

Fonte: Kahar (2017).

3.2. O PROCESSO DE DEFORMAÇÃO A QUENTE

Quando um material metálico é submetido a um processo metalúrgico de conformação à quente sua resistência mecânica está relacionada à tensão de escoamento plástica necessária para deformá-lo, a qual é apresentada pelo material nas condições de processamento, e seu comportamento durante a deformação dependerá da característica do material (microestrutura e composição química), das condições de deformação, ou seja, quantidade de deformação, taxa de deformação e temperatura, das características do processo (lubrificação, geometria da zona deformada e atrito) e das transformações que ocorrem durante o processo de deformação (transformações da microestrutura), constituída pela transformação de fase, precipitação, mecanismos de restauração e encruamento (AHLBLOM e SANDSTROM, 2013; ROUCOULES, 1992). A Figura 2 apresenta a influência das variações de temperatura, a uma dada taxa de deformação e o efeito de variações na taxa de deformação, a uma dada temperatura.

Figura 2. Curvas de escoamento plástico (a) para o aço 0,25% C a 1100°C e (b) para o Ferro-Armco a uma taxa de deformação de 0,0015 s⁻¹.



Fonte: Rossard e Blain (1958); Immarigeon e Jonas (1974).

No início do processo de deformação, a tensão atinge rapidamente seu valor máximo com o aumento da taxa de deformação e a diminuição da temperatura, até o momento em que a quantidade de tensão imposta não irá influenciar na deformação chegando a um valor estacionário.

O parâmetro de Zener-Hollomon (Z) estabelece uma relação entre a energia de ativação e a tensão aplicada, onde R é a constante universal dos gases, T é a temperatura, Q é a energia de ativação, $\dot{\epsilon}$ é a taxa de deformação, σ é a tensão aplicada e A , α e n são constantes do material, como pode ser visto na Equação 1 (ZENER; HOLLONON, 1944):

$$Z = \dot{\epsilon} \times \exp\left(\frac{Q}{RT}\right) = A \times \{\sinh \alpha \sigma\}^n \quad (1)$$

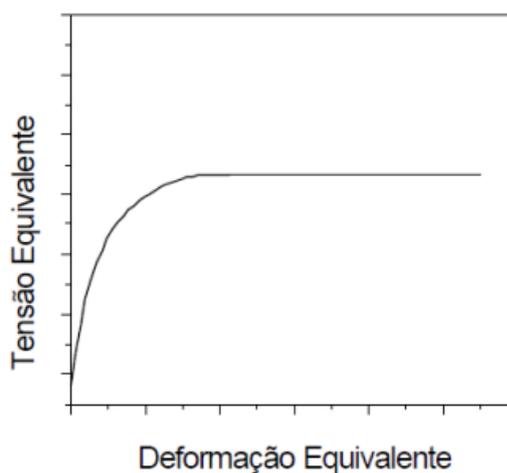
De acordo com Laasraqui e Jonas (1991) e El Wahabi, Cabrera e Prado (2003) esta relação indica o comportamento plástico de aços, e retrata as curvas de escoamento plástico para pequenas quantidades de deformação.

3.3. MUDANÇAS MICROESTRUTURAIS DURANTE O PROCESSO DE DEFORMAÇÃO.

Nos processos de conformação a quente, uma parte da energia gasta na deformação plástica de um material metálico, em altas temperaturas, é liberada na forma de calor e outra parte é armazenada devido à geração de discordâncias. No entanto, durante a deformação a quente, parâmetros de recuperação e recristalização (amaciamento) e de encruamento (endurecimento por deformação) podem ocorrer, simultaneamente, influenciando a resistência mecânica e a ductilidade do metal.

O endurecimento por deformação ocorre com o aumento da densidade das discordâncias, o qual é resultante dos mecanismos de escalagem e deslizamento cruzado, ocasionando o aumento da resistência mecânica do material metálico. No entanto, no mecanismo de recuperação tais discordâncias podem ser reorganizadas de forma que sua produção e eliminação atinjam um estado de equilíbrio (MCQUEEN; JONAS, 1976; MECKING; GOTTSTEIN, 1978). A Figura 3 representa um exemplo de curva de tensão e deformação de um material recuperado dinamicamente.

Figura 3. Curva de tensão versus deformação de um material que se recupera dinamicamente.

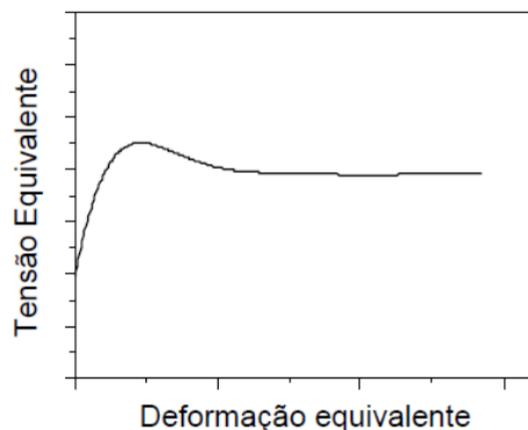


Fonte: Mcqueen (1976).

Conforme observado na figura acima, pequenas deformações no material ocorrem no início da tensão aplicada. Com o aumento da tensão tem-se o aumento da deformação, a qual torna-se constante ao alcançar o estado de equilíbrio entre a

formação e a aniquilação das discordâncias. Quando a quantidade de deformação for menor que o seu valor equivalente ao pico de tensão, tem o início o processo de recristalização, caracterizado pela nucleação e formação de novos grãos (ROBERTS; BODÉN; AHLBLOM, 1979; GOTTSTEIN; ZABARDJADI; MECKING, 1979). A Figura 4 representa a curva de escoamento plástico de materiais que sofrem recristalização dinâmica.

Figura 4 - Curva de escoamento típica de materiais que sofrem recristalização dinâmica.



Fonte: Mcqueen (1975).

Em relação à deformação e sua relação com a recuperação e a recristalização Gerônimo e Balancin (2013) afirmam que ambas podem ocorrer no amaciamento dinâmico de metais deformados, dependendo das características do material, como por exemplo a energia de falha de empilhamento e parâmetros do processo de conformação, como temperatura e taxa de deformação.

Nos casos em que a energia de falha de empilhamento é elevada, as discordâncias parciais podem se deslocar mais próximas umas das outras, e há um aumento da quantidade de discordâncias aniquiladas. Isto diminui a taxa de encruamento até o momento em que há uma igualdade entre a geração de discordâncias e a anulação delas (GERÔNIMO; BALACIN, 2013).

Para o caso de metais que apresentam baixos e médios valores de falha de empilhamento, essas mesmas discordâncias se movem mais distantes umas das

outras, dificultando o rearranjo e a aniquilação desses defeitos através do processo de recuperação.

Assim, os valores da taxa de aniquilação e geração de discordâncias diferem entre si, sendo que a taxa de geração se torna maior, o que aumenta a densidade de discordâncias e a energia que é armazenada pelo material. Esse processo ocorre até o limite em que é atingido um valor crítico para a ativação de mecanismos de nucleação e recristalização dinâmica (GERÔNIMO; BALACIN, 2013).

3.4. DEFORMAÇÃO PLÁSTICA DE AÇOS INOXIDÁVEIS

Nos aços ferríticos, onde a falha de empilhamento é de alta energia, mecanismos de escalagem e deslizamento cruzado facilitam o rearranjo e a eliminação das discordâncias, havendo poligonização de subgrãos. Já na austenita a energia de falha de empilhamento é baixa, dificultando a escalagem e deslizamento cruzado das discordâncias. Conseqüentemente, para que a recristalização dinâmica se inicie, o material deverá apresentar elevado valor de encruamento e aumento da densidade de discordâncias, as quais podem ser rapidamente eliminadas com a nucleação e crescimento dos novos grãos. Na deformação do ferro a uma temperatura de 800°C por laminação, o amaciamento da fase ferrítica ocorre por recuperação dinâmica nas deformações com reduções de até 80% (CIZEK; WYNNE, 1997; RIZHI; LEI, 1993).

Na ferrita, a recuperação dinâmica é o processo de amaciamento predominante, visto que os valores de tensão para deformar o material são reduzidos e a concentração de tensões nos contornos de grão é baixa resultando no aumento da ductilidade e redução na formação de trincas (BALANCIN, 2000; PINOL-JUEZ, 2000). No entanto, o mecanismo de recuperação dinâmica pode ser modificado para recristalização dinâmica sob influência do parâmetro de Zener-Hollomon (Z) Glover e Sellars (1973). Em um estudo realizado por Tsuji et al. (1998), utilizando ensaios de compressão a quente em aço inoxidável ferrítico, houve recristalização da microestrutura ferrítica em valores baixos do parâmetro Z. Em um trabalho realizado utilizando aço inoxidável ferrítico (26Cr-2Ni-2,9Mo), foi observado que a ferrita sofreu recristalização dinâmica, após grandes quantidades de deformação (JORGE JR., 1997).

Devido à sua microestrutura bifásica do aço inoxidável duplex, mudanças microestruturais são observadas durante o processamento metalúrgico, como por

exemplo a transformação da ferrita em austenita, ocasionada devido ao aumento da nucleação e crescimento de partículas de austenita (IZA-MENDIA et al., 1998; RICHARDS; SHEPPARD, 1986). Na deformação de aços inoxidáveis duplex, a fase ferrita é deformada inicialmente, até diminuição dos gradientes de deformações internos. Durante este processo, ocorrem transferências de tensões e de deformações da matriz para austenita, deslizamento de contornos de grãos, recuperação e recristalização dinâmicas (PINOL-JUEZ; IZA-MENDIA; GUTIÉRREZ, 2000). Consequentemente, diferentes formas de curva de escoamento plástico são observadas durante a deformação a quente de aços inoxidáveis duplex.

De acordo com Reis e Balancin (2008), após deformação, em torção, de dois tipos de aços inoxidáveis: aço A: 25,5Cr - 4,9Ni - 1,6Mo (Cr eq/Ni eq = 4,8) e aço B: 22,2Cr - 5,6Ni - 3Mo (Cr eq/Ni eq = 3,5), foi observado que tanto o material quanto as condições de deformação influenciam na forma da curva de escoamento plástico.

O aço A, em altas temperaturas, apresenta comportamento plástico característicos dos aços inoxidáveis ferríticos, onde na diminuição da temperatura de deformação é observado um pico de tensões, após pequenas deformações. Por outro lado, no aço B, quando as partículas de austenita estão dispersas grosseiramente dentro da matriz, observa-se um pico de tensão separando regiões que mostram aumento da tensão com a deformação (encruamento) diminuição da tensão com a deformação (amaciamento). Por outro lado, quando a microestrutura é constituída por proporções iguais de austenita e ferrita, a curva nos ensaios de torção a quente é bem característica (REIS; BALANCIN, 2008). A Tabela 2 apresenta as variações da fração volumétrica nos aços A e B.

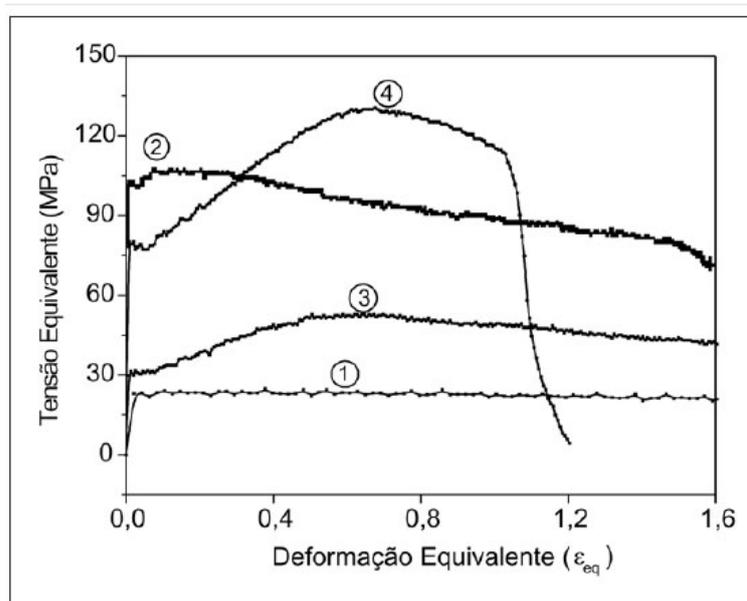
Tabela 2 - Variações da fração volumétrica em (em %) de austenita nos aços A e B em função da temperatura de reaquecimento.

	900°C	950°C	1000°C	1150°C	1100°C	1150°C	1200°C	1250°C
Aço A	38,8	19,9	14,3	9,4	5,2	2,4	1,3	<1,0
Aço B					53,3	46,5	41,4	39,6

Fonte: Reis e Balancin (2008).

A Figura 5 mostra as curvas de escoamento plástico, típicas de aço inoxidável dúplex, obtidas em ensaios de torção a quente. A curva 1 representa a amostra com microestrutura essencialmente ferrítica; a curva 2 representa a matriz ferrítica com partículas de austenita finamente dispersas; a curva 3 representa a matriz ferrítica com partículas de austenita grosseiramente dispersas; e a curva 4 representa a microestrutura dúplex.

Figura 5 - Variações encontradas de acordo com os ensaios realizados de curvas tensão vs. deformação.



Fonte: Reis e Balancin (2008).

3.5. REDE NEURAL ARTIFICIAL: INTELIGÊNCIA ARTIFICIAL

Após anos de estudos, pesquisadores criaram modelos empíricos e fenomenológicos utilizando expressões matemáticas, para reproduzir as condições de conformação plástica de metais observadas na prática, em diversas condições de tensão, deformação, taxa de deformação e temperatura (LIN; CHEN, 2011). Estas reações de condições de trabalho produziram dados que auxiliaram no desenvolvimento de modelos matemáticos para a deformação de trabalho a quente e, conseqüentemente, foi possível descrever a modelagem das curvas. Conclui-se,

portanto, que diversos parâmetros encontrados são dependentes da deformação (XIAO; GUO, 2011).

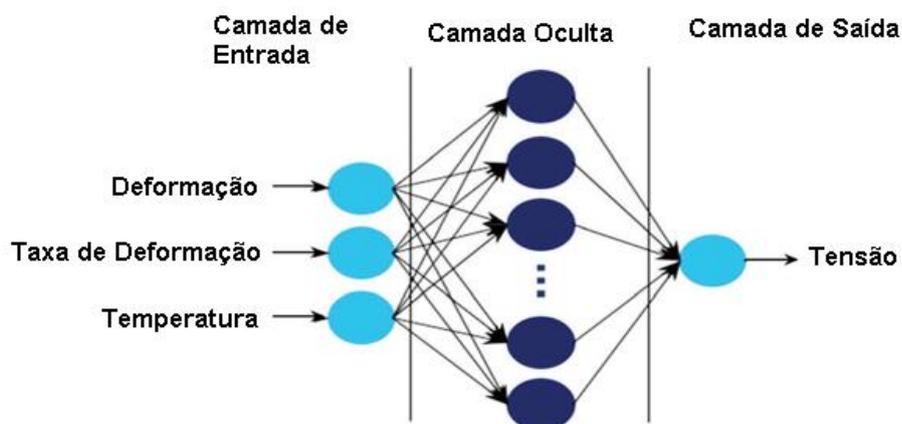
A literatura relata a utilização de diversos modelos constitutivos de base física, em diferentes materiais, os quais fornecem melhores condições para adequar mecanismos de deformação nestas extensas condições de trabalho a quente. Entre os parâmetros físicos utilizados na formação destes modelos estão o tamanho de grão e densidade de deslocamento. Desta forma, o crescimento da tensão de fluxo do material pode ser descrito baseando na sua microestrutura, mecanismos de endurecimento, amolecimento e movimento de contorno de grão (LAASRAOUI; JONAS, 1991; MEDINA; HERNANDEZ, 1996; JORGE JR; BALANCIN, 2005).

As pesquisas realizadas com materiais metálicos de comportamentos plásticos bem conhecidos e já parametrizados favorecem a utilização de modelos fenomenológicos que descrevem, matematicamente, o comportamento plástico dos materiais. Materiais nos quais este tipo de comportamento ainda não é conhecido faz-se necessário buscar novos caminhos para realização da modelagem destas curvas de conformação plásticas. A utilização de técnicas de inteligência artificial (IA) é uma das alternativas para obtenção destes dados (WANG, 2020).

No ramo da ciência da computação, a técnica de inteligência artificial (IA) possibilita a construção de algoritmos que podem ser aplicados no processamento de informações, utilizando dados que podem reproduzir a técnica de inteligência de seres vivos. Na interação destes dados, os algoritmos aprendem com os padrões e informações apresentados e tomando decisões para solução de problemas.

Dentre as tecnologias que compreendem a IA está a Rede Neural Artificial (RNA), estruturalmente, constituída de unidades interconectadas denominadas neurônios, responsável pelo processamento dos dados de entrada e difusão às unidades seguintes, até a obtenção da resposta desejada. Ou seja, um modelo matemático e/ou computacional constituído de um conjunto de neurônios artificiais interconectados, denominado “nós”, e agrupados em camadas projetadas como uma camada de entrada, camadas ocultas e camada de saída (Figura 6).

Figura 6 - Representação esquemática da arquitetura de rede com uma camada oculta.

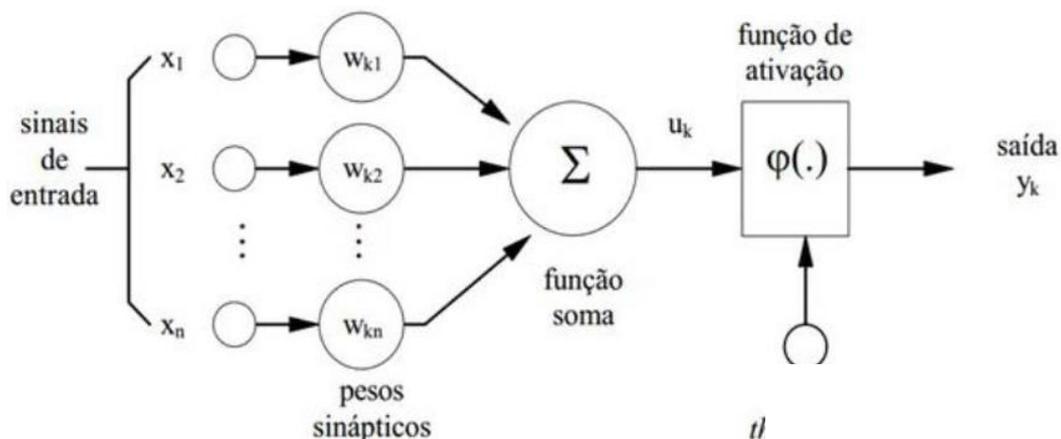


Fonte: Contini Jr e Balancin (2021).

A necessidade de criar modelos precisos de realidade estimulou a busca para o desenvolvimento de redes neurais artificiais (RNAs), capazes de modelar a dinâmica operacional de diversos sistemas. A vantagem da utilização das RNAs é que as mesmas podem ser aplicadas em tempo real, possuem boa tolerabilidade às falhas e capacidade de auto-adaptação, além de resolverem problemas práticos sem a necessidade de modelos precisos (HAYKIN, 2008).

Fundamental para a operação de redes neurais, um neurônio artificial é uma unidade de processamento de informação, constituído de conexões e pesos de entrada, de uma função de mapeamento e uma saída com estrutura, função, conexão e interatividade dos neurônios. A Figura 7 ilustra um modelo básico de um neurônio artificial.

Figura 7 - Modelo de um neurônio artificial.



Fonte: Haykin (2008).

De acordo com Haykin (2008), o modelo neural é constituído basicamente de conjuntos de sinapses, um somador e uma função de ativação. Os conjuntos de sinapses contêm pesos ou força própria, sendo que um sinal de entrada (x_j) da sinapse j que está conectado a um determinado neurônio k deve ser multiplicado pelo seu peso sináptico w_{kj} , sendo que o primeiro índice faz referência ao neurônio e o segundo à entrada da sinapse. O referido autor destaca que, diferentemente da sinapse do cérebro humano, o valor do peso sináptico de neurônios artificiais pode assumir valores positivos e negativos. O somador possui a função de somar os sinais de entrada, que estão ponderados pelas sinapses do neurônio, e a função de ativação restringe a amplitude de saída do neurônio a um valor finito, tipicamente descrito como um intervalo $[0,1]$ ou $[-1,1]$ (HAYKIN, 2008).

Pesquisas em inteligência artificial buscam aprender e modelar o comportamento do cérebro, através de sistemas especialistas, redes neurais e sistemas de lógica *Fuzzy*. A lógica *Fuzzy* surgiu com a necessidade de obter uma abordagem quantitativa a partir da representação qualitativa do raciocínio baseado em regra, resultando na quantificação dos qualificadores aproximadamente, frequentemente, raramente, vários, poucos e muitos (HAYKIN, 2008).

Relações de mapeamento precisas entre dados de entrada e saída podem ser estabelecidas utilizando técnicas de inteligência artificiais combinando redes neurais e as capacidades de aprendizagem do sistema de inferência de lógica difusa – ANFIS,

do inglês, *Adaptative Neuro - Fuzzy Inference System*. O conhecimento humano nos processos reais é introduzido através de um método matemático presente nos sistemas *fuzzy*, e a rede ANFIS combina o raciocínio da lógica *fuzzy*, por meio da representação do conhecimento humano e habilidades de explicação, e as capacidades de aprendizagem das RNA (NEGNEVITSKY, 2005).

De acordo com Sumathi e Surekha (2010), para treinar um modelo de rede neural utiliza-se o processo de *feed-forward* o qual permite ajustar os pesos associados a cada conexão entre os neurônios, onde cada entrada se conecta ao longo da rede até a próxima camada final de neurônios, na camada de saída na qual o valor gerado é então comparado com o valor real (alvo). A diferença entre o valor experimental e o calculado é determinado e, em seguida, os pesos da rede são ajustados através do algoritmo de retro propagação, de maneira que o valor de saída calculado fique próximo ao valor alvo.

3.5.1 Sistema de Inferência Fuzzy Baseado em Rede Adaptativa

Em uma RNA o número de informações a serem trabalhadas são de grande importância para o processo de aprendizado de máquina e na obtenção de resultados. A lógica *fuzzy* é usualmente utilizada em redes neurais para permitir o aprendizado de máquina em casos em que não há quantidade de dados suficientes, pois concedem uma forma simples e razoável de interpolação, com muito menos dados e dados inexatos (GOMIDE; GUDWIN; TANSCHHEIT, 2015).

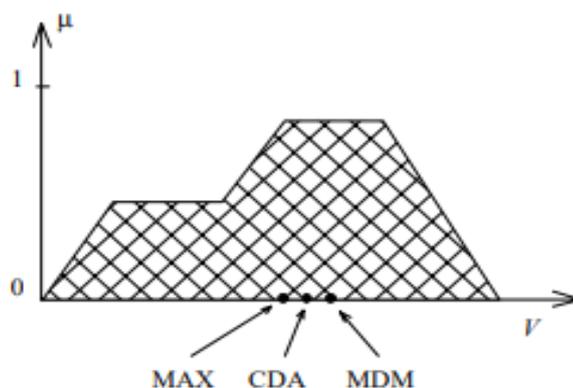
A Lógica *Fuzzy* ou Lógica Nebulosa é uma lógica que contém tipos de raciocínio que não são exatos. Possui um sistema de modelagem com técnicas adequadas capazes de tratar de forma precisa informações qualitativas, e apresenta uma abordagem diferente para métodos de controle de processo, em que são utilizados modelagem matemática para derivar ações de controle como função (GOMIDE; GUDWIN; TANSCHHEIT, 2015).

Os sistemas *fuzzy* tem como objetivo modelar conceitos vagos ou imprecisos que surgem na linguagem natural, sendo capaz de introduzir o conhecimento humano subjetivo transformando números em conjuntos *fuzzy*, tornando-os instâncias de variáveis linguísticas. De acordo com Gomide, Gudwin e Tanscheit (2015), a base de conhecimento do sistema *fuzzy* consiste de regras que caracterizam uma estratégia de controle juntamente com suas respectivas metas. Uma base de dados pode armazenar definições referentes à discretização e normalização de universos de

discursos, às funções de pertinência e partições de espaços de entrada e saída. A inferência analisa os dados de entrada para então definir as ações de controle, através da aplicação de um operador *fuzzy* e de regras de inferência da lógica *fuzzy*. A chamada interface de “defuzzyficação” transforma as ações de controle *fuzzy* em ações não-fuzzy, e após este passo é realizado um escalonamento para que os valores normalizados advindos da etapa anterior possam ser contabilizados com valores dos universos de discurso das variáveis.

Após a inferência é realizada uma ação de controle não-fuzzy e que represente da melhor maneira possível a decisão *fuzzy*, para posteriormente ser enviada ao controle. As estratégias de defuzzyficação mais comuns são o critério de máximo (MAX), que se baseia na escolha do ponto onde a função inferida possui valor máximo, a média de todos os pontos de máximos (MDM), que é calculada na situação onde existem vários pontos de máximo, e o método do centro de área (CDA), que calcula o centro da área da função inferida. A Figura 8 apresenta um modelo de Métodos de Defuzzyficação, onde MAX é o critério do máximo MDM é a média dos máximos e CDA é o centro de área (GOMIDE; GUDWIN; TANSCHHEIT, 2015).

Figura 8 - Modelo de Métodos de Defuzzyficação.

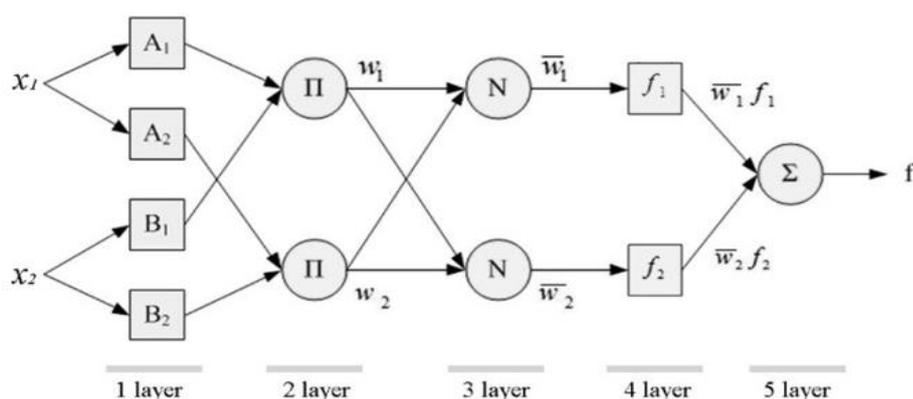


Fonte: Gomide, Gudwin e Tanscheit (2015).

A Lógica Difusa combinada com a RNA produz sistema de inferência difuso, FIS (*Fuzzy Inference System*), baseado em rede adaptativa ANFIS (*Adaptive Neural Fuzzy Inference System*) do tipo Sugeno (JANG, 1993). O ANFIS oferece as melhores vantagens que existem para técnicas de lógica difusa e rede neural em uma única

ferramenta. A Figura 9 ilustra a arquitetura da rede da ANFIS, onde a primeira camada estrutura as variáveis de entrada relativa a cada função de pertinência (MF). Na segunda camada é utilizada a operação binária na estrutura de dados métricos probabilístico (norma T), generalizando a intercessão em uma rede (conjunção na lógica), e a terceira camada normaliza as funções de pertinência. Os parâmetros consequentes são calculados na quarta camada e, finalmente, a última camada calcula a soma de todos os sinais de entrada (SUMATHI; SUREKHA, 2010). Para a comprovação da eficiência do sistema ANFIS, após determinação do número de associações, fixa-se o número de camadas em 5 e estabelece-se o número de nós em cada camada.

Figura 9 - Representação esquemática da arquitetura de rede da ANFIS.



Fonte: Contini Jr e Balancin (2021).

Após aplicação dos métodos acima, um sistema de inferência neuro adaptativa é construído, usando o algoritmo *backpropagation* (BP) e o método de mínimos quadrados para ajustar apropriadamente as funções de pertinência aos dados de entrada e saída. O sistema de inferência *fuzzy* introduz no treinamento da RNA variáveis linguísticas na forma de “se-então”, permitindo ajustes sob novas situações.

4. MATERIAIS E MÉTODOS

4.1 MATERIAL

Para conduzir essa investigação, foram utilizados dados experimentais de um trabalho desenvolvido no Departamento de Engenharia de Materiais da Universidade Federal de São Carlos (DIAS, 2016 - Dissertação de Mestrado). O material utilizado neste trabalho foi o aço inoxidável super duplex – UNS S32760 cuja composição química está indicada na Tabela 3.

Tabela 3 - Composição química do aço UNS S32760 (% em massa).

C	Si	Mn	Cr	Ni	Mo	W	Cu	N	Fe
0,02	0,25	0,54	25,18	7,04	3,57	0,53	0,55	0,23	Bal.

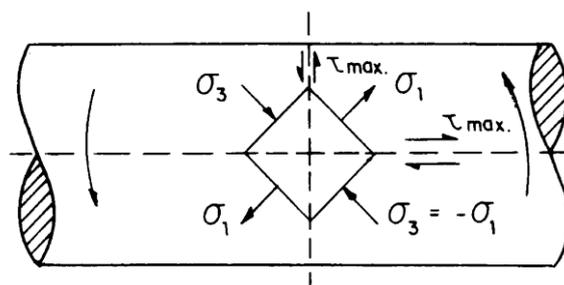
Fonte: O Autor.

4.2 ENSAIOS MECÂNICOS

Os ensaios foram realizados em uma máquina horizontal de ensaios de torção a quente, a qual está acoplada a um microcomputador por meio de interfaces que possibilitam a intercomunicação máquina-computador, permitindo o controle do ensaio e a aquisição de dados. A máquina horizontal de torção a quente foi projetada e construída no Departamento de Engenharia de Materiais da Universidade Federal de São Carlos (DEMa). O equipamento é constituído de uma máquina horizontal de torção, de um forno para aquecimento dos corpos de prova e de um sistema de controle e aquisição de dados.

O estado de tensões desenvolvido na região central do corpo de prova quando é aplicado um momento torsor pode ser representado pela Figura 10. As tensões de tração (σ_1) e de compressão (σ_3) são iguais, em magnitude, às tensões cisalhantes máximas ($\tau_{máx}$), e formam um ângulo de 45° com a direção de atuação destas tensões, ou seja, com o eixo longitudinal da amostra. A tensão atuante no plano normal ao destas tensões (tensão intermediária – σ_2), é igual a zero.

Figura 10 - Estado de tensões observado na região central do corpo de prova submetido à torção.



Fonte: Dieter (1988).

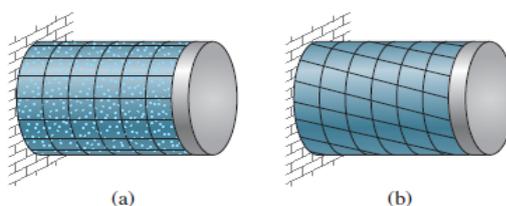
O cálculo da tensão equivalente se faz utilizando a Equação 2:

$$\sigma = \frac{\sqrt{3} \cdot M}{2 \cdot \pi \cdot R^3} (3 + m + n) \quad (2)$$

onde M é o momento torsor, R é o raio do corpo de prova e m e n são os coeficientes de sensibilidade do material à taxa de deformação e ao encruamento, respectivamente.

O estado de deformação ao aplicar um esforço torção está representado na Figura 11. Antes da aplicação do esforço de torção, os elementos desenhados na superfície da amostra se apresentam com as faces paralelas entre si (Figura 11-a). Depois da aplicação de um momento torsor, os elementos se deformam de modo que uma das diagonais se alonga, enquanto a outra é reduzida, transformando cada quadrado inicial em um losango (Figura 11-b).

Figura 11 - Região útil da amostra submetida a um esforço de torção. (a) Antes da aplicação do esforço e (b) depois de aplicado o momento torsor.



Fonte: Vable (2010).

A deformação equivalente é calculada utilizando-se a Equação 3:

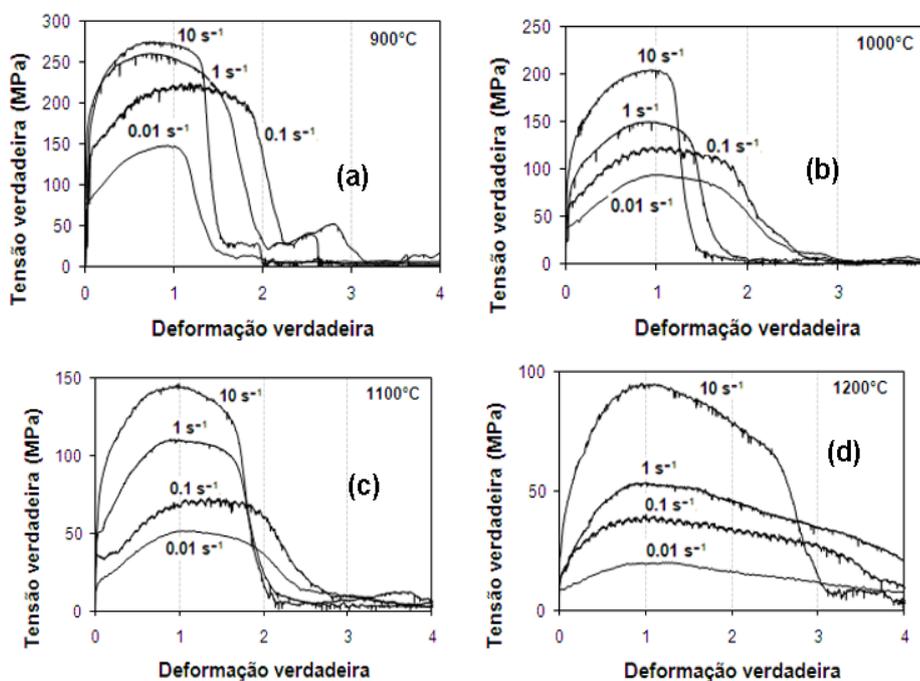
$$\varepsilon = \frac{R \cdot \theta}{\sqrt{3} \cdot L} \quad (3)$$

onde L é o comprimento útil do corpo de prova, R é o raio do corpo de prova e θ o ângulo de rotação da máquina. A taxa de deformação é calculada dividindo-se a deformação pelo tempo total do ensaio.

Na realização dos ensaios, as amostras do material foram aquecidas até 1200°C, mantidas nesta temperatura durante 10 minutos em uma atmosfera protegida com argônio, e em seguida resfriadas até a temperatura de deformação, sendo mantidas nesta temperatura durante 30 segundos para eliminar os gradientes térmicos. Os testes de torção a quente foram realizados no intervalo de temperaturas entre 900 e 1200°C com taxas de deformação de 0,01, 0,1, 1 e 10s⁻¹. A temperatura e a velocidade de deformação eram impostas e controladas pelo *software*. A deformação e a tensão necessária para deformar o material foram medidos por sensores (*encoder* e célula de torção) acoplados à máquina e enviados ao *software* que construía as curvas tensão equivalente vs. deformação equivalente, como apresentadas na Figura 12.

Optou-se por apresentar esses resultados aqui, pois referem-se a dados obtidos por um pesquisador não associado a este trabalho.

Figura 12 - Curvas de escoamento plástico obtidas nos ensaios de torção a quente do aço inoxidável duplex.



Fonte: Dias (2016).

As curvas mostradas na Figura 12 reportam a evolução da tensão com a deformação em ensaios contínuos até deformações de 4,0, independentemente se ocorreu ou não a ruptura dos corpos de prova durante os ensaios. Essas curvas indicam que para a grande maioria dos ensaios houve a ruptura dos corpos de prova antes de completar a deformação; ensaios realizados em 1200°C com taxas de deformações de 1, 0,1 e 0,01s⁻¹ são exceções a esse comportamento.

4.3 PREPARAÇÃO DOS DADOS

Com os dados arquivados pela máquina foram construídas planilhas com os valores dos parâmetros utilizados nos ensaios. A Tabela 4 mostra os vinte primeiros valores dos ensaios realizados com taxa de deformação de 0,01 s⁻¹ nas temperaturas de 900, 1000, 1100 e 1200°C. A partir desses dados experimentais foi construído uma planilha agrupando todos os dados das 16 curvas mostradas na Figura 12. Essa planilha iniciava com os dados da curva experimental conduzida a 900°C com taxa

de $0,01s^{-1}$, seguido pelos dados do experimento conduzido a mesma temperatura com taxa de $0,1s^{-1}$, seguido pelas taxas de $1s^{-1}$ e $10s^{-1}$. A continuidade da planilha se deu repetindo a mesma sequência para as curvas obtidas a 1000, 1100 e 1200°C. Essa planilha com todos os dados experimentais contém 21296 pontos de dados.

Tabela 4 - Vinte primeiros pontos de dados obtidos com taxa de deformação de $0,01s^{-1}$.

900°C - 0,01s⁻¹		1000°C - 0,01 s⁻¹		1100°C - 0,01 s⁻¹		1200°C - 0,01 s⁻¹	
Deform.	Tensão (MPa)	Deform.	Tensão (MPa)	Deform.	Tensão (MPa)	Deform.	Tensão (MPa)
0,0015	4,3241	0,0103	36,6782	0,0067	12,2617	0,0057	8,5486
0,0025	32,6584	0,0147	37,0321	0,0374	18,0059	0,0375	8,5486
0,0027	35,8726	0,0188	38,0630	0,0562	18,8129	0,0562	8,8067
0,0160	79,7629	0,0377	39,6060	0,0749	20,8385	0,0750	8,5486
0,0570	82,1943	0,0565	40,8918	0,0936	20,5548	0,0937	9,5812
0,0760	83,1669	0,0754	41,6633	0,1123	22,0711	0,1124	9,8067
0,0949	87,3003	0,0942	43,2063	0,1311	22,3292	0,1312	9,8393
0,1139	89,0024	0,1130	44,7493	0,1498	22,5873	0,1499	10,0974
0,1329	91,4338	0,1319	46,2923	0,1685	24,1362	0,1686	11,0974
0,1519	93,6221	0,1507	47,2350	0,1872	24,1362	0,1874	11,1300
0,1709	96,2967	0,1696	48,0925	0,2059	24,9106	0,2061	11,1300
0,1899	98,2418	0,1884	50,1499	0,2247	25,9432	0,2248	11,3882
0,2089	101,1596	0,2072	51,6929	0,2434	26,4595	0,2436	11,3882
0,2279	103,3478	0,2261	53,2359	0,2621	26,9757	0,2623	11,9044
0,2468	106,0224	0,2449	54,7789	0,2808	28,2664	0,2811	12,6789
0,2658	108,4539	0,2637	56,8362	0,2995	28,7827	0,2998	12,6789
0,2848	110,8853	0,2826	58,3792	0,3183	30,0734	0,3185	12,9370
0,3038	113,3168	0,3014	59,6651	0,3370	30,5897	0,3373	13,7114

Fonte: O Autor.

Uma vez que as curvas medidas experimentalmente são compostas de pontos que representam a deformação plástica dos corpos de prova e pontos medidos após a falha dos corpos de prova, é necessário isolar os pontos que descrevem o regime plástico, que é o foco deste estudo. Esse processo é visual e depende da experiência do pesquisador. Em algumas curvas esta transição é bastante clara e em outras nem tanto, podendo gerar alguns erros de interpretação.

Com a limpeza nos dados experimentais obteve-se uma planilha com 10158 pontos de dados. Uma vez que a variação dos valores da taxa de deformação é bastante severa, variando de $0,01$ a $10 s^{-1}$, optou-se pela apresentação destes dados

em escala logarítmica. Desta forma, construiu-se a planilha PlanFL que passou a representar o comportamento plástico do aço inoxidável duplex.

4.4 MODELAGEM UTILIZANDO UMA REDE NEURAL ARTIFICIAL

De posse da planilha PlanFL pôde-se iniciar o processo de modelagem das curvas de escoamento plástico utilizando uma rede neural artificial rasa. Foram considerados como dados de entrada: a temperatura, a taxa de deformação e a deformação e como dados de saída os valores da tensão. Esse processo de aprendizado de máquina foi realizado utilizando a linguagem MATLAB® (Deep Learning Toolbox™ – Getting Start Guide, The MathWorks, Inc - USA). Inicialmente fez-se o carregamento da planilha no software:

```
%.....
load PlanFL.txt
x = PlanFL( : , [1 2 3] );
y = PlanFL( : , 4 );
%.....
```

Usualmente, fazem-se alguns tratamentos nos dados obtidos antes de utilizá-los em um processo de aprendizagem de máquina. Neste exercício, os dados obtidos nos experimentos realizados representam bem o comportamento do material, não necessitando de tratamentos especiais para eliminação de valores inconsistentes ou valores faltantes. Todavia, há diferenças marcantes entre os valores numéricos dos parâmetros em estudo. A temperatura assume valores duas ordens de grandeza maiores que os valores da taxa de deformação e três ordens de grandeza maiores que a deformação. Para um processo eficiente de aprendizagem de máquina, os dados obtidos experimentalmente precisam ser normalizados, pois a mistura de grandes e pequenos valores numéricos podem confundir o processo de aprendizagem. Assim, tanto os dados de entrada como os de saída foram normalizados no intervalo entre 0,1 e 0,9 usando a Equação 4:

$$X_i = 0.1 + 0.8 x \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right), \quad (4)$$

onde X é o valor original, X_{min} o valor mínimo de X , X_{max} o valor máximo de X e X_i o valor normalizado correspondente de X .

```

%.....
% Normalização dos dados
for i = 1:4
    PlanFLEs( : , i) = 0.1 + 0.8*(PlanFL( : , i) - min(PlanFL( : , i)))/(max(PlanFL(
: , i) - min(PlanFL( : , i)));
end
%.....

```

Obtida a planilha PlanFLEs com os dados normalizados, podemos iniciar o treinamento (utilização dos dados para testes e performance) da rede neural dividindo a planilha em três subconjuntos: treinamento, validação e teste como indicado abaixo:

```

%.....
% Treinamento de uma rede neural artificial (ANN)
PlanFLEsX = PlanFLEs( : , [1 2 3])';
PlanFLEsY = PlanFLEs( : , 4)';

hiddenLayerSize = 18;
net = fitnet(hiddenLayerSize);
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

[net, tr] = train(net, PlanFLEsX, PlanFLEsY);

%Test the network
outputs = net(PlanFLEsX);
errors = gsubtract(outputs, PlanFLEsY);
performance = perform(net, PlanFLEsY, outputs);

%View the network
view(net);
%.....

```

Os resultados preditos foram quantificados usando parâmetros estatísticos para avaliar a acurácia de predição da RNA. Foram utilizados os seguintes parâmetros estatísticos: erro percentual absoluto médio (MAPE) (Equação 5), raiz quadrada do erro médio quadrático (RMSE) (Equação 6) e o coeficiente de correlação R^2 (Equação 7).

$$MAPE = \frac{\sum_1^N \left| \frac{E_i - P_i}{E_i} \right|}{N} \times 100 \quad (5)$$

$$RMSE = \left[\frac{1}{N} \sum_1^N (E_i - P_i)^2 \right]^{\frac{1}{2}} \quad (6)$$

$$R = \frac{\sum_1^N (E_i - \bar{E})(P_i - \bar{P})}{\sqrt{\sum_1^N (E_i - \bar{E})^2} \sqrt{\sum_1^N (P_i - \bar{P})^2}}, \quad (7)$$

onde E é o valor experimental e P é o valor predito pela RNA, e N é o número de dados. \bar{E} e \bar{P} representam os valores médios medidos e os valores médios preditos de E e P. Os códigos utilizados para determinar o desempenho da rede neural artificial são descritos a seguir:

```
%.....
% Desempenho do treinamento com os dados normalizados
yTrain = net(PlanFLEsX( : , tr.trainInd));
yTrainTrue = PlanFLEsY(tr.trainInd);
rmseTrain = sqrt(mean((yTrain - yTrainTrue).^2));

%Cálculo do MAPE
A = yTrain;
B = yTrainTrue;
MapeTrain = mean((abs(A-B))./A)*100;

% Desempenho do treinamento com os dados não normalizados
yTrain1 = (net(PlanFLEsX( : , tr.trainInd))-0.1)*(max(PlanFL( : , i))- min(PlanFL( : , i)))/(0.8)- min(PlanFL( : , i));
yTrainTrue1 = (PlanFLEsY(tr.trainInd)- 0.1)*(max(PlanFL( : , i))- min(PlanFL( : , i)))/(0.8)- min(PlanFL( : , i));
rmseTrain1 = sqrt(mean((yTrain1 - yTrainTrue1).^2));

%Cálculo do MAPE
A = yTrain1;
B = yTrainTrue1;
MapeTrain1 = mean((abs(A-B))./A)*100;

%.....
% Desempenho da validação com os dados normalizados
yVal = net(PlanFLEsX( : , tr.valInd));
yValTrue = PlanFLEsY(tr.valInd);
rmseVal = sqrt(mean((yVal - yValTrue).^2));

%Cálculo do MAPE
A = yVal;
B = yValTrue;
MapeVal = mean((abs(A-B))./A)*100;

% Desempenho da validação com os dados não normalizados
yVal1 = (net(PlanFLEsX( : , tr.valInd))-0.1)*(max(PlanFL( : , i))- min(PlanFL( : , i)))/(0.8)- min(PlanFL( : , i));
yValTrue1 = (PlanFLEsY(tr.valInd)- 0.1)*(max(PlanFL( : , i))- min(PlanFL( : , i)))/(0.8)- min(PlanFL( : , i));
rmseVal1 = sqrt(mean((yVal1 - yValTrue1).^2));
```

```

%Cálculo do MAPE
A = yVal1;
B = yValTrue1;
MapeVal1 = mean((abs(A-B))./A)*100;

%.
%.....
% Desempenho do teste com os dados normalizados
yTest = net(PlanFLEsX( : , tr.testInd));
yTestTrue = PlanFLEsY(tr.testInd);
rmseTest = sqrt(mean((yTest - yTestTrue).^2));

%Cálculo do MAPE
A = yTest;
B = yTestTrue;
MapeTest = mean((abs(A-B))./A)*100;

%Desempenho do teste com os dados não normalizados
yTest1 =(net(PlanFLEsX( : , tr.testInd))-0.1)*(max(PlanFL( : , i))- min(PlanFL( : , i)))/(0.8)- min(PlanFL( : , i));
yTestTrue1 = (PlanFLEsY(tr.testInd)- 0.1)*(max(PlanFL( : , i))- min(PlanFL( : , i)))/(0.8)- min(PlanFL( : , i));
rmseTest1 = sqrt(mean((yTest1 - yTestTrue1).^2));

%Cálculo do MAPE
A = yTest1;
B = yTestTrue1;
MapeTest1 = mean((abs(A-B))./A)*100;

%.
%.....

```

A arquitetura de uma rede neural artificial rasa é determinada pela função de ativação juntamente com o número de neurônios na camada escondida (*hidden layer*). Neste exercício, o processo de aprendizado foi baseado na descida do gradiente (encontrar o mínimo numa função de erro) que requer uma função de ativação diferenciável. Assim, a função sigmoideal logística foi aplicada como função de ativação. Para determinar o número de neurônios na camada escondida foi investigado a evolução da raiz quadrada do erro médio quadrático (RMSE) variando o número de neurônios na camada escondida de 1 a 25. Para isto, utilizou-se um laço for como descrito abaixo:

```

%.
%.....
for j =1:25
    %defining the architecture of the ANN
    hiddenLayerSize = j;
    net = fitnet(hiddenLayerSize);
    net.divideParam.trainRatio = 70/100;
    net.divideParam.valRatio = 15/100;

```

```

net.divideParam.testRatio = 15/100;

%Training the ANN
[net, tr] = train(net, PlanFLEsX, PlanFLEsY);

%Determine the error of the ANN
%Performance of the ANN normalized
yTrain1 =(net(PlanFLEsX( : , tr.trainInd))-0.1)*(max(PlanFL( : , i))-
min(PlanFL( : , i)))/(0.8) - min(PlanFL( : , i));
yTrainTrue1 = (PlanFLEsY(tr.trainInd)- 0.1)*(max(PlanFL( : , i))-
min(PlanFL( : , i)))/(0.8) - min(PlanFL( : , i));
rmseTrain2(j) = sqrt(mean((yTrain1 - yTrainTrue1).^2));

%Performance of the validation normalized
yVal1 =(net(PlanFLEsX( : , tr.valInd))-0.1)*(max(PlanFL( : , i))-
min(PlanFL( : , i)))/(0.8) - min(PlanFL( : , i));
yValTrue1 = (PlanFLEsY(tr.valInd)- 0.1)*(max(PlanFL( : , i))-
min(PlanFL( : , i)))/(0.8) - min(PlanFL( : , i));
rmseVal2(j) = sqrt(mean((yVal1 - yValTrue1).^2));

%Performance of the testing normalized
yTest1 =(net(PlanFLEsX( : , tr.testInd))-0.1)*(max(PlanFL( : , i))-
min(PlanFL( : , i)))/(0.8) - min(PlanFL( : , i));
yTestTrue1 = (PlanFLEsY(tr.testInd)- 0.1)*(max(PlanFL( : , i))-
min(PlanFL( : , i)))/(0.8) - min(PlanFL( : , i));
rmseTest2(j) = sqrt(mean((yTest1 - yTestTrue1).^2));
end
%.....

```

4.5 MODELAGEM UTILIZANDO UMA ANFIS

De posse da planilha PlanFL, pôde-se iniciar o processo de modelagem das curvas de escoamento plástico utilizando o sistema de inferência adaptando lógica difusa a uma rede neural (ANFIS – *Adaptive Neuro Fuzzy Inference System*). Esse processo foi realizado utilizando a linguagem MATLAB® (Fuzzy Logic Toolbox™ – User’s Guide, The MathWorks Inc – USA). Inicialmente fez-se o carregamento da planilha no software:

```

%.....
load PlanFL.txt
%.....

```

Uma vez carregada a planilha, pôde-se iniciar o treinamento propriamente dito do ANFIS dividindo a planilha em dois subconjuntos: treinamento e checagem, como indicado abaixo:

```
%.....
%.....
%Definindo uma planilha com R linhas e C colunas.
[R,C] = size(PlanFL);

%Definindo b como uma linha especifica
b = 1:R;

%Separando checagem de treinamento
I = true(size(b));
I(1:5:end) = false;

%Determinando a planilha de checagem
PlanFL(b(~I),:);
PlanFLchk = PlanFL(b(~I),:);

%Determinando a planilha de treinamento
PlanFL(b(I),:);
PlanFLtrn = PlanFL(b(I),:);

%.....
```

Para iniciar o treinamento da ANFIS é preciso definir a sua estrutura. A partir da Figura 12 é possível observar que as curvas de escoamento plástico do aço inoxidável duplex foram determinadas com temperatura e taxa de deformação constantes em quatro níveis para cada uma destas variáveis, e a deformação variou continuamente de 0 até a fratura. Assim, é esperado que uma escolha adequada para o número de funções de pertinência, MFs, seja quatro para a temperatura e quatro para a taxa de deformação. Também, a grande diferença na ductilidade sugere que é necessário um grande número de MFs para a deformação. Além do número de MFs é necessário definir o tipo, e neste exercício foi escolhido o “gbellmf” com [4 4 10]. Esta escolha foi feita conduzindo o treinamento com diferentes números e tipos de MFs.

```
%.....
%Definir a estrutura inicial
genOpt = genfisOptions('GridPartition');
genOpt.NumMembershipFunctions = [4 4 10];
genOpt.InputMembershipFunctionType = ["gbellmf" "gbellmf" "gbellmf"];
```

```
% Gerar o FIS
inFIS = genfis(PlanFLtrn(:, [1 2 3]), PlanFLtrn(:, 4), genOpt);
% Configurar o treinamento do ANFIS
opt = anfisOptions('InitialFIS', inFIS);
opt.DisplayANFISInformation = 0;
opt.DisplayErrorValues = 0;
opt.DisplayStepSize = 0;
opt.DisplayFinalResults = 0;
```

```
%.....
```

Definida a estrutura da ANFIS fez-se o treinamento e a checagem do modelo.

```
%.....
%Treinamento do ANFIS
outFIS = anfis([PlanFLtrn(:, [1 2 3]), PlanFLtrn(:, 4)], opt);
anfisOutput1 = evalfis(outFIS, PlanFLtrn(:, [1 2 3]));
```

```
%Checagem do ANFIS
anfisOutput2 = evalfis(outFIS, PlanFLchk( : , [1 2 3]));
```

```
%.....
```

Os resultados preditos foram quantificados usando parâmetros estatísticos para avaliar a acurácia de predição da ANFIS.

```
%.....
%Cálculo dos RMSEs
```

```
%Entre os dados experimentais e os de treinamento
a1 = anfisOutput1;
b1 = PlanFLtrn( : , 4);
rmsetrn1 = sqrt(mean((a1 - b1).^2));
```

```
%Entre os dados experimentais e o de checagem
a2 = anfisOutput2;
b2 = PlanFLchk( : , 4);
rmsechk2 = sqrt(mean((a2 - b2).^2));
```

```
%.....
```

```
% Cálculo dos Rs
```

```
%Entre os dados experimentais e de treinamento
```

```
A = PlanFLtrn( : , 4);
B = anfisOutput1( : );
```

```
h = polyfit(A, B, 1);
f = polyval(h, A);
```

```

Bbar = mean(B);
SStot = sum((B - Bbar).^2); %SStot = sun of squared total
%SSreg = sum((f - Bbar).^2); %SSreg = sun of squared regression
SSres = sum((B - f).^2); %SSres = sun of squared error

%Ra = 1 - SSres/SStot;

Ra = corrcoef(A,B);
Rsqa = Ra(1,2).^2;

%Entre os dados experimentais e de checagem

A = PlanFLchk( : ,4);
B = anfisOutput2( : );

h = polyfit(A, B, 1);
f = polyval(h, A);

Bbar = mean(B);
SStot = sum((B - Bbar).^2); %SStot = sun of squared total
%SSreg = sum((f - Bbar).^2); %SSreg = sun of squared regression
SSres = sum((B - f).^2); %SSres = sun of squared error

%Rb = 1 - SSres/SStot;

Rb = corrcoef(A,B);
Rsqb = Ra(1,2).^2;

%.....

%Cálculo dos MAPEs

%Entre os dados experimentais e os de treinamento
A1 = PlanFLtrn( : ,4);
B1 = anfisOutput1;
MAPE1 = mean((abs(A1-B1))./A1)*100;

%Entre os dados experimentais e os de checagem
A2 = PlanFLchk( : ,4);
B2 = anfisOutput2;
MAPE2 = mean((abs(A2-B2))./A2)*100;
%-----

```

Uma vez que a ANFIS é capaz de refazer as curvas de escoamento plástico do aço inoxidável duplex de uma forma satisfatória, o modelo construído pôde ser utilizado para prever valores de tensão em condições não medidas experimentalmente.

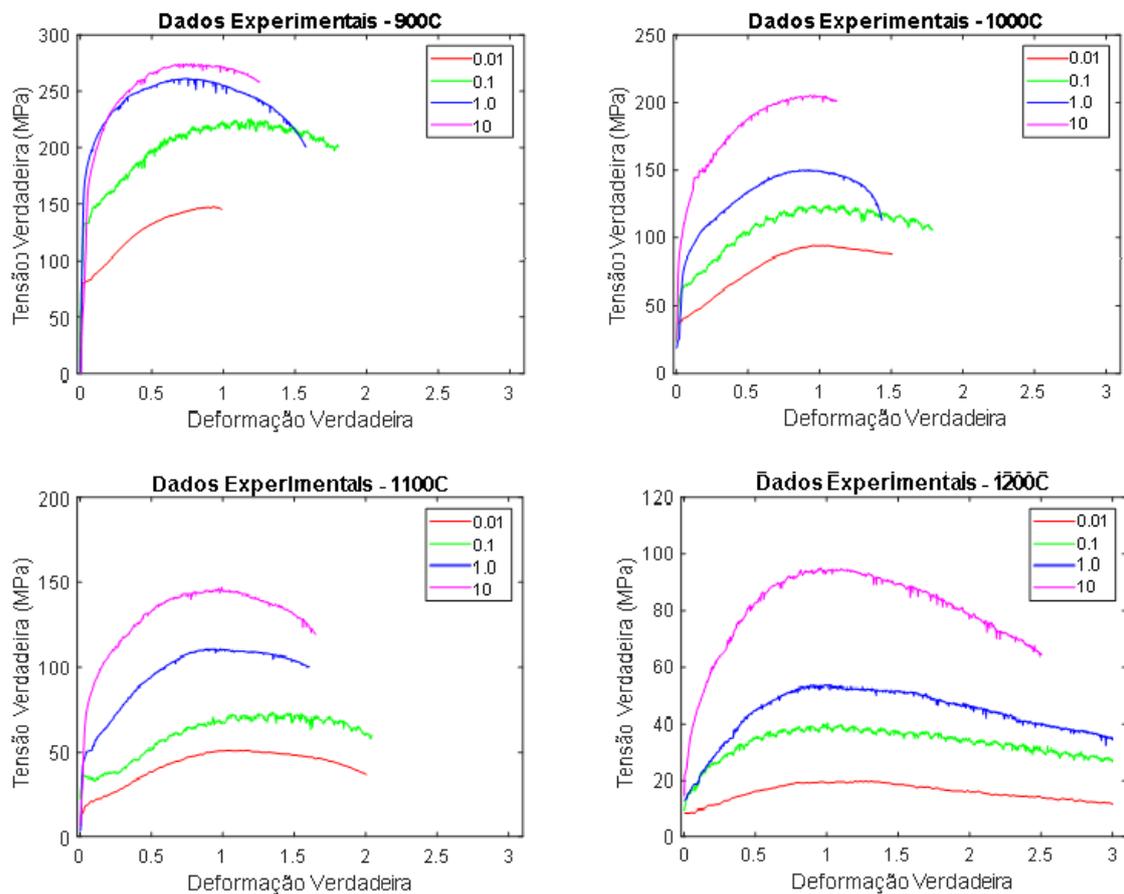
```
%.....  
load PlanFL50b.txt;  
load PlanFL1s.txt  
anfisOutput2 = evalfis(outFIS,PlanFL50b);  
%.....
```

5. RESULTADOS E DISCUSSÃO

5.1 CURVAS DE ESCOAMENTO PLÁSTICO

Após os dados experimentais passarem por um processo de preparação, como descrito no capítulo anterior, foi obtida a planilha PlanFL que representa apenas as regiões de deformação plástica das curvas de escoamento plástico do aço inoxidável duplex, como mostra a Figura 13.

Figura 13 - Curvas de escoamento plástico obtidas experimentalmente mostrando apenas as regiões de deformação plástica.



Fonte: O Autor.

Estas curvas apresentam a forma típica do comportamento mecânico a quente dos aços, cuja tensão aumenta com a deformação até um máximo e depois decresce. Todavia, pode-se notar que o estado estacionário de tensões em grandes deformações não foi alcançado. Observa-se nesta figura que as amostras

deformadas em baixas temperaturas e com altas taxas de deformação falharam com deformações próximas a 1,0 - 1,5, enquanto amostras deformadas em altas temperaturas e baixas taxas de deformação suportaram maiores deformações.

Vê-se também na Figura 13, que ao variar a temperatura de deformação a forma da curva de escoamento plástico assume dois padrões distintos. Em baixas temperaturas e/ou altas taxas de deformação a curva tem uma forma arredondada, como pode ser observado em 900°C com taxas de 1,0 e 10 s⁻¹ ou em 1100°C com taxa de 10 s⁻¹. Em altas temperaturas e/ou baixas taxas de deformação, a tensão aumenta com a deformação de forma aproximadamente linear até um máximo, no início da deformação. Ao alcançar o máximo, pode ou não haver uma faixa de deformações com tensão constante, seguida de um decréscimo.

Assim, fica claro que existem diferenças significativas no formato dessas curvas quando comparadas com as apresentadas por materiais monofásicos que amaciam por recuperação dinâmica e/ou recristalização dinâmica. Nestes materiais, quando a deformação é conduzida com a temperatura e taxa de deformação constantes, a tensão de fluxo aumenta no regime inicial de encruamento e então torna-se constante em materiais que se recuperam dinamicamente de uma forma extensiva; em contraste, a tensão experimenta um máximo antes de decrescer para um estado estacionário em materiais que são amaciados pela recristalização dinâmica.

5.2 MODELAGEM COM REDE NEURAL ARTIFICIAL

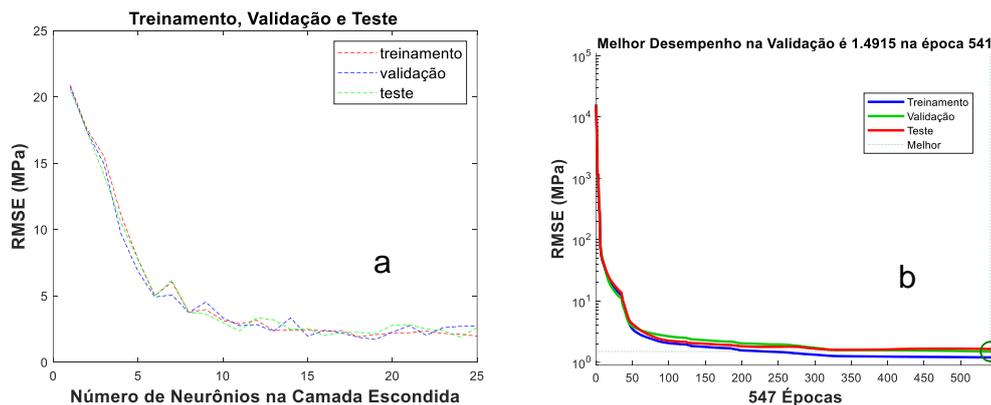
Em um processo de aprendizagem de máquina o software (algoritmo) cria um modelo que descreve a relação entre os dados de entrada e os dados de saída. Com este modelo, os dados de saída são calculados e comparados com os valores experimentais. Comparando esses dados, os desvios no processo de aprendizagem são determinados. Baseado nestes erros, o algoritmo *backward* (regra da cadeia que usa o erro de saída para atualizar os pesos) recalcula os novos pesos das sinapses preparando a rede para uma nova rodada de cálculos, época.

A arquitetura de uma rede neural artificial rasa é determinada pela função de ativação juntamente com o número de neurônios na camada escondida. Para determinar o número de neurônios na camada escondida foi investigado a evolução da raiz quadrada do erro médio quadrático (RMSE) variando o número de neurônios na camada escondida de 1 a 25. Os resultados desta investigação estão

apresentados na Figura 14-a. Pode-se ver nesta figura que o desvio decresce com o aumento dos números de neurônios na camada escondida. Para poucos neurônios a queda é brusca diminuindo conforme o número aumenta tendendo para valores constantes. Neste trabalho, considerou-se que 18 neurônios é um número adequado.

Na Figura 14-b é apresentado um exemplo mostrando como o erro evolui com o número de épocas. Pode-se ver nesta figura que o desvio diminui com o avanço do processo de aprendizagem de máquina. Inicialmente a queda é brusca tendendo para um valor mínimo, a partir do qual a tendência é de aumentar a diferença. Neste exemplo, o valor do RMSE é significativamente baixo, sendo o desvio no treinamento menor que o da validação que é bastante próximo dos desvios observados no teste.

Figura 14 - Evolução do RMSE, com o número de neurônios na camada escondida (a) e com a evolução do processo de aprendizagem de máquina (b).

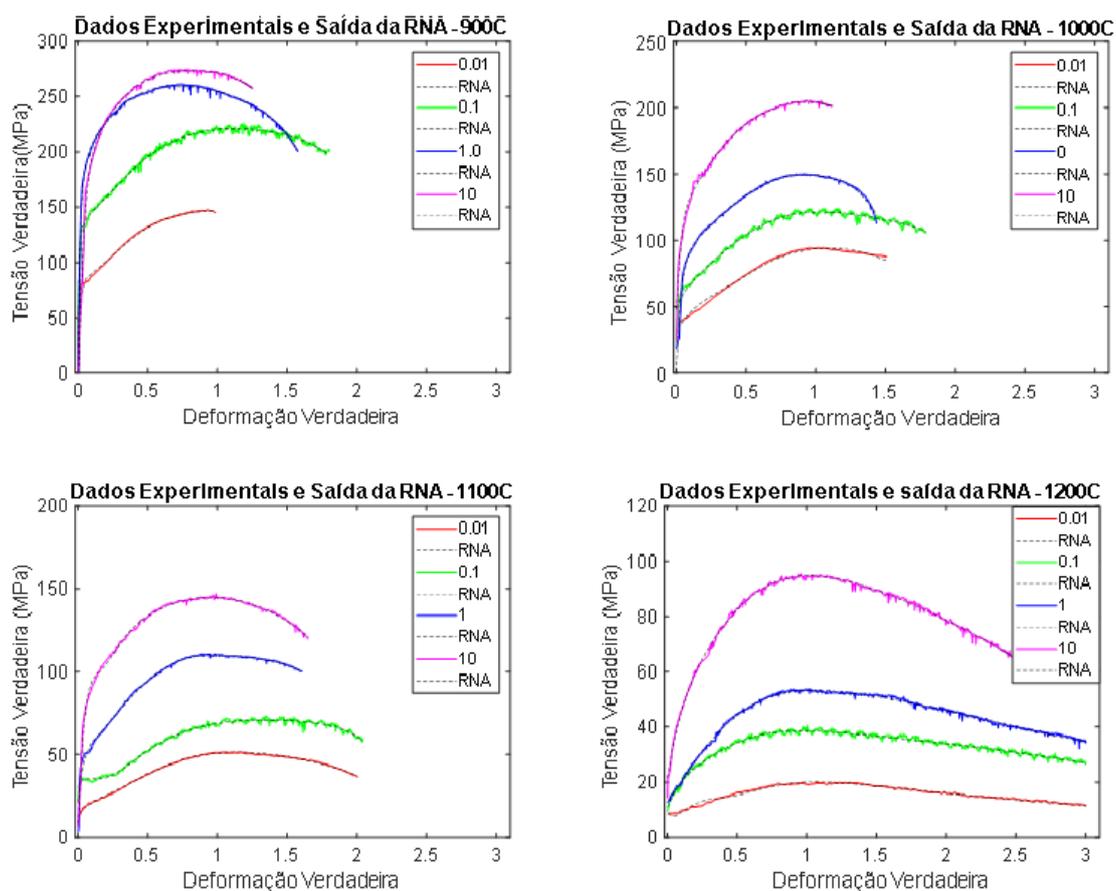


Fonte: O Autor.

Definida a arquitetura da rede neural artificial rasa (camada de entrada com três atributos, camada escondida com 18 neurônios, camada de saída com um neurônio (3x18x1) e a função sigmoial como função de ativação) esta foi usada para modelar as curvas de escoamento plástico do aço inoxidável duplex. A Figura 15 mostra as curvas de escoamento plástico obtidas com o modelo da RNA juntamente com os respectivos dados experimentais. Comparando visualmente os dados calculados com os dados experimentais pode-se dizer que o modelo descreve bem o comportamento plástico do aço duplex durante o processo de deformação a quente,

indicando que o processo de aprendizagem de máquina apresentou desempenho satisfatório.

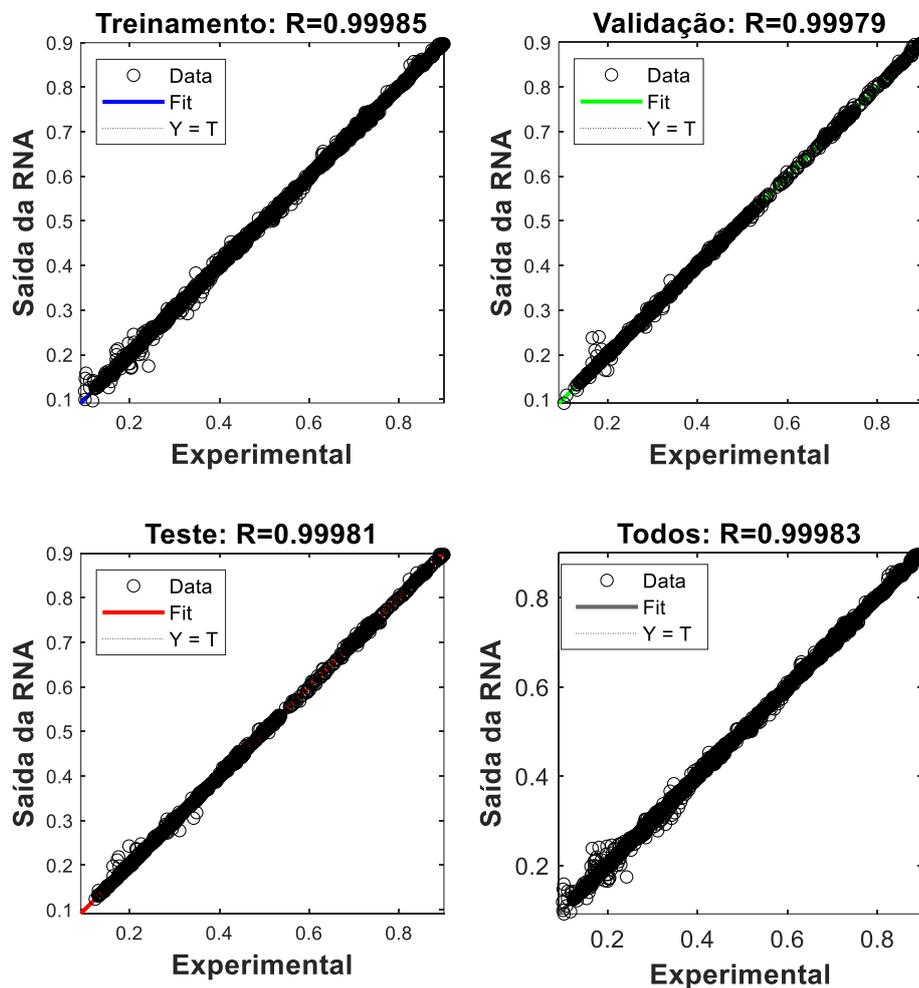
Figura 15 - Curvas de escoamento plástico calculadas com a RNA juntamente com as respectivas curvas experimentais.



Fonte: O Autor.

Para melhor avaliar visualmente o ajuste entre os dados de saída da RNA e os dados experimentais foi construída a Figura 16. Vê-se nesta figura que os dados estão em torno da reta diagonal do gráfico, indicando um bom ajuste.

Figura 16 - Curvas relacionando os dados experimentais com os dados de saída da RNA. Nestes diagramas utilizaram-se os dados normalizados.



Fonte: O Autor.

Prosseguindo o exercício, o desvio entre as curvas calculadas e as medidas experimentalmente foram analisados usando parâmetros estatísticos como está indicado na Tabela 5. O resíduo médio entre os valores dos pontos medidos e calculados foi de 2,176 MPa para o treinamento, o que representa um erro percentual médio de 1,552%. Os dados obtidos pela RNA representam 99,9% das variações obtidas na relação entre a tensão e a deformação experimental. Também, os valores dos parâmetros estatísticos determinados tanto para o treinamento quanto para a validação e teste são próximos. Esses valores indicam que o modelo tem forte habilidade e precisão para modelar as curvas de escoamento plástico durante a deformação a quente do aço inoxidável super duplex.

Tabela 5 - Valores de parâmetros estatísticos determinados a partir do processo de aprendizagem.

	RMSE (MPA)	MAPE (%)	R²
Training	2,176	1,552	0,999
Validation	2,163	1,457	0,999
Test	2,415	1,619	0,999

Fonte: O Autor.

5.3 MODELAGEM COM ANFIS

Para modelar as curvas de escoamento plástico utilizando uma ANFIS é preciso definir a sua estrutura. Observando a Figura 12, pode-se ver que as curvas de escoamento plástico do aço inoxidável duplex foram determinadas com temperaturas e taxas de deformação constantes em quatro níveis para cada uma destas variáveis e a deformação variou continuamente de 0 até a fratura. A Tabela 6 mostra a evolução dos desvios entre os valores experimentais e os calculados realizando o processo de aprendizagem de máquina com funções de pertinência (MFs), que estabelece o grau de certeza de uma determinada variável de entrada representa para uma variável linguística, do tipo triangular (trimf), com forma de sino (gbellmf) e gaussiana (gaussmf) variando os números destas funções. Uma vez que o produto das três funções de pertinência determina o número de regras (relação entre suas entradas e saídas), este parâmetro foi usado para indicar a evolução da arquitetura da ANFIS. Vê-se nesta tabela que o erro diminui conforme o número de MFs aumenta. Também, o tipo de MF altera os resíduos, como pode ser visto na Figura 17.

Tabela 6 - Evolução dos índices de avaliação em função dos tipos e números de funções de pertinência.

Função de Pertinência (MF)		Regras		Índices de Avaliação		
Número	Tipo	Número	Visual	RMSE (MPa)	MAPE (%)	R ²
3 3 3	tri – tri - tri	27	X	4,002	5,094	0,9970
3 3 3	gauss-gauss-gauss	27		6,183	10,182	0,9928
3 3 3	bell – bell - bell	27		6,928	11,274	0,9910
3 3 3	tri – tri- gauss	27		6,190	10,263	0,9928
3 3 3	tri – tri - bell	27		6,917	11,440	0,9910
3 3 3	tri – gauss - bell	27		6,935	11,461	0,9910
3 3 3	gauss – bell - tri	27	X	4,255	5,194	0,9966
3 3 3	Gauss – tri - tri	27	X	3,971	4,973	0,9970
3 3 4	tri – tri - tri	36	X	3,664	4,383	0,9975
3 3 4	gauss-gauss-gauss	36		5,871	9,413	0,9935
3 3 4	bell – bell - bell	36		5,991	9,691	0,9933
3 3 4	tri – tri- gauss	36		5,883	9,503	0,9935
3 3 4	tri – gauss - bell	36		6,010	9,903	0,9932
3 3 4	bell – gauss - tri	36	X	3,518	4,182	0,9977
3 3 4	gauss - tri - tri	36	X	3,531	4,268	0,9977
3 3 4	bell – tri - tri	36	X	3,447	4,170	0,9978
4 4 4	tri – tri - tri	64	X	2,756	3,207	0,9986
4 4 4	gbell – gbell - gbell	64		5,494	8,453	0,994
4 4 4	gauss-gauss - gauss	64		5,241	7,816	0,995
4 4 4	tri – tri - bell	64		5,489	8,441	0,9943
4 4 4	tri – tri - gauss	64		5,237	7,806	0,9949
4 4 4	gauss – bell - tri	64		5,495	8,453	0,9943
4 4 4	tri – bell - gauss	64		5,240	7,813	7,8134
4 4 5	tri – tri - tri	80	X	2,690	2,964	0,9986
4 4 5	bell – bell - bell	80		4,763	7,113	0,9958
4 4 5	gauss-gauss - gauss	80		4,960	7,332	0,9954
4 4 5	tri – tri - bell	80		4,755	7,106	0,9958

Tabela 6 - Evolução dos índices de avaliação em função dos tipos e números de funções de pertinência (continuação).

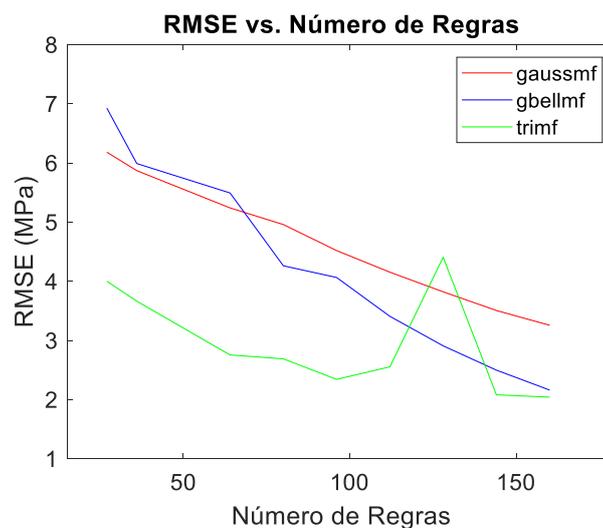
4 4 5	tri – gauss - bell	80		4,760	7,109	0,9958
4 4 5	tri – bell - gauss	80		4,958	7,331	0,9954
4 4 5	bell – gauss - tri	80	X	2,924	2,974	0,9984
4 4 6	tri – tri - tri	96	X	2,343	2,801	0,9989
4 4 6	gauss-gauss-gauss	96		4,520	6,545	0,9962
4 4 6	bell – bell -bell	96		4,065	5,793	0,9969
4 4 6	tri – tri - bell	96		4,063	5,790	0,9969
4 4 6	tri – tri - gauss	96		4,511	6,528	0,9962
4 4 6	tri – bell - gauss	96		4,516	6,538	0,9962
4 4 6	gauss – bell - tri	96	X	2,444	2,782	0,9989
4 4 7	tri – tri - tri	112	X	2,535	2,714	0,9988
4 4 7	gauss-gauss-gauss	112		4,155	5,867	0,9968
4 4 7	bell – bell -bell	112		3,409	4,601	0,9978
4 4 7	tri – tri - bell	112		3,407	4,596	0,9978
4 4 7	tri – tri - gauss	112		4,152	5,865	0,9968
4 4 7	tri – bell - gauss	112		4,154	5,867	0,9968
4 4 7	gauss – bell - tri	112	X	2,315	2,681	0,9990
4 4 8	tri – tri – tri	128	X	4,407	6,223	0,9964
4 4 8	bell – bell - bell	128		2,910	3,723	0,9984
4 4 8	gauss-gauss-gauss	128		3,823	5,2785	0,9973
4 4 8	gauss-gauss-bell	128		2,910	3,723	0,9984
4 4 8	gauss – bell - tri	128	X	4,403	6,216	0,9964
4 4 8	Tri – gauss-bell	128		2,908	3,718	0,9984
4 4 8	tri – bell - gauss	128		3,822	5,278	0,9973
4 4 9	bell – bell -bell	144		2,499	2,953	0,9988
4 4 9	gauss-gauss-gauss	144		3,507	4,690	0,9977
4 4 9	tri – tri - tri	144	X	2,082	2,423	0,9992
4 4 10	Bell – bell - bell	160		2,162	2,545	0,9991

Tabela 6 - Evolução dos índices de avaliação em função dos tipos e números de funções de pertinência (continuação).

4 4 10	gauss-gauss-gauss	160		3,237	4,215	0,9980
4 4 10	Tri – tri -tri	160	X	2,042	2,320	0,9992
4 5 7	bell – bell - bell	140		3,410	4,602	0,9978
5 5 5	tri – tri - tri	125	X	2,883	2,984	0,9984
5 5 5	bell – bell - bell	125		4,771	7,122	0,9957
5 5 5	gauss-gauss - gauss	125		4,968	7,340	0,9954
5 5 5	gauss-gauss-bell	125		4,772	7,124	0,9957
5 5 5	tri – bell - gauss	125		4,965	7,336	0,9954
5 5 5	tri – gauss - bell	125		4,770	7,122	0,9957
5 5 5	gauss - bell - tri	125	X	2,479	2,9188	0,9988
5 5 6	bell – bell - bell	150		4,067	5,795	0,9969
5 5 7	bell – bell - bell	175		3,413	4,607	0,9978

Fonte: O Autor.

Figura 17 - Evolução do RMSE com a arquitetura da ANFIS.

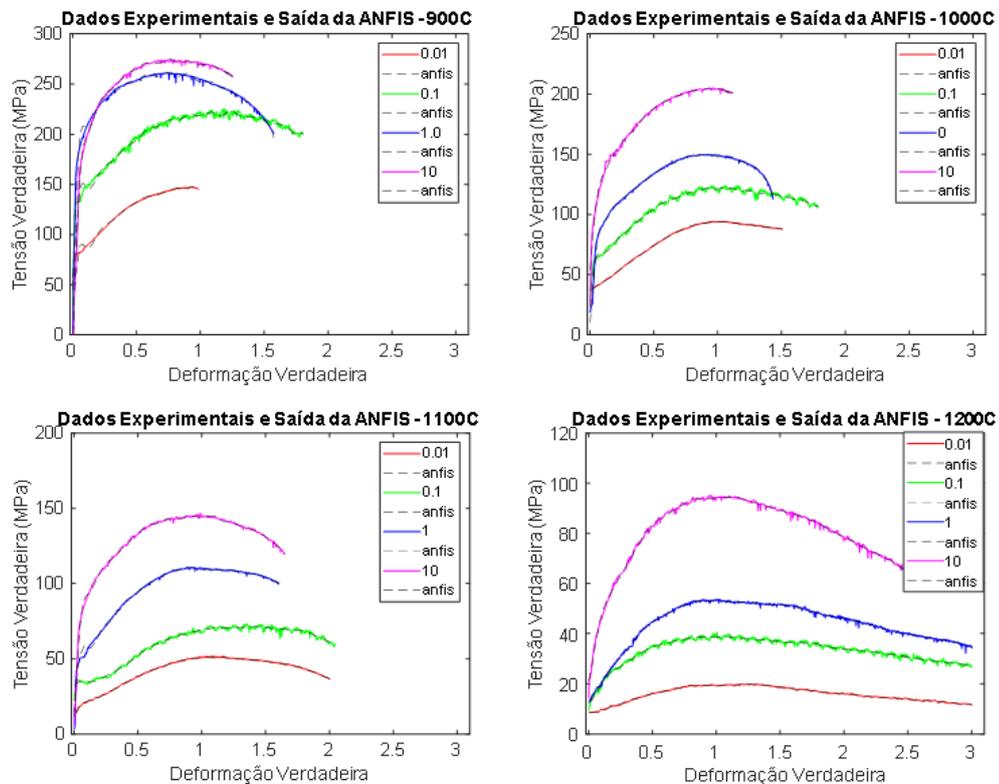


Fonte: O Autor.

Pode-se ver na Figura 17 que os valores da RMSE decrescem conforme o número de regras aumenta. Sendo o número de MFs constantes para a temperatura e para a taxa de deformação, aumentar o número de regras significa aumentar o número de MFs para a deformação. A combinação de três MFs do tipo triangular indica menores valores para RMSE, embora esta curva mostre um aumento na RMSE, quando o número de regras foi 128. Também, foi notado visualmente que quando se usava a função triangular para a deformação, indicado por X na Tabela 6, os desvios nos dados de saída se concentravam em um ponto, distorcendo a forma das curvas. Quando a função seno ou a função gaussiana era aplicada na deformação, combinações com outros tipos de MFs resultavam em diferenças muito pequenas nos valores de RMSE. A combinação de três funções seno foi usada na arquitetura da ANFIS. Assim, o comportamento plástico do aço inoxidável duplex foi modelado utilizando uma ANFIS com (4 4 10) MFs do tipo (gbellmf, gbellmf, gbellmf).

Montando uma ANFIS com (4 4 10) e (gbellmf, gbellmf, gbellmf) como função de pertinência, o conjunto de dados do aço inoxidável duplex foi treinado. Os resultados calculados juntamente com os dados experimentais são apresentados na Figura 18. Vê-se nesta figura que os desvios entre os valores experimentais e os valores calculados são mínimos. Porém, também é possível observar que existem algumas diferenças no ajuste das curvas: o ajuste é melhor em temperaturas mais altas e em taxas de deformação menores (tensões menores) do que em temperaturas mais baixas e taxas de deformação mais altas (tensões mais altas).

Figura 18 - Resultados do processo de aprendizado de máquina com modelagem ANFIS.



Fonte: O Autor.

O modelo ANFIS treinado foi utilizado para investigar a capacidade de generalização do algoritmo. Neste trabalho, o conjunto de dados foi dividido em dois grupos: um com 80% dos dados selecionados para treinar o modelo ANFIS e outro grupo de dados com 20% foi usado para validar a previsibilidade da ANFIS recém treinada. O desvio médio entre os dados calculados e os dados experimentais foi analisado por meio de parâmetros estatísticos e são apresentados na Tabela 5. O resíduo médio entre os pontos de dados medidos e os calculados é de 2,071 MPa para os experimentos de treinamento, representando um erro percentual absoluto médio de 2,048%, e os dados obtidos pela ANFIS representam 99,9% das variações na relação entre tensão e deformação obtida experimentalmente. Vale observar que o desvio médio é significativamente maior na checagem do que no treinamento.

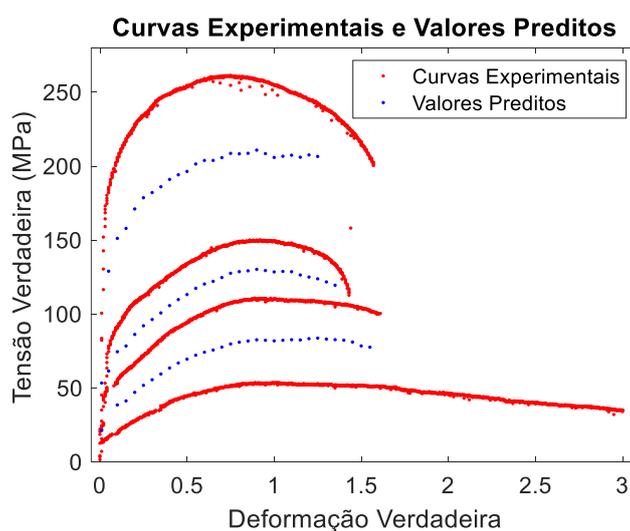
Tabela 7 - Valores de parâmetros estatísticos determinados a partir do processo de aprendizagem.

	RMSE (MPa)	MAPE (%)	R²
Treinamento	2,071	2,048	0,999
Checagem	2,595	5,140	0,999

Fonte: O Autor.

O modelo estabelecido pelo processo de aprendizado de máquina foi usado para prever os valores de tensão em condições em que nenhuma medição experimental foi realizada. A Figura 19 exibe as curvas de previsão de tensão vs. deformação para deformações a 950°C, 1050°C e 1150°C com taxa de deformação de 1 s⁻¹. Pode-se observar nesta figura que as curvas previstas para 950°C, 1050°C e 1150°C assumiram valores intermediários aos das curvas experimentais determinadas em 900°C, 1000°C, 1100°C e 1200°C.

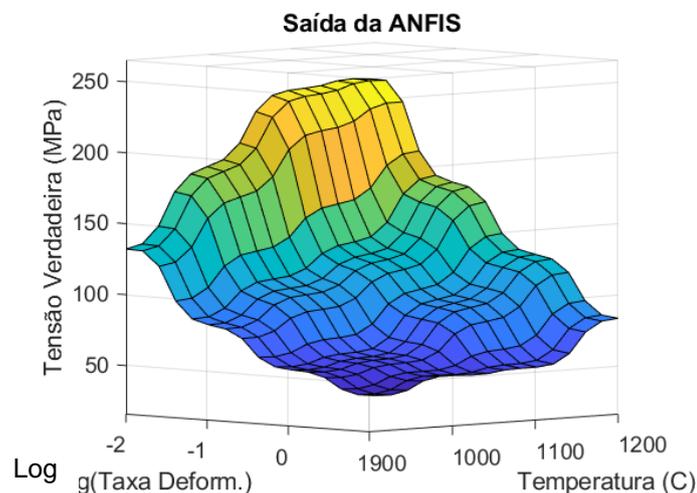
Figura 19 - Valores previstos para a tensão em 950°C, 1050°C e 1150°C com taxa de deformação igual a 1s⁻¹.



Fonte: O Autor.

O algoritmo ANFIS também permitiu observar a dependência dos atributos de entrada com os valores de saída simultaneamente ou isoladamente. O exemplo da Figura 20 mostra a dependência da tensão com a temperatura e a taxa de deformação. Observa-se que a tensão aumenta com a taxa de deformação e queda da temperatura de forma continuada, sendo que esse aumento não é simétrico. Pela forma observada na figura percebe-se que a variação de, por exemplo, 100°C na escala de temperatura tem-se um aumento menor na tensão do que a variação de uma ordem de grandeza nas taxas de deformação no intervalo utilizado nos experimentos.

Figura 20 - Dependência da tensão, com a temperatura e taxa de deformação em log para uma deformação igual a 0,5.



Fonte: O Autor.

Os processos de aprendizado de máquina realizados, com rede neural rasa e com lógica *fuzzy*, exibidos na Figura 15 e Figura 18, indicam que o ajuste entre os dados experimentais e calculados foi satisfatório. Em ambos os casos, o coeficiente de correlação foi de 0,999, indicando que R^2 está próximo de 100%; as curvas previstas representam bem as experimentais. É claro que ambos os modelos preveem bem a verdadeira evolução da tensão do aço inoxidável duplex durante a deformação plástica em alta temperatura e alta taxa de deformação.

Pode-se ver nestas figuras que as curvas de fluxo de tensões previstas por ambas as técnicas são muito semelhantes às experimentais. Porém, comparando as curvas apresentadas nestas figuras, pode-se ver que o ajuste das curvas

experimentais e previstas são algo melhores quando conduzido pelo algoritmo RNA. Visualmente, o ajuste por RNA é muito semelhante para todas as curvas e os parâmetros estatísticos assumem valores menores do que para as previsões ANFIS.

CONCLUSÕES

Para representar as curvas de deformação plástica à quente do aço inoxidável super duplex, a IA apresentou-se capaz de funcionar mesmo não conhecendo totalmente os mecanismos que representam a deformação. Estabeleceu-se vínculos entre os atributos de entrada e saída nos modelos apresentados no processo de aprendizado de máquina que permitiram a previsão de valores para pontos de dados não medidos experimentalmente.

A RNA não precisa conhecer os mecanismos físicos que atuam durante a deformação plástica à quente e o seu algoritmo acompanha melhor o ajuste de curvas experimentais e previstas no aço inoxidável super duplex. A IA apresentou melhor acompanhamento das curvas obtidas, experimentalmente, em baixas taxas de deformação a quente. De qualquer forma, o conhecimento humano subjetivo introduzido nos processos reais com a modelagem ANFIS, utilizado por meio da lógica *fuzzy*, apresentou que as mesmas regras não se adaptam com as diferentes microestruturas do material, mesmo não considerando como entrada no processo de aprendizagem de máquina.

As curvas obtidas pelos modelos desenvolvidos possibilitam maior agilidade para o conhecimento do material em processos industriais permitindo adiantar a preparação da fábrica em trabalhos de conformação a quente em laminação e forjamento em indústrias de transformação na conformação a quente de metais.

REFERÊNCIAS

AHLBLOM, B.; SANDSTROM, R. Hot workability of stainless steels: influence of deformation parameters, microstructural components and restoration process. **International Metals Reviews**. [S. L.], p. 1-27. jul. 2013.

BALANCIN, O.; HOFFMANN, W.A.M.; JONAS, J.J. Influence of microstructure on the flow behavior of duplex stainless steels at high temperature. **Metallurgical And Materials Transactions**. [S. L.], p. 1353-1364. abr. 2012.

BALANCIN O.; HOFFMANN W.A.M.; JONAS J.J. Influence of microstructure on the flow behavior of duplex stainless steels at high temperatures. **Metallurgical and Materials Transactions A**, v. 31A, [S. I.], p. 1353, mai. 2000.

BELADI, H.; CIZEK, P.; HODGSON, P.D. On the characteristics of substructure development through dynamic recrystallization. **Acta Materialia**. [S. L.], p. 3531-3541. maio 2010.

BRANCA, T. A. et al. The challenge of digitalization in the steel sector. **Metals**. [S. L.], p. 288-301. fev. 2020.

CASTAN, C.; MONTHEILLET, F.; PERLADE, A. Dynamic recrystallization mechanisms of an Fe–8% Al low density steel under hot rolling conditions. **Scripta Materialia**. [S. L.], p. 360-364. jun. 2013.

CHEN, D.D. et al. Dislocation substructures and an adaptive-network-based fuzzy inference system model for constitutive behavior of a Ni-based superalloy during hot deformation. **Journal Of Alloys And Compounds**. [S. L.], p. 938-946. mar. 2017.

CIZEK, P.; WYNNE, B.P. A mechanism of ferrite softening in a duplex stainless steel deformed in hot torsion. **Materials Science and Engineering**, [S. I.], v. 230A, p. 88-94, jul. 1997.

CONTINI JR, L.; BALANCIN, O. Modeling and Analysis of the Plastic Flow Curves of a Duplex Stainless Steel Using Artificial Intelligence (AI), 2021.

DEGHAN-MANSHADI, A.; HODGSON, P.D. Dependency of Recrystallization Mechanism to the Initial Grain Size. **Metallurgical And Materials Transactions**. [S. L.], p. 2830-2840. jan. 2008.

DIAS, C.P.; BALANCIN, O. Analysis of hot deformation behavior of super duplex stainless steel UNS S32760 through processing maps. **Revista Escola de Minas**, [S. L.], v. 69, n. 8, p. 155-160, abr-jun. 2016.

DIETER, G.E. **Mechanical Metallurgy**. London: McGraw Hill, 1988. 751 p.

EL WAHABI, M.; CABRERA, J.M.; PRADO, J.M. Hot working of two AISI 304 steels: a comparative study. **Materials Science and Engineering: A**, [S. I.], v. 343, n. 1-2, p. 116-125, 2003.

EL-SHENAWY, E.H. Physical simulation technology for thermo-mechanical processing of metallic alloys using Gleeble system. **Materials Today: Proceedings**, [S. L.], v. 28, n. 2, p. 998-1004, fev. 2020.

GERÔNIMO, F.H.C.; BALACIN, O. Competição entre Recuperação e Recristalização Dinâmica do Aço Inoxidável Austenítico ASTM F 138 utilizado em Implantes Ortopédicos. **Tecnologia em Metalurgia, Materiais e Mineração**. São Paulo, v. 10, n. 2, p. 162-169, jun. 2013.

GOMIDE, F.A.C.; GUDWIN, R.R.; TANSCHKEIT, R. **Conceitos Fundamentais da Teoria de Conjuntos Fuzzy, Lógica Fuzzy e Aplicações**. Departamento de Engenharia de Computação e Automação Industrial (DCA), 2009, 38 p.

GOTTSTEIN, G.; ZABARDJADI, D.; MECKING, H. Dynamic recrystallization in tension-deformed copper single crystals. **Metal Science**, [S. I.], v. 13, n. 3-4, p. 223-227, jan. 1979.

GLOVER, G.; SELLARS, C.M. Recovery and recrystallization during high temperature deformation of α -iron. **Metallurgical Transactions A**, [S. I.], v. 4A, p. 765-775, mar. 1973.

HAGHDADI, H. et al. Dynamic restoration processes in a 23Cr-6Ni-3Mo duplex stainless steel: effect of austenite morphology and interface characteristics. **Metallurgical And Materials Transactions A: Physical Metallurgy And Materials Science**. [S. L.], p. 4803-4820. out. 2017.

HAGHDADI, N. et al. Artificial neural network modeling to predict the hot deformation behavior of an A356 aluminum alloy. **Materials Design**. [S. L.], p. 386-391. ago. 2013.

HAN, Y. et al. A comparative study on constitutive relationship of as-cast 904L austenitic stainless steel during hot deformation based on Arrhenius-type and artificial neural network models. **Computational Materials Science**. [S. L.], p. 93-103. fev. 2013.

HAYKIN, S. **Neural networks and learning machines**. 3^o ed. New York: Prentice Hall, 2008. 906 p.

IMMARIGEON, J-P.A.; JONAS, J. J. The deformation of Armco-iron and silicone steel in the vicinity of the Curie temperature. **Acta Metallurgica**. [S. L.], p. 1235-1248. ago. 1957.

IZA-MENDIA A. et al. Microstructure and mechanical behavior of a duplex stainless steel under hot working conditions. **Metallurgical and Materials Transactions A**, [S. I.], v. 29A, p. 2975-2986, dez. 1998.

JANG J.S.R. ANFIS: adaptive-network-based fuzzy inference system. **IEEE Transactions On Systems, Man, And Cybernetics**. [S. L.], p. 665-685. jun. 1993.

JORGE JR., A.M.; BALANCIN, O., Prediction of steel flow stress under hot working conditions. **Materials Research**, [S. I.], v. 8, n. 3, p. 309-315, set. 2005.

JORGE JR., A.M.; REGONE, W.; BALANCIN, O. Effect of competing hardening and softening mechanisms on the flow stress curve modeling of ultra-low carbon steel at high temperatures. **Journal Of Materials Processing Technology**. [S. L.], p. 415-421. nov. 2003.

JORGE JÚNIOR, A.M.; REIS, G.S.; BALANCIN, O. Influence of the microstructure on the behavior of duplex stainless steel. **Materials Science And Engineering: A**. [S. L.], p. 2559-2564. mar. 2011.

JORGE JUNIOR, A.M. **Análise do comportamento mecânico de aços inoxidáveis em altas temperaturas e altas taxas de deformação**. 1997. [] f. Tese (Doutorado) - Curso de Engenharia de Materiais, Departamento de Engenharia de Materiais, Universidade Federal de São Carlos, São Carlos, 1997.

KAHAR, S.W. Duplex Stainless Steels - An overview. **International Journal Of Engineering Research And Applications**. [S. L.], v.7 (4), p. 27-36. abr. 2017.

KINGKLANG, S.; UTHAISANGSUK, V. Investigation of Hot Deformation Behavior of Duplex Stainless Steel Grade 2507. **Metallurgical And Materials Transactions A**. [S. L.], p. 95-108. out. 2016.

KUMAR, S.; KARMAKAR, A.; NATH, S. K. Construction of hot deformation processing maps for 9Cr-1Mo steel through conventional and ANN approach. **Materials Today Communications**. [S. L.], p. 101-903. dez. 2020.

LAASRAOUI, A.; JONAS, J.J. Prediction of Steel Flow Stresses at High Temperatures and Strain Rates. **Metallurgical Transactions**, [S. l.], v. 22A, p. 1545-1558, jul. 1991.

LIN, Y.C.; CHEN, X.M., A critical review of experimental results and constitutive descriptions for metals and alloys in hot working. **Materials and Design**, [S. l.], v. 32, p. 1733-1759, abr. 2011.

LIN, Y. C. et al. Constitutive models for high-temperature flow behaviors of a Ni-based superalloy. **Materials And Design**. [S. L.], p. 115-123. jul. 2014.

LONGFEI, I.; WANGYUE, Y.; ZUING, S. Dynamic recrystallization of ferrite in a low carbon steel during hot rolling in the (F+A) two-phase region. **Metallurgical And Materials Transactions A**. [S. L.], p. 609-619. nov. 1994.

LOURENÇO, N.J. et al. Plastic behavior of medium carbon vanadium microalloyed steel at temperatures near $\gamma \rightarrow \alpha$ transformation. **Materials Research**. São Carlos-SP, p. 149-156. jul. 2001.

MEDINA S.F., HERNANDEZ C.A. Modelling of the dynamic recrystallization of austenite in low alloy and microalloyed steels. **Acta Materialia**, [S. l.], v. 44, n. 1 p. 165-171, jan.1996.

MECKING, H.; GOTTSTEIN, G.. Recovery and Recrystallization During Deformation. In: HAESSNER, F. **Recrystallization of Metallic Materials**. Stuttgart: Riederer-Verlag, 1978. p. 195-222.

MCQUEEN, H.J.; JONAS, J.J. Recovery and recrystallization during high temperature deformation. In: **Treatise on Materials Science & Technology.**, [S. I.], 393-493, fev.1975.

NEGNEVITSKY, M. **Artificial Intelligence A Guide to Intelligent Systems.** 2^o ed. [S. I.] Addison-Wesley, 2005, 435p.

PATRA, S. et al. Deformation induced austenite formation in as-cast 2101 duplex stainless steel and its effect on hot-ductility. **Materials Science And Engineering: A.** [S. L.], p. 61-70. fev. 2016.

PINOL-JUEZ, A.; IZA-MENDIA, A.; GUTIÉRREZ, I. Interface Boundary Sliding as a Mechanism for Strain Accommodation During Hot Deformation in a Duplex Stainless Steel. **Metallurgical and Materials Transactions A.**, [S. I.], v. (31A), p. 1671-1677, abr. 2000.

REDDY, N. S. et al. Neural network modelling of flow stress in Ti-6Al-4V alloy with equiaxed and Widmanstätten microstructures. **Materials Science And Technology.** [S. L.], p. 294-301. jul. 2013.

REIS, G.S.; BALANCIN, O. Influence of microstructure on the plastic behavior of duplex stainless steels. **Revista Escola de Minas**, Ouro Preto, v. 61, n. 4, p. 499-503, dez. 2008.

RICHARDS P.; SHEPPARD T. Development of structure and effect of processing parameters on strength-structure relationships for two ferritic stainless steels. **Materials science and Technology**, [S. I.], v. 2, p. 836-840, 1986.

RIZHI, W.; LEI, T.C. Microstructural evolution of pure iron during hot rolling. **Materials Science and Technology**, [S. I.], v. 9, p. 698-704, 1993.

ROBERTS, W.; BODÉN, H.; AHLBLÖM, B. Dynamic recrystallization kinetics, **Metal Science.** [S. L.], v. 13, p. 195-205, 1979. Gottstein et al., 1979.

ROSSARD, C.; BLAIN, P. Premiers resultants de recherches sur la deformation des aciers à chaud. Mise au point d'un appareillage spécialement étudié. **La Revue de Métallurgie.** Paris, p. 573-594. jun. 1958.

ROUCOULES, C. **Dynamic and metadynamic recrystallization in HSLA steels.** 1992. 291 f. Tese (Doutorado) - Curso de Engineering Metallurgy, Department Of Mining And Metallurgical Engineering, McGill University, Montreal, 1992.

SENATORE, M.; FINZETTO, L.; PEREA, E. Estudo comparativo entre os aços inoxidáveis dúplex e os inoxidáveis AISI 304L/316L. **Escola de Minas**, [S. L.], v. 1, n. 60, p. 175-181, mar. 2007.

SUMATHI, S.; SUREKHA, P, A **Computational Intelligence Paradigms Theory and Applications using MATLAB®.** CRC Press, New York, 2010, 803p.

TSUJI, N. et al. Occurrence of dynamic recrystallization in ferritic iron. **Nippon Kinzoku Gakkaishi (1952)**, [S. I.], v. 62, n. 10, p. 967-976, 1998.

VABLE, M. **Mechanics of Materials**. 2^o ed. Michigan: Michigan Technological University, 2010. 578 p.

VAFAEENEZHAD, H. et al. Application of constitutive description and integrated ANFIS – ICA analysis to predict hot deformation behavior of Sn-5Sb lead-free solder alloy. **Journal Of Alloys And Compounds**. [S. L.], p. 287-299. dez. 2016.

XIAO, Y. H.; GUO, C., Constitutive modelling for high temperature behavior of 1Cr12Ni3Mo2VNbN martensitic steel. **Materials Science and Engineering A 528**, p. 5081-5087, jun. 2011.

ZA-MENDIA, A. et al. Microestrutural and mechanical behavior of a duplex stainless steel under hot working conditions. **Metallurgical And Materials Transactions A 29A**. [S. L.], p. 2975-2986. dez. 1998.

ZENER, C.; HOLLOMON, J.H. Effect of strain rate upon plastic flow of steel, **Journal of Applied Physics**. [S. L.], v. 15, p. 22-32, abr. 1944.

ZHONG, Ray Y. et al. Intelligent Manufacturing in the Context of Industry 4.0: A Review. **Engineering**. [S. L.], p. 616-630. out. 2017.