



Workshop de Pesquisa
em Manufatura

ANAIS DO V WORKSHOP DE PESQUISA EM MANUFATURA



Workshop de Pesquisa
em Manufatura

ANAIS DO V WORKSHOP DE PESQUISA EM MANUFATURA



EDITORA
OMNIS SCIENTIA

Editora Omnis Scientia

ANAIS DO V WORKSHOP DE PESQUISA EM MANUFATURA

Volume 1

1ª Edição

TRIUNFO – PE

2021

PROMOÇÃO:

Programa de Pós-Graduação em Engenharia Mecânica (PPGEMec/UFSCar)

Apresentadores (as):

Adailton Gomes Pereira

Alana Carla Miranda Araújo

Bruna Oliveira da Silva

Bruno Alexandre Roque

Caique de Castro Gonçalves

Cassiano da Silva Tavares

Cristie Luis Kugelmeier

Gustavo Roberto dos Santos

Henrique A. C. Durello

Hugo Emanuel de Andrade Costa

Jonatan Augusto da Silva

Leones Contini Junior

Marco Gabriel Lorenzoni

Matheus Luis Manfredo

Paulo De Tarso Durigan

Rafael Fernando Teixeira

Talia Gibim

Tony Emerson Marim.

Participantes do painel:

Carlos Eiji Hirata Ventura

Danielle Cristina Camilo Magalhães

Rodrigo da Silva (“PPGEMec: Presente e futuro”).

Palestrante:

Yayue Pan - University of Illinois Chicago (“Field-assisted Photopolymerization-based Additive Manufacturing for Productions of Multi-Functional Materials and Devices”)

Comitê científico:

Alexandre Tácito Malavolta

Carlos Eiji Hirata Ventura

Danielle Cristina Camilo Magalhães

Flávio Yukio Watanabe

Marcos Roberto Monteiro

Rodrigo da Silva

Sérgio Henrique Evangelista.

Comissão organizadora:

Adailton Gomes Pereira

Armando Ítalo Sette Antonialli

Bruna Oliveira da Silva

Edson Bruno Lara Rosa

Sidney Bruce Shiki.

Imagem de Capa

Freepik

Edição de Arte

Vileide Vitória Larangeira Amorim

Revisão

Os autores



Este trabalho está licenciado com uma Licença Creative Commons – Atribuição-NãoComercial-SemDerivações 4.0 Internacional.

O conteúdo abordado nos artigos, seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores.

**Dados Internacionais de Catalogação na Publicação (CIP)
(eDOC BRASIL, Belo Horizonte/MG)**

W912a Workshop de Pesquisa em Manufatura (5 : 2021)
Anais do [...] / V Workshop de Pesquisa em Manufatura, 10
dezembro 2021. – Triunfo, PE: Omnis Scientia, 2021.
52 p.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

ISBN 978-65-88958-78-0

DOI 10.47094/978-65-88958-78-0

1. Engenharia mecânica – Brasil – Congressos. 2. Manufaturas.
I. Título.

CDD 621.7

Elaborado por Maurício Amormino Júnior – CRB6/2422

Editora Omnis Scientia

Triunfo – Pernambuco – Brasil

Telefone: +55 (87) 99656-3565

editoraomnisscientia.com.br

contato@editoraomnisscientia.com.br



PREFÁCIO

A exemplo do ensino e da extensão, a pesquisa no âmbito da Engenharia Mecânica apresenta-se bastante ampla e diversificada. A ramificação mais canônica dessa modalidade de engenharia aponta para três áreas fundamentais: Projeto de Sistemas Mecânicos, Ciências Fluidotérmicas e Processos de Fabricação. Outras subdivisões, como Dinâmica e Vibrações, Mecatrônica e Metrologia, flutuam entre as três grandes áreas. Sendo assim, a nucleação e o crescimento do Grupo de Pesquisa em Manufatura Inteligente (GPMI), devidamente registrado no Diretório dos Grupos de Pesquisa do CNPq e reconhecido pela UFSCar, têm sido salutar no sentido da consolidação do Departamento de Engenharia Mecânica (DEMec) e do curso de graduação em Engenharia Mecânica. Da mesma forma, O GPMI se mostra essencial enquanto alicerce para o recém-criado curso de mestrado acadêmico dentro do Programa de Pós-Graduação em Engenharia Mecânica (PPGEMec), conferindo-lhe vocação e identidade. Finalmente, a comunicação e a difusão dos resultados obtidos pelo grupo propiciam o alinhamento do mesmo ao lema da UFSCar: excelência acadêmica e compromisso social. O objetivo geral do "V Workshop de Pesquisa em Manufatura" consiste em disseminar os trabalhos em andamento dentro do Grupo de Pesquisa em Manufatura Inteligente (GPMI) e de outros grupos afins à área de Manufatura, promovendo discussões profícuas e de alto nível com o público interno e externo à universidade. Como objetivos específicos, destacam-se a exposição dos estudantes de graduação e pós-graduação a um ambiente de conferência científica sem sair de casa e a oportunidade de contar com convidados com grande potencial de contribuição a essa área do conhecimento. O evento foi realizado ao longo do dia 10 de dezembro de 2021, de forma online, de maneira a viabilizar e fomentar a participação de uma parcela significativa de estudantes.

SUMÁRIO

INFLUÊNCIA DA SENSIBILIDADE DE PARÂMETROS DOS MODELOS DE AVRAMI NAS CINÉTICAS DE RECRISTALIZAÇÃO SOBRE O TAMANHO DE GRÃO EM UM PROCESSO DE LAMINAÇÃO A QUENTE DE LIGA DE AÇO SAE 4140.....	10
SIMULAÇÃO NUMÉRICA DA EXTRUSÃO EM CANAL ANGULAR COM TORÇÃO (ECA-T): INFLUÊNCIA DA GEOMETRIA NA DEFORMAÇÃO.....	13
OTIMIZAÇÃO TOPOLÓGICA APLICADA NO CONTEXTO DE PRÓTESES HUMANAS.....	15
PROCESSO DE DOBRAMENTO A FRIO DE CHAPAS FINAS METÁLICAS: ANÁLISES POR ELEMENTOS FINITOS, EXPERIMENTOS E MODELO MATEMÁTICO PARA COMPENSAÇÃO DO RETORNO ELÁSTICO.....	17
FORÇAS NA ESTAMPAGEM INCREMENTAL DE CHAPA FINA METÁLICA POR MEIO DE EXPERIMENTOS E ANÁLISES POR ELEMENTOS FINITOS.....	19
MODELAGEM DE CURVAS DE FLUXO PLÁSTICO DE UM AÇO BIFÁSICO UTILIZANDO INTELIGÊNCIA ARTIFICIAL.....	22
APLICAÇÃO DA TECNOLOGIA DE MACHINE LEARNING PARA AVALIAÇÃO DA QUALIDADE DE PEÇAS IMPRESSAS EM 3D.....	24
ESTUDO DA PREVISIBILIDADE DO ERRO DE TRANSMISSÃO DE ENGRENAGENS DE DENTES RETOS PARA PROJETO DE MODIFICAÇÕES DE MICROGEOMETRIA.....	26
CONTRIBUIÇÃO DO PRÉ-AQUECIMENTO DO SUBSTRATO NA PREVENÇÃO DE TRINCAS EM REVESTIMENTOS GERADOS POR LASER CLADDING.....	28
AVALIAÇÃO DA INFLUÊNCIA DA VELOCIDADE DE CORTE SOBRE O ESTADO DE SUPERFÍCIE NO TORNEAMENTO DA LIGA TI-6AL-4V ELI.....	30
INFLUÊNCIA DO TAMANHO DO GRÃO DO REBOLO NA QUALIDADE SUPERFICIAL DO INSERTO DE CORTE DE METAL DURO RETIFICADO.....	36
INVESTIGAÇÃO DOS MECANISMOS DE REMOÇÃO DE MATERIAL NA RETIFICAÇÃO DE INSERTOS DE CORTE.....	38
SHUNT PIEZOELÉTRICO PARA CONTROLE PASSIVO DE CHATTER NO PROCESSO DE TORNEAMENTO DE LIGAS DE TITÂNIO.....	40
AVALIAÇÃO DE TEXTURAS INDUZIDAS POR VIBRAÇÃO NO TORNEAMENTO DURO DE UM AÇO FERRAMENTA.....	42
INVESTIGAÇÃO DA INFLUÊNCIA DO CONTROLE TÉRMICO ATIVO SOBRE A RESISTÊNCIA MECÂNICA E QUALIDADE SUPERFICIAL DE PEÇAS IMPRESSAS PELA TÉCNICA FPM.....	44

ATUALIZAÇÃO DE MÁQUINAS-FERRAMENTA ANTIGAS ATRAVÉS DE INSTRUMENTAÇÃO DE BAIXO CUSTO: UM ESTUDO SOBRE O EFEITO DO MONITORAMENTO DO PROCESSO DE TORNEAMENTO NA QUALIDADE SUPERFICIAL.....	46
AVALIAÇÃO MICROESTRUTURAL DO AÇO INOXIDÁVEL LEAN DUPLEX 2404 APÓS SIMULAÇÕES DE CICLOS TÉRMICOS DE ZONAS TERMICAMENTE AFETADAS REALIZADAS POR GLEEBLE.....	48
AVALIAÇÃO DA INFLUÊNCIA DO ACABAMENTO SUPERFICIAL NA RESISTÊNCIA À CORROSÃO DO AÇO 1020 EM BIODIESEL E SUAS MISTURAS COM ÓLEO DIESEL.....	50

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

Leones Contini Junior, UFSCAR, São Carlos, Brasil, rpleonesjr@yahoo.com.br

Oscar Balancin, UFSCAR, São Carlos, Brasil, balancin@ufscar.br

Resumo: Curvas de tensão de fluxo de metais com ligas em condições de trabalho a quente são primordiais nos processos de conformação de metais. O aço inoxidável super duplex com matriz de ferrita e partículas de austenita dispersa foram deformadas por testes de torção a quente. Simulou-se o comportamento plástico deste material usando dados apenas da região da deformação plástica e construí-se uma planilha com quatro colunas. Os atributos de entrada foram temperatura, taxa de deformação, deformação e tensão imposta pelo material durante a deformação. Estes foram submetidos a algoritmos de aprendizado de máquina em uma rede neural artificial com uma camada oculta (RNA) e depois em uma rede neural com um sistema especialista (ANFIS), resultando em curvas de fluxo plástico as quais foram comparadas com as obtidas experimentalmente. A capacidade de ambos os algoritmos de reconstruir as curvas de fluxo foram associadas às mudanças nas formas das curvas de fluxo e evolução da microestrutura. Observou-se que as curvas de tensão de escoamento previstas pelas duas técnicas foram muito semelhantes às experimentais. O ajuste das curvas experimentais e previstas é melhor quando utilizado pelo algoritmo RNA. A IA foi capaz de funcionar sem conhecer totalmente os mecanismos que representam a deformação.

Palavras-chaves: Conformação, Rede Neural, Fuzzy, Modelo.

1. INTRODUÇÃO

Existem materiais que têm comportamento plástico bastante complexo como é o caso dos aços inoxidáveis super duplex. Usualmente, o comportamento plástico de materiais metálicos é determinado em escala de laboratório na forma de curvas de escoamento plástico. Essas curvas são determinadas em largas faixas de condições de trabalho, mas não necessariamente nos valores em que são realizadas as operações industriais. Assim, para transportar os valores experimentais para a prática industrial, torna-se necessário tomar valores aproximados e uma alternativa é a modelagem matemática dessas curvas (Eren *et al.*, 2021).

O comportamento plástico de muitos materiais não é conhecido, exigindo outro caminho para modelar as suas curvas de fluxo plástico. Uma alternativa realística e bastante atual é a utilização de técnicas de inteligência artificial (IA) (Wang *et al.*, 2020).

A combinação da IA com redes neurais e as capacidades de aprendizagem do sistema de inferência de lógica difusa pode ser utilizada para estabelecer relações de mapeamento precisas entre dados de entrada e saída (Jang, 1993). Os sistemas fuzzy utilizam um método matemático para introduzir o conhecimento humano subjetivo nos processos reais. O ANFIS tem sido aplicado para diferentes materiais com bom desempenho (Vafaezhad *et al.*, 2017).

Estudos comparando a aptidão atingida por IA com aquela obtida com modelos fenomenológicos ou com os modelos constitutivos de base física indicam melhor fitness com IA (Haghdadi *et al.*, 2013; Kumar *et al.*, 2021)

Uma vez que esses algoritmos não postulam nenhuma expressão matemática específica e podem ser facilmente estabelecidos com base em dados experimentais, espera-se que seja possível modelar e prever o comportamento de 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. MATERIAIS E MÉTODOS

O material utilizado neste trabalho foi o aço inoxidável super duplex - UNS S32760 – (Tabela 1).

Tabela 1 – Composição química do aço inoxidável 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.

Os ensaios foram realizados em uma máquina horizontal de ensaios de torção a quente, acoplada a um micro-computador por meio de interfaces que possibilitam a intercomunicação máquina-computador, permitindo o controle do ensaio e a aquisição de dados.

Os testes de torção a quente foram realizados a 900 °C, 1000 °C, 1100 °C e 1200 °C com taxas de deformação de 0,01, 0,1, 1 e 10 s⁻¹. Essas temperaturas e as taxas de deformação foram impostas e controladas pelo software. As tensões necessárias para deformar o material foram medidas por sensores (codificador e célula de torção) acoplados à máquina e enviados ao

software para a construção das curvas verdadeiras tensão x deformação.

Utilizou-se dois algoritmos de aprendizado de máquina: rede neural artificial rasa (RNA) com uma camada oculta e a combinação de uma RNA com lógica fuzzy, criando um sistema de inferência neuro-fuzzy adaptativo (ANFIS).

Na aplicação da ANFIS foram feitos experimentos de treinamento e de teste. Assim, a base de dados foi separada em base de treinamento e base de testes e definiu-se com bastante cuidado a deformação de ruptura do corpo de prova em cada ensaio. No processo de aprendizagem de máquina, as curvas de escoamento plástico foram reconstruídas e comparadas com as obtidas experimentalmente. A construção de um sistema neuro-fuzzy permitiu a análise dos parâmetros nas respostas obtidas. A montagem do algoritmo, aprendizagem de máquina e linguagem de programação foram feitas utilizando o software Matlab.

Embora o trabalho tenha sido projetado para usar a caixa de ferramentas 'Fuzzy Logic Designer', em diversas ocasiões, foi necessário escrever os códigos para que fossem obtidos resultados mais adequados. Após adequação da base de dados, foi utilizado o tool box do fuzzy logic designer para promover o aprendizado de máquina. Neste processo, o computador construiu o modelo do material em estudo. Após o aprendizado de máquina, foi necessário determinar o erro comparando os dados experimentais com os dados calculados pelo modelo. Para isso, atentou-se ao erro, ou seja: a diferença entre os valores experimentais e os preditos pelo modelo. Quando o nível do erro não foi satisfatório, foram feitas mudanças, em particular, nas funções de pertinência (membership functions) e nos níveis dos parâmetros de entrada e de saída. Quando foi alcançado um nível aceitável, este modelo foi usado para fazer predições.

3. RESULTADOS PRELIMINARES

Controlando o processo de aprendizado de máquina, pelo software/algoritmo originou-se um modelo para descrever a relação entre os dados de entrada e de saída. Com este modelo, os dados experimentais foram comparados com os dados de saída calculados e desta forma os erros no processo de aprendizagem foram determinados.

O conjunto de dados foi dividido em três grupos: 70% para treinamento, 15% para validação e 15% para teste. O número de neurônios na camada oculta e a evolução do erro quadrático médio da raiz (RMSE) na rede neural rasa, que foi aplicada ao aço inoxidável duplex, alterou o número de neurônios na camada oculta.

Observou-se que para poucos números de neurônios a inclinação é maior, todavia para mais de 18 neurônios o erro é praticamente constante, se considerarmos os conjuntos de dados de treinamento, validação e teste. Estes conhecimentos junto com a função de ativação sigmoideal logística definiram a arquitetura do algoritmo ANN.

Com a definição da arquitetura do RNA, o mesmo foi usado para prever as curvas de fluxo plástico do aço inoxidável duplex (Figura 1).

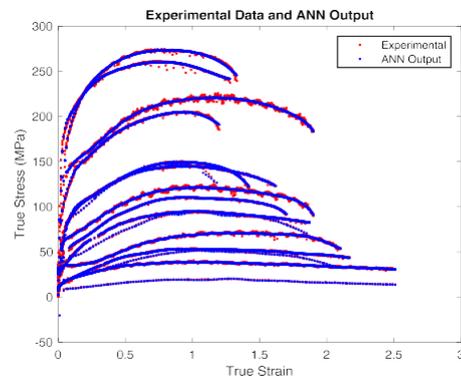


Figura 1: Resultados do aprendizado de máquina com RNA.

4. CONCLUSÃO

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.

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 do aço inoxidável super duplex.

5. REFERÊNCIAS

- Eren, B., Guvenc, M.A. e Mistikoglu, S., 2021. "Artificial Intelligence Applications for friction stir welding: a review. *Metals and Materials International*, Vol. 27, p.193-219.
- Haghdadi, N.; Zarei-Hanzaki, A.; Khalesian, A.R.; Abedi, H.R., 2013. "Artificial neural network modeling to predict the hot deformation behavior of an A356 aluminum alloy". *Materials Design*, Vol. 49, p. 386-391.
- Jang, J-S.R., 1993. "ANFIS: adaptive-network-based fuzzy inference system". *IEEE Transactions Systems, Man, and Cybernetics*, Vol. 23, p.665-685.
- Kumar, S.; Karmakar, A.; Nath, S. K., 2021. "Construction of hot deformation processing maps for 9Cr-1Mo steel through conventional and ANN approach". *Materials Today Communications*, Vol.26, p.101903.
- Vafaenezhad, H.; Seyedein, S.H.; Aboutalebi, M.R.; Eivani, A.R., 2017. "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*, Vol. 697, p.287-299.
- Wang, Y., Wu, X., Li, X., Xie, Z., Liu, R., Liu, W., Zhang, Y., Xu, Y. e Liu, C., 2020. "Prediction and analysis of tensile properties of austenitic stainless steel using artificial neural network". *Metals*, Vol. 10, p.234.



editoraomnisscientia@gmail.com 

<https://editoraomnisscientia.com.br/> 

@editora_omnis_scientia 

<https://www.facebook.com/omnis.scientia.9> 

+55 (87) 9656-3565 



editoraomnisscientia@gmail.com 

<https://editoraomnisscientia.com.br/> 

@editora_omnis_scientia 

<https://www.facebook.com/omnis.scientia.9> 

+55 (87) 9656-3565 