



ISSN: 2230-9926

Available online at <http://www.journalijdr.com>

IJDR

International Journal of Development Research

Vol. 11, Issue, 09, pp. 50626-50629, September, 2021

<https://doi.org/10.37118/ijdr.23012.09.2021>



RESEARCH ARTICLE

OPEN ACCESS

MODELAGEM DO COMPORTAMENTO PLÁSTICO DE UM AÇO INOXIDÁVEL DUPLEX UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Leones Contini Jr. and *Oscar Balancin

Programa de Pós-Graduação em Engenharia Mecânica, UFSCar

ARTICLE INFO

Article History:

Received 03rd August, 2021

Received in revised form

28th August, 2021

Accepted 10th September, 2021

Published online 30th September, 2021

Key Words:

Modeling; Flow Stress Curves;
Duplex Stainless Steel.

*Corresponding author:

Oscar Balancin

RESUMO

Amostras de um aço inoxidável super duplex compostas por uma matriz ferrítica e partículas dispersas de austenita foram deformadas com ensaios de torção nas temperaturas de 900°C a 1200°C e taxas de deformação variando de 0,01 s⁻¹ a 10 s⁻¹. Os resultados desses experimentos são apresentados na forma de curvas de escoamento plástico com a temperatura e a taxa de deformação constantes. A forma das curvas depende da temperatura e da taxa de deformação e varia com a fração volumétrica de austenita; o fluxo plástico em aços bifásicos é mais complexo que em materiais monofásicos. Com os dados obtidos nos experimentos foi construído 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 um algoritmo de aprendizagem de máquina que consiste em uma rede neural artificial com uma camada escondida. Após o processo de aprendizagem de máquina, as curvas de escoamento plástico foram reconstruídas e comparadas com as obtidas experimentalmente. Fez-se a predição de curvas em condições não medidas experimentalmente e discutem-se os resultados obtidos.

Copyright © 2021, Leones Contini Jr. and Oscar Balancin. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Citation: Leones Contini Jr. and Oscar Balancin. 2021. "Modelagem do Comportamento Plástico de um Aço Inoxidável Duplex Utilizando Inteligência Artificial", *International Journal of Development Research*, 11, (09), 50626-50629.

INTRODUÇÃO

Atualmente estão em curso transformações nos meios de produção industrial visando substituir operações manuais ou mecanizadas por operações automatizadas controladas por inteligência artificial (IA) [Schwab, 2017]. Modelos matemáticos com diferentes arquiteturas computacionais estão sendo formulados para calcular os parâmetros operacionais com precisão. Valores de parâmetros como o posicionamento e a velocidade de deslocamento das ferramentas, ou do material, e a temperatura das peças que estão sendo deformadas durante o processamento metalúrgico a quente podem ser captados com boa precisão por sensores inseridos nas máquinas e transferidos à programas computacionais através da internet das coisas (IoT). Todavia, o comportamento plástico dos materiais não pode ser determinado diretamente nos meios de produção. Usualmente, o comportamento plástico a quente de materiais metálicos é determinado em escala de laboratório na forma de curvas de escoamento plástico [El-Shenawy]. Alguns materiais como o alumínio puro ou o ferro alfa recuperam-se extensivamente quando deformados a quente ou a morno. Outros materiais como ligas de níquel, de cobre e em especial ligas de ferro com estrutura austenítica recristalizam-se dinamicamente durante a deformação a quente após certa quantidade de deformação. É bem conhecido que a ferrita recupera extensivamente durante a deformação enquanto que a

austenita recristaliza dinamicamente após certa quantidade de encruamento e recuperação dinâmica [Cizek, 1997]. Quando a deformação é conduzida com temperatura e taxa de deformação constantes, a tensão de fluxo aumenta no regime inicial de encruamento e então se torna constante na fase ferrítica quando deformada isoladamente; em contraste a tensão experimenta um máximo antes que decrescer para um estado estacionário na fase austenítica [Jorge, 2003]. Esses materiais que têm comportamentos plástico bem conhecidos e parametrizáveis permitem a aplicação de modelos fenomenológicos - equilíbrio da taxa de geração e aniquilação de discordância e/ou a equação de Avrami - para descrever matematicamente o seus comportamentos [Jorge, 2005]. Existem materiais que têm comportamentos plástico mais complexo como é o caso de ligas bifásicas como os aços inoxidáveis duplex. Nas condições de processamento a quente os aços inoxidáveis duplex ferrítico-austeníticos são constituídos de partículas de austenita embebidas em uma matriz ferrítica. Quando as duas fases são deformadas juntas, a distribuição de deformação não é mais uniforme havendo concentração de deformação na fase alfa mais macia no início da deformação. Conforme a deformação prossegue, os gradientes de deformação podem ser decrescido com a ação de mecanismos de amaciamento como a recuperação e a recristalização dinâmicas, tão bem como deslizamento de interfaces e de contornos de grão ou mesmo com a deformação localizada na fase ferrítica [Balancin, 2000; Piñol-JJuez, 2000; Jorge, 2011]. Após certa

quantidade de deformação, com a transferência de tensão para a fase austenítica, pode ocorrer a fragmentação dessas partículas. Em consequência, a construção de modelos fenomenológicos para descrever o comportamento plástico desses materiais necessita de mais investigações. Neste manuscrito descreve-se uma alternativa realística e bastante atual para fazer a modelagem das curvas de escoamento plástico de um aço inoxidável super duplex utilizando uma técnica de inteligência artificial.

MATERIAIS E MÉTODOS

O material utilizado neste trabalho foi um aço inoxidável super duplex - UNS S32760 - com a composição química indicada na tabela 1.

Tabela 1. Composição química do aço super duplex (% 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.

Ensaio mecânico: Os ensaios mecânicos foram conduzidos em uma máquina horizontal de ensaios de torção a quente, à qual está acoplada um microcomputador, que por meio de interfaces possibilita a intercomunicação máquina-computador, permitindo o controle dos ensaios e a aquisição de dados. Na realização dos ensaios, as amostras foram aquecidas até 1200°C, mantidas nesta temperatura durante 10 minutos em uma atmosfera protegida com argônio, em seguida resfriadas até a temperatura de deformação, sendo mantidas nestas temperaturas durante 30 segundos para eliminar os gradientes térmicos. Os testes de torção a quente foram realizados em 900°C, 1000°C, 1100°C e 1200°C com taxas de deformação de 0,01, 0,1, 1 e 10 s⁻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 medidas por sensores (encoder e célula de torção) acoplados à máquina e enviados ao software que construía as curvas tensão equivalente vs. deformação equivalente.

Aprendizado de máquina: A partir dos dados obtidos nos ensaios foi construída uma tabela contendo os valores dos atributos de entrada e dos valores de saída. Neste caso são considerados “inputs” os valores da temperatura, da taxa de deformação e da deformação e “outputs” os valores da tensão aplicada pela máquina. Neste trabalho foi utilizado como algoritmo de aprendizagem de máquina uma rede neural artificial (RNA) rasa com uma camada escondida. RNA é um modelo matemático e/ou computacional que *mimetiza* a estrutura e aspectos funcionais de uma rede neural biológica [Sumathi, 2010]. Uma RNA consiste de um conjunto de neurônios artificiais interconectados que processam informações usando métodos computacionais (Figura 1). Esses neurônios processam os dados paralelamente e os propagam através de uma malha complexa de interconexões. Analogamente ao cérebro humano, as RNAs têm a capacidade de interagir com o meio externo e adaptar-se a ele. Uma RNA pode aprender a partir de exemplos e reconhecer trajetórias em uma série de dados de entradas (input) e saídas (output) sem nenhum conhecimento anterior de suas naturezas e interrelações. A RNA não necessita conhecer os mecanismos físicos que atuam durante a deformação a quente. Assim, é esperado que ela tenha a habilidade de modelar e prever o comportamento plástico a quente do aço inoxidável duplex cujo comportamento plástico não é totalmente conhecido. O treinamento de uma rede neural consiste em ajustar os pesos associados a cada conexão entre neurônios. No processo “feedforward” cada sinal de entrada evolui ao longo da rede até a camada de saída. Na camada final é gerado o valor de saída que é comparado com o valor real. Após determinar a diferença, o algoritmo “backpropagation” ajusta os pesos de forma que o valor seguinte a ser calculado esteja mais próximo do valor real. Uma rede neural artificial do tipo “feed forward back propagation” treinada com o algoritmo Levenberg-Marquardt foi utilizada para prever a tensão de escoamento plástico do aço inoxidável duplex.

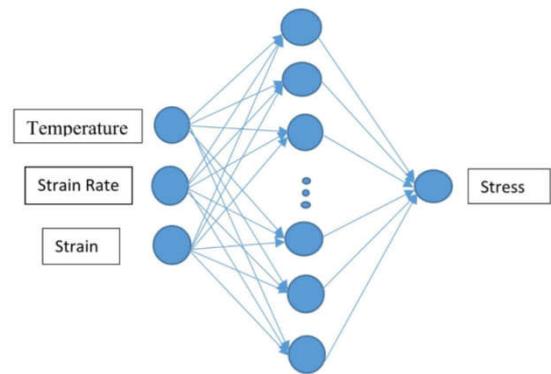


Figura 1. Representação esquemática da arquitetura de uma rede neural artificial com uma camada escondida

O processo de aprendizado é baseado na descida do gradiente que requer uma função de ativação diferenciável. Assim, a função sigmoideal logística foi aplicada como função de ativação. Uma descrição detalhada do algoritmo usado neste estudo está fora do alcance deste texto e pode ser encontrado na literatura [Sumathi, 2010]. A função de ativação juntamente com o número de neurônios na camada escondida define a arquitetura de uma RNA rasa. O número de neurônios na camada escondida é determinado pela experiência ou por tentativa e erro. Neste trabalho, para se determinar a melhor resolução, um experimento foi conduzido variando de 1 a 25 o número de neurônios na camada escondida. 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), raiz quadrada do erro médio quadrático (RMSE) e o coeficiente de correlação (R).

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

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

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

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.

RESULTADOS

Curvas de escoamento plástico: A Figura 2 mostra as curvas de escoamento plástico obtidas experimentalmente. Essas curvas têm a forma característica do comportamento mecânico a quente de aços; a tensão aumenta com a deformação até um máximo e decresce em seguida. Pode-se ver nesta Figura que as amostras deformadas em baixas temperaturas e com altas taxas de deformações falham com deformações próximas a 1,0 – 1,5. Por outro lado, amostras deformadas em altas temperaturas e baixas taxas de deformação suportam maiores deformações, sendo que em 1200°C com taxas de deformação de 0,01 a 1s⁻¹ o material não falhou nem mesmo com deformação de 3,0. Todavia, o estado estacionário de tensões em grandes deformações não foi alcançado. Vê-se nesta figura 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 10s⁻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.

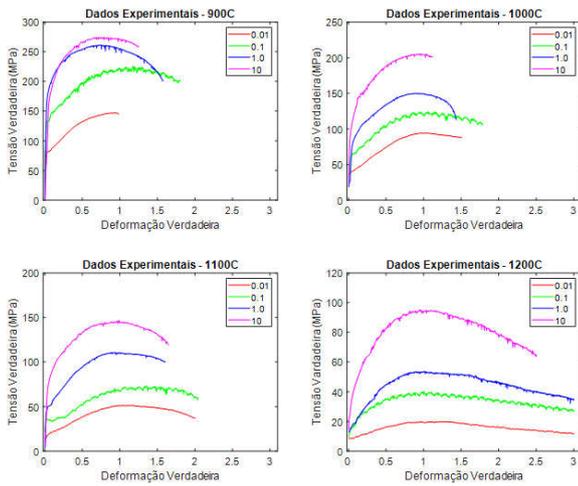


Figura 2. Curvas de escoamento plástico obtidas nos ensaios de torção a quente

Ao alcançar o máximo, pode ou não apresentar uma faixa de deformações com tensão constante, vindo a decrescer em seguida. Essas alterações nas formas das curvas de escoamento plástico tornam a modelagem matemática com modelos fenomenológicos ou com base científica mais complexa; seriam necessários dois ou mais conjuntos de equações para descrever o comportamento mecânico deste material.

Rede neural Artificial: Os dados experimentais gerados pelas curvas tensão vs. deformação foram rearranjados na forma de uma tabela e submetidos ao processo de aprendizagem de máquina utilizando uma rede neural rasa. Neste trabalho, os dados foram separados em três conjuntos: 70% para o treinamento, 15% para a validação e 15% para teste. Para encontrar o número de neurônios na camada escondida foi calculada a evolução da raiz quadrada do erro médio quadrático (RMSE) aumentando o número de neurônios nesta camada de 1 a 25 com mostrado na Figura 3.

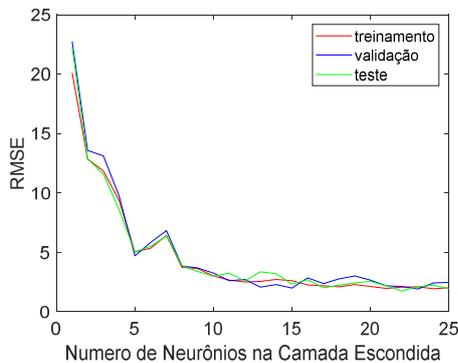


Figura 3. Evolução da RMSE com o número de neurônios na camada escondida

Vê-se na Figura 3 que o valor do RMSE decresce conforme o número de neurônios é aumentado: para poucos neurônios a inclinação da curva é grande enquanto que para 15 ou mais neurônios o erro é basicamente constante considerando o treinamento, a validação e o teste. Essas informações juntamente com a função de ativação sigmoidal definem a arquitetura da RNA (3 x 18 x 1) usada neste exercício. A Figura 4 apresenta o resultado do processo de aprendizagem de máquina. Estão plotados juntos os valores medidos e os valores preditos pela RNA. No processo de aprendizagem o algoritmo cria um modelo que descreve a relação entre os dados de entrada e os dados de saída. Com esse modelo calculam-se os dados de saída. Comparando-se os valores medidos e os calculados determinam-se os erros do processo de aprendizagem. Visualmente, pode-se observar nesta figura que há um bom ajuste entre os dados, indicando que o processo de aprendizagem teve sucesso.

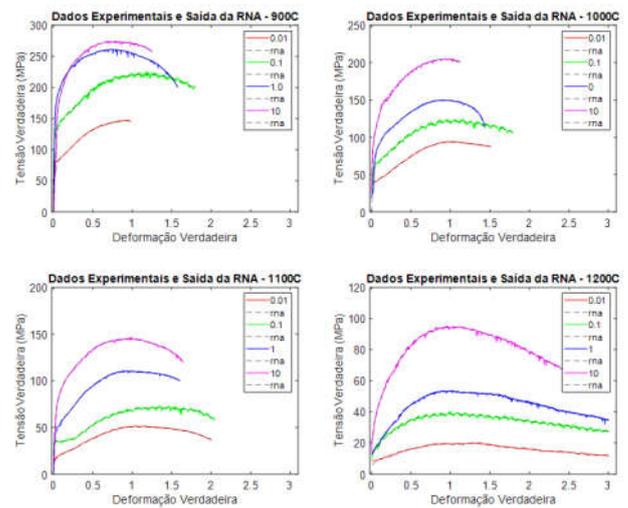


Figura 4. Curvas de escoamento plástico experimentais e calculadas com a RNA

Tabela 2. Valores dos parâmetros estatísticos determinados pelo processo de aprendizagem de máquina

	RMSE (MPa)	MAPE (%)	R ²
Treinamento	2,176	1,552	0,999
Validação	2,163	1,457	0,999
Teste	2,415	1,619	0,999

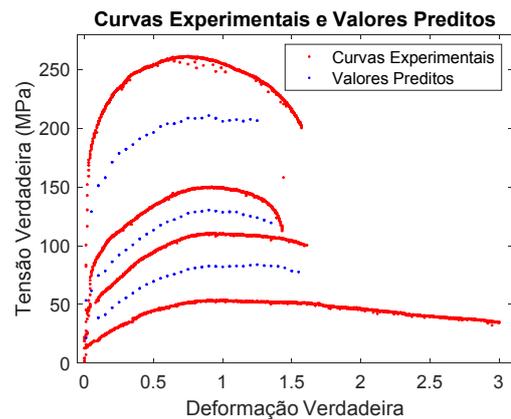


Figura 5. Valores preditos para a relação tensão vs. deformação em 3 temperaturas diferentes das medidas experimentalmente

Os desvios entre os valores medidos e calculados foram analisados utilizando parâmetros estatísticos, cujos valores estão descritos na Tabela 2. O resíduo médio entre os valores medidos e calculados em cada ponto é de 2,176 MPa para os experimentos de treinamento, que representa um erro porcentual de 1,552% e os dados obtidos pela RNA representam 99,9% da variação na relação entre a tensão e a deformação medida experimentalmente. Os valores dos parâmetros estatísticos determinados são similares tanto no treinamento quanto na validação e nos testes. Esses valores indicam que o modelo tem grande habilidade de predição e alta precisão para determinar a tensão de escoamento durante a deformação a quente, mesmo para um material cuja forma da curva de escoamento depende de outros parâmetros tais como a fração volumétrica de uma segunda fase, que não foi considerada neste estudo. O modelo estabelecido pelo processo de aprendizagem de máquina foi utilizado para prever valores de tensões em condições não medidas experimentalmente. Na figura 5 estão plotados, juntamente com as curvas experimentais determinadas em 900°C, 1000°C e 1200°C, valores preditos para a relação entre a tensão e deformação para 950°C, 1050°C e 1150°C. Pode-se ver que as curvas preditas apresentam valores intermediários aos obtidos experimentalmente.

DISCUSSÃO

Neste exercício, utilizou-se um modo de deformação típico de laboratório, cujo estados de tensões e de deformações são bem conhecidos. Ao observar os resultados experimentais mostrados na Figura 2, pode-se notar que ocorrem alterações no comportamento mecânico do material conforme as condições de deformação foram alteradas. Está bem estabelecido na literatura [Jorge, 2011] que, ao reduzir a temperatura após o reaquecimento das amostras do aço inoxidável super duplex, ocorre a transformação de ferrita em austenita com a nucleação e crescimento de partículas de austenita dentro da matriz ferrítica. Na Figura 6 pode-se observar diferenças na distribuição e fração volumétrica de partículas de austenita, para amostras deformadas a 1200°C e a 1000°C com taxa de 1s⁻¹. Em baixas temperaturas não apenas as partículas de austenitas que estavam presentes durante o reaquecimento mas também partículas precipitadas durante o resfriamento e a deformação podem ser observadas na Figura 6b; partículas menores entre as maiores que vieram do reaquecimento. Assim, a fração volumétrica de austenita altera-se desde menores quantidades em altas temperaturas até frações volumétricas próximas às da ferrita quando a temperatura é decrescida durante a deformação [Jorge, 2011]. Em altas temperaturas, quando a fração volumétrica de austenita é menor, a deformação se concentra na ferrita que é mais macia, como pode ser observado na figura 6(a). Neste caso há o fluxo da ferrita paralelamente e ao redor das partículas de austenita; predominando a recuperação dinâmica da ferrita.

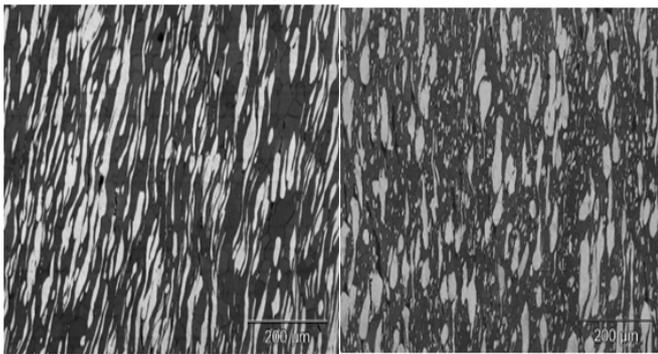


Figura 6. Microestrutura de amostras deformadas com 1.0 s⁻¹ em (a) 1200°C e (b) 1000°C

Ao diminuir a temperatura de ensaio, a fração volumétrica de austenita aumenta, reduzindo o espaçamento entre as partículas. Antes de serem deformadas, as partículas de austenita estavam alinhadas com o eixo horizontal dos corpos de prova. Ao deformar o material, essas partículas são rotacionadas tendendo a se alinharem com a direção da tensão cisalhante máxima, ocorrendo maior transferência de tensão e deformação para a austenita. Em consequência, as partículas de austenita são alongadas em seus comprimentos e comprimidas lateralmente tendendo a se aglomerarem, como mostrado na Figura 6(b).

Observando esse modo de deformação, pode-se especular que além da recuperação e recristalização dinâmicas, pode ocorrer o deslizamento de contornos de fase ou mesmo a fragmentação de partículas de austenita. Em consequência, conforme o material é deformado observa-se a fratura das amostras com menores quantidades de deformação. Ao modelar as curvas de escoamento plástico do aço inoxidável duplex utilizando redes neurais artificiais não foi necessário o entendimento dos mecanismos que controlam o processo de deformação plástica. Neste exercício não foi considerado a variação da fração volumétrica de austenita e suas consequências no comportamento do aço. E, mesmo assim, esta tarefa pôde ser conduzida de forma satisfatória, como mostram os resultados obtidos.

CONCLUSÕES

A utilização de uma técnica de inteligência artificial permitiu a modelagem de forma satisfatória das curvas de escoamento plástico a quente de um material cujos mecanismos que atuam durante a deformação a quente não são totalmente conhecidos. O processo de aprendizagem de máquina gerou modelos estabelecendo relações entre os atributos de entrada e de saída, permitindo a predição de valores para curvas de escoamento plástico não medidas experimentalmente.

REFERÊNCIAS

- Balancin, O., Hoffmann, W.A.M., Jonas, J.J. 2000. Influence of microstructure on the flow behavior of duplex stainless steels at high temperature. *Metal. Mater. Trans. A* 31A 1353-1364.
- Cizek, P.; Wynne, B.P., 1997. A mechanism of ferrite softening in a duplex stainless steel deformed in hot torsion. *Mater. Sci. Eng. A* 230 88-94.
- El-Shenawy, E. H. 2019. Physical Simulation of Thermo-Mechanical Processing of Metallic Alloys using Gleeble System. *Materials Today: Proceedings*, <https://doi.org/10.1016/j.matpr.12.339>.
- Jorge Jr, A.M., Regone, W., Balancin, O. 2003. 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*, v.142 415-421.
- Jorge Jr., A.M., Balancin, O., 2005. Prediction of steel flow stress under hot working conditions. *Materials Research* 8 309-315.
- Jorge Jr., A.M.; Reis, G.S.; Balancin, O., 2011. Influence of the microstructure on the behavior of duplex stainless steel. *Mater Sci. Eng. A* 528 2259-2264.
- Piñol-JJuez, A.; Iza-Mendia, A.; Gutiérrez, J., 2000. δ/γ Interface boundary sliding as a mechanism for strain accommodation during hot deformation in a duplex stainless steel. *Metal. Trans. A* 31A 1671-1677.
- Schwab, K. 2017. *A Quarta Revolução Industrial*. Ed. Edipro, São Paulo.
- Sumathi, S.; Surekha, P. 2010. *A Computational Intelligence Paradigms Theory and Applications using MATLAB®*. CRC Press, Taylor & Francis Group, New York.
