

**44° SENAFOR**

28ª Conferência Internacional de Forjamento - Brasil
14ª Conferência Internacional de Conformação de Chapas / 11º Congresso do BrDDR
14ª Conferência Internacional de Materiais e Processos para Energias Renováveis
3ª Conferência Internacional de Inovação em Materiais e Manufatura
Porto Alegre, RS, dias 1, 2 e 3 de outubro de 2025
www.senafor.com

INTELIGÊNCIA ARTIFICIAL APLICADA NA MODELAGEM DO COMPORTAMENTO DE DEFORMAÇÃO A QUENTE DE CHAPAS METÁLICAS

André Rosiak ⁽¹⁾
Rafael Pandolfo da Rocha ⁽²⁾
Matheus Henrique Riffel ⁽³⁾
Lirio Schaeffer ⁽⁴⁾

RESUMO

Este trabalho tem como objetivo modelar o comportamento de deformação plástica a quente da liga de alumínio AA 5052-H32 utilizando abordagens tradicionais e baseadas em Inteligência Artificial (IA). Ensaios de tração a quente foram conduzidos no simulador termomecânico Gleeble® 540 em diferentes temperaturas (100–450 °C) e velocidades de deformação (0,01 e 1 s⁻¹), possibilitando a obtenção das curvas de escoamento do material. Inicialmente, os dados experimentais foram ajustados por meio da equação constitutiva de Hensel-Spittel, amplamente utilizada para simular processos de conformação a quente. Em seguida, modelos preditivos baseados em IA foram desenvolvidos, utilizando Redes Neurais Artificiais (RNA) e o algoritmo eXtreme Gradient Boosting (XGBoost). A RNA foi otimizada com diferentes arquiteturas e funções de ativação, alcançando erro absoluto médio (MAE) de 3,61 MPa e erro quadrático médio (MSE) de 19,09 MPa². Já o modelo XGBoost apresentou desempenho superior, com MAE de 0,74 MPa, MSE de 2,46 MPa² e coeficiente de determinação (R²) de 0,9988. Os resultados indicam que ambas as abordagens são eficazes na previsão do escoamento a quente da liga AA 5052-H32, sendo o XGBoost particularmente eficiente na modelagem de relações não lineares complexas entre deformação, velocidade de deformação e temperatura.

Palavras-chave: Deformação a quente; Ligas de alumínio; Inteligência Artificial.

1. INTRODUÇÃO

Os avanços na indústria da mobilidade têm se concentrado em soluções inovadoras e economicamente viáveis, visando ampliar a eficiência energética dos veículos. Paralelamente, as exigências relacionadas ao desempenho em impactos têm se tornado cada vez mais rigorosas. Como resultado, os veículos estão mais seguros do que nunca, impulsionando o uso de materiais leves e de alta resistência, criteriosamente selecionados para atender a esses requisitos.

As ligas de aço ainda predominam no setor automotivo devido à sua excelente relação custo-benefício. No entanto, as ligas de alumínio vêm ganhando destaque como alternativa promissora aos materiais convencionais, desempenhando um papel relevante na redução de peso dos componentes veiculares [1]. Essas ligas se destacam por sua elevada resistência mecânica, boa capacidade de absorção de energia, alta reciclabilidade e baixa densidade, além de apresentarem boa resistência à corrosão [2]. Comparadas ao aço, possibilitam uma redução de peso de até 50% [3].

Os avanços na indústria da mobilidade têm se concentrado em soluções inovadoras e economicamente viáveis, visando ampliar a eficiência energética dos veículos. Paralelamente, as exigências relacionadas ao desempenho em impactos têm se tornado cada vez mais rigorosas. Como resultado, os veículos estão mais seguros do que nunca, impulsionando o uso de materiais leves e de alta resistência, criteriosamente selecionados para atender a esses requisitos.

As ligas de aço ainda predominam no setor automotivo devido à sua excelente relação custo-benefício. No entanto, as ligas de alumínio vêm ganhando destaque como alternativa promissora aos materiais convencionais, desempenhando um papel relevante na redução de peso dos componentes veiculares [1]. Essas ligas se destacam por sua elevada resistência mecânica, boa capacidade de absorção de energia, alta reciclabilidade e baixa densidade, além de apresentarem boa resistência à corrosão [2]. Comparadas ao aço, possibilitam uma redução de peso de até 50% [3].

2. MATERIAIS E MÉTODOS

A Tabela 1 lista a composição química da liga de alumínio 5052-H32 com 1 mm de espessura utilizada neste trabalho. A composição está dentro da faixa nominal encontrada na literatura [8].

Tabela 1 Composição química da liga de alumínio 5052-H32 com 1 mm de espessura.

Al	Mg	Si	Fe	Cr	Outros
96,9	2,20	0,18	0,31	0,15	0,26




Figura 1 Detalhamento dos corpos de prova de tração a quente.

O material foi submetido a ensaios de tração a quente conduzidos no simulador termomecânico Gleeble® 540. A Figura 1 mostra o detalhamento do corpo de prova utilizado.

Durante os testes, as amostras foram aquecidas à temperatura alvo com taxa controlada, mantidas em patamar térmico por 30 segundos para homogeneização e, em seguida, deformadas até a fratura. A Tabela 2 lista as condições termomecânicas utilizadas nos testes.

Tabela 2 Parâmetros termomecânicos dos ensaios de tração a quente.

Condições	Temperatura [°C]	Velocidade de deformação [1/s]
1	100	0,01
2	100	1
3	200	0,01
4	200	1
5	300	0,01
6	300	1
7	450	0,01
8	450	1

2.1 Modelo de Hensel-Spittel

Uma abordagem amplamente utilizada na modelagem e previsão da tensão de escoamento na deformação a quente foi proposta por Hensel e Spittel [9-11]:

$$k_f = C \cdot e^{m_1 T} \cdot \dot{\varphi}^{m_2} \cdot \dot{\varphi}^{\frac{m_3}{v}} \cdot (1 + \varphi)^{m_4 T} \cdot e^{m_5 \varphi} \cdot \dot{\varphi}^{m_6 T} \cdot T^{m_7} \quad (\text{Equação 1})$$

Onde C , m_1 a m_7 são constantes do material e devem ser determinadas experimentalmente.

Este modelo é basicamente uma combinação do modelo clássico de lei de potência e dos modelos Hollomon e Swift com as constantes consideradas como funções da deformação e da temperatura [12].

O modelo constitutivo de Hensel-Spittel quantifica o efeito da deformação, temperatura e velocidade de deformação na tensão de escoamento, e pode apresentar o comportamento de deformação a quente com alta precisão [13]. Além disso, a maioria dos softwares comerciais de elementos finitos integra o Modelo Constitutivo de Hensel-Spittel, e a identificação dos parâmetros do modelo constitutivo pode fornecer dados de entrada para a simulação de elementos finitos.

A metodologia adotada para o ajuste do modelo constitutivo baseou-se na linearização da equação de Hensel-Spittel por meio da aplicação do logaritmo natural, permitindo a determinação sequencial dos parâmetros do modelo. A partir de simplificações com variáveis constantes, diferentes formas da equação foram obtidas para isolar os coeficientes associados à velocidade de deformação, temperatura e deformação. Com isso, foram realizados ajustes lineares entre os dados experimentais e as variáveis transformadas, possibilitando a extração dos parâmetros por meio das inclinações e interceptações médias obtidas em diferentes condições.

2.2 Modelamento utilizando Inteligência Artificial

Modelos baseados em Inteligência Artificial (IA) começaram a ser aplicados em processos de conformação mecânica principalmente a partir da década de 1990. A

introdução da IA visou superar algumas limitações intrínsecas aos métodos tradicionais, como a dificuldade em representar com precisão fenômenos complexos relacionados ao comportamento dos materiais, além da necessidade de otimização de processos com múltiplos parâmetros em tempo real. Desde então, os modelos de IA têm se mostrado altamente eficazes ao lidar com a complexidade inerente aos processos de conformação, oferecendo abordagens mais flexíveis para a modelagem de relações não lineares e a previsão de comportamentos mecânicos e falhas. A expansão de seu uso foi impulsionada pelo aumento da capacidade computacional e pela maior disponibilidade de dados experimentais e de simulações. Dessa forma, a IA consolidou-se como uma ferramenta poderosa para aprimorar a eficiência, a precisão e o controle de processos na área de conformação mecânica [14].

Devido a essas características, diferentes abordagens baseadas em Inteligência Artificial (IA) têm sido aplicadas à predição de curvas de escoamento de metais [15–21]. Diferentemente de modelos fenomenológicos, como o de Hensel-Spittel, o desenvolvimento de modelos de IA não requer a definição prévia de relações explícitas entre as variáveis de entrada e saída, o que confere maior flexibilidade e simplicidade à sua aplicação. Trata-se, contudo, de uma abordagem na qual as relações físicas entre as variáveis não são incorporadas diretamente ao modelo [13].

Neste trabalho, duas abordagens baseadas em Inteligência Artificial (IA) foram investigadas: Redes Neurais Artificiais (RNA) e eXtreme Gradient Boosting (XGBoost). Os modelos foram treinados com os dados obtidos experimentalmente a partir dos ensaios de tração da liga AA 5052, nos quais variaram-se os parâmetros de deformação, velocidade de deformação e temperatura, com o objetivo de prever com precisão a tensão de escoamento em diferentes condições de conformação.

A primeira etapa da metodologia consistiu no pré-processamento dos dados. As variáveis de entrada — deformação (ϕ), velocidade de deformação ($\dot{\phi}$) e temperatura (T) — e a variável de saída — tensão de escoamento (σ_f) — foram organizadas em um conjunto de dados estruturado. Em seguida, foi aplicada a técnica de normalização Min-Max para escalar os dados entre 0 e 1, garantindo uma distribuição equilibrada entre as variáveis e favorecendo a estabilidade e a eficiência do processo de aprendizado das redes neurais.

Na abordagem com RNA, os dados foram divididos em conjuntos de treino e teste, mantendo-se uma fração de 20% para validação final do desempenho. A arquitetura da rede foi definida com base em um processo automatizado de otimização de hiperparâmetros estruturais, no qual diferentes combinações de camadas ocultas e funções de ativação foram sistematicamente avaliadas quanto ao desempenho preditivo. O modelo final foi treinado com o otimizador Adam e função de perda do tipo erro quadrático médio (MSE). Para evitar o sobreajuste (overfitting), foi empregado o recurso de early stopping, interrompendo o treinamento caso não houvesse melhora da perda de validação após 30 épocas consecutivas.

Durante o treinamento, a rede foi avaliada continuamente por meio de métricas como o erro absoluto médio (MAE) e o erro quadrático médio (MSE), tanto para os dados de treinamento quanto de validação. As curvas de aprendizado resultantes foram analisadas para confirmar a estabilidade do processo e a capacidade de generalização do modelo. Após o término do treinamento, a RNA foi testada com todo o conjunto de dados para geração das curvas de escoamento previstas e posterior comparação com os dados experimentais.

A metodologia aplicada ao XGBoost seguiu princípios semelhantes, com a diferença de que esta técnica não requer normalização das entradas e é

particularmente eficaz para conjuntos de dados tabulares. O modelo foi ajustado utilizando uma combinação de validação cruzada e otimização dos principais hiperparâmetros de controle, como profundidade das árvores, taxa de aprendizado e número de estimadores. Após o ajuste fino do modelo, os resultados previstos foram comparados com os experimentais, possibilitando a avaliação crítica do desempenho preditivo da abordagem em relação à RNA.

3. RESULTADOS E DISCUSSÕES

Esse capítulo apresenta os resultados obtidos desde a caracterização do comportamento mecânico a quente da liga AA 5052-H32 até a sua modelagem por meio de técnicas avançadas de Inteligência Artificial.

3.1 Curvas de escoamento da liga AA 5052-H32

A Figura 2 apresenta as curvas de escoamento da liga AA 5052-H32 obtidas sob diferentes temperaturas e velocidades de deformação. Observa-se uma influência significativa da temperatura na resistência do material: com o aumento da temperatura de deformação, ocorre uma expressiva redução na tensão de escoamento, evidenciando o amolecimento térmico característico de materiais metálicos.




Figura 2 Curvas de escoamento da liga AA 5052-H32 obtidas sob diferentes temperaturas e velocidades de deformação.

O efeito da velocidade de deformação também é notável. Para todas as temperaturas analisadas, as tensões de escoamento são mais elevadas nas maiores velocidades, o que se deve à atuação limitada dos mecanismos de amolecimento, que requerem tempo para ocorrer. Em consequência, o encruamento é mais pronunciado em altas velocidades de deformação, resultando em maior resistência ao escoamento. Além disso, o formato das curvas varia conforme a condição térmica. A 100 °C, por exemplo, observa-se um aumento contínuo da tensão com a deformação, indicando forte influência do encruamento. Em temperaturas mais elevadas, como 300 °C, a elevação da tensão com a deformação é menos acentuada. Já a 450 °C, a curva exibe uma região plástica praticamente estável, com pouca variação adicional da tensão de escoamento, o que revela a atuação dominante dos mecanismos de amolecimento térmico. Esse comportamento também foi observado por [22] em condições semelhantes de deformação para a liga AA 5052.

3.2 Modelo de Hensel-Spittel

A Tabela 3 apresenta os parâmetros da equação de Hensel-Spittel obtidos a partir do ajuste aos dados experimentais, Já a Figura 3 compara as curvas de escoamento experimentais com aquelas previstas pelo modelo.

Tabela 3 Parâmetros de Hensel-Spittel para a liga AA 5052-H32.

C	m1	m2	m3	m4	m5	m7	m8	m9
1247,7	-8,443	0,872	0,030	0,002	-0,101	-2,129	-0,948	0,572




Figura 3 Comparação das curvas de escoamento da liga AA 5052-H32 experimentais e previstas pelo modelo de Hensel-Spittel,

De modo geral, observa-se um bom ajuste entre os dados modelados e os valores experimentais, conforme ilustrado na Figura 4, que apresenta a correlação entre os valores previstos e medidos da tensão de escoamento. Embora o modelo tenha alcançado um elevado coeficiente de determinação global ($R^2 = 0,9847$), indicando alta capacidade preditiva, nota-se uma variação no desempenho em função das condições de ensaio. Em temperaturas mais elevadas, especialmente a 450 °C, o modelo mostrou-se menos eficaz na representação do comportamento do material, sugerindo limitações na capacidade de capturar adequadamente os mecanismos de amolecimento térmico predominantes nessas condições.

A análise dos coeficientes permite algumas considerações relevantes sobre o comportamento do material. O parâmetro m_1 negativo confirma a tendência esperada de redução da resistência ao escoamento com o aumento da temperatura, caracterizando o amolecimento térmico típico dos metais durante a conformação a quente. O valor positivo de m_2 reflete o encruamento do material, evidenciado pelo aumento gradual da resistência com o incremento da deformação verdadeira.

A influência da velocidade de deformação, expressa por um valor de $m_3 = 0,0304$, mostrou-se pequena, sugerindo que o material possui baixa sensibilidade à velocidade de deformação nas condições avaliadas. O termo exponencial m_4/φ atua de forma mais significativa em baixas deformações, contribuindo para o crescimento inicial da resistência.

O parâmetro m_5 negativo modula o termo $(1+\phi)$ e suaviza o efeito do encruamento, especialmente em altas temperaturas. Os termos m_7 e m_8 , ambos negativos, exercem importante papel na descrição do amolecimento térmico e da recuperação dinâmica, especialmente em altas deformações e temperaturas elevadas.

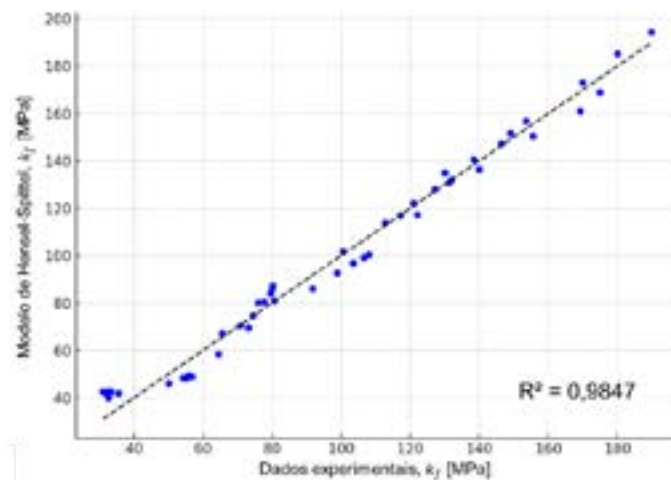


Figura 4 Comparação dos dados de tensão de escoamento da liga AA 5052-H32 experimentais e previstos pelo modelo de Hensel-Spittel,

O parâmetro m_9 positivo atua compensando o efeito de redução exponencial de resistência imposto por m_1 , ajustando adequadamente a inclinação da curva de escoamento em função da temperatura.

3.3 Modelo de RNA

A escolha da arquitetura de uma Rede Neural Artificial (RNA) tem impacto direto no seu desempenho [23], especialmente em problemas com relações complexas e não lineares, como é o caso da previsão da tensão de escoamento da liga AA 5052-H32. Com o objetivo de identificar a arquitetura ideal com base nas variáveis deformação, velocidade de deformação e temperatura, foi implementado um algoritmo de busca automatizada por hiperparâmetros estruturais. A estratégia adotada consistiu em um processo exaustivo e sistemático, no qual diferentes combinações de camadas ocultas e funções de ativação foram avaliadas quanto ao desempenho preditivo.

Foram definidas manualmente diversas arquiteturas com estrutura piramidal, representando diferentes níveis de complexidade, A Tabela 4 apresenta as características dessas arquiteturas, Além disso, foram testadas três funções de ativação amplamente utilizadas em problemas de regressão: 'relu', 'tanh' e 'elu', O código executa um duplo laço: para cada arquitetura, todas as funções de ativação são combinadas e avaliadas.


Para cada combinação, uma RNA do tipo Sequential é criada com as camadas ocultas e ativações definidas, O modelo é compilado utilizando o otimizador adam e a função de perda mse, O treinamento é realizado com validação interna (validation_split=0,2) e controle de overfitting por meio da técnica de EarlyStopping, com patience=30, A avaliação final de desempenho é feita no conjunto de teste, utilizando as métricas MAE (erro absoluto médio), MSE (erro quadrático médio) e R^2 (coeficiente de determinação).

Os resultados de todas as execuções são armazenados em uma lista de dicionários, convertida ao final em um DataFrame, que é ordenado com base no

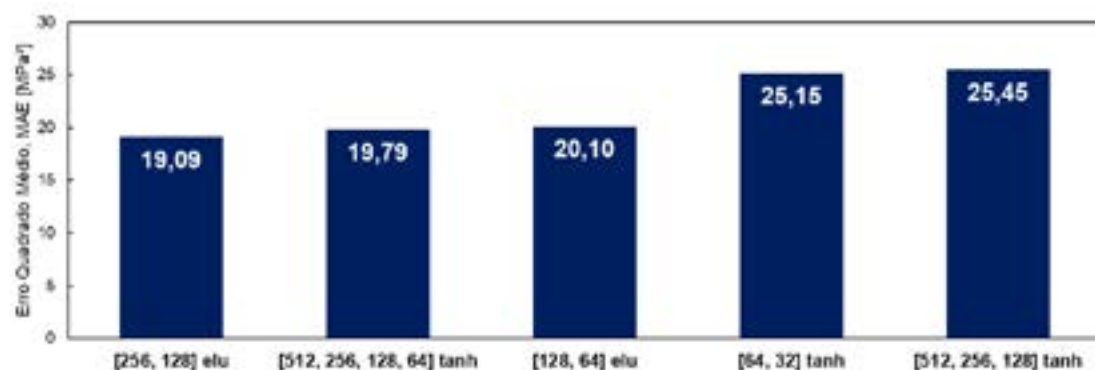
menor MSE, permitindo a identificação objetiva das arquiteturas mais precisas e robustas. As Figuras 5, 6 e 7 comparam os resultados de MAE, MSE e R^2 para os cinco modelos que apresentaram melhor desempenho.

Tabela 4 Características das arquiteturas de RNA avaliadas.


Arquitetura	Camadas Ocultas	Total de Neurônios	Distribuição de Neurônios
[64, 32]	2	96	64 → 32
[128, 64]	2	192	128 → 64
[256, 128]	2	384	256 → 128
[512, 256, 128]	3	896	512 → 256 → 128
[512, 256, 128, 64]	4	960	512 → 256 → 128 → 64



Figuras 5 Resultados de MAE para os cinco modelos de RNA que apresentaram melhor desempenho.



Figuras 6 Resultados de MSE para os cinco modelos de RNA que apresentaram melhor desempenho.



Figuras 7 Resultados de R^2 para os cinco modelos de RNA que apresentaram melhor desempenho.

Os dados experimentais envolvem relações não lineares e acopladas entre as variáveis de entrada. A tensão de escoamento, por exemplo, não cresce linearmente com a deformação, sendo fortemente influenciada pela velocidade de deformação e, sobretudo, pela temperatura [18]. As melhores arquiteturas identificadas possuem múltiplas camadas com número progressivamente menor de neurônios — estrutura piramidal. Esse tipo de arquitetura permite extrair representações de alto nível a partir das variáveis de entrada e garante capacidade de generalização, ao reduzir gradualmente a dimensionalidade e focar nas interações mais relevantes.

As funções de ativação elu e tanh foram as que apareceram nas melhores combinações. Exponential Linear Unit (elu) tem como vantagem a suavidade e a capacidade de lidar melhor com gradientes negativos, o que favorece o aprendizado em profundidade [24]. Já a função tanh é simétrica em torno de zero, o que ajuda em tarefas de regressão e melhora a convergência do treinamento. A escolha dessas funções em arquiteturas profundas contribuiu para um treinamento mais estável e uma melhor representação das variações suaves nos dados [25].

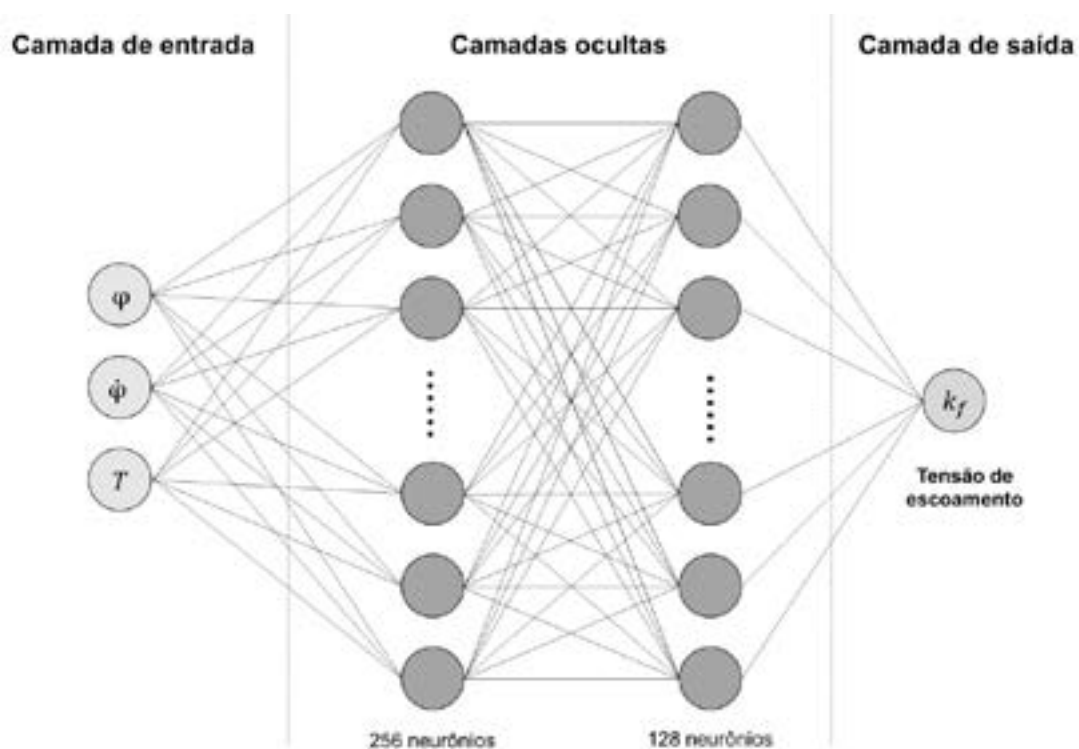


Figura 8 Desenho esquemático da arquitetura de RNA.

As melhores arquiteturas atingiram o equilíbrio entre capacidade de ajuste e robustez contra sobreajuste. Arquiteturas muito simples não capturam a complexidade do fenômeno, enquanto redes excessivamente profundas podem superajustar os dados.

A Figura 8 ilustra a arquitetura da Rede Neural Artificial (RNA) selecionada como a mais eficaz para prever a tensão de escoamento da liga AA 5052-H32. Na camada de entrada da RNA são fornecidos os dados de deformação (φ), velocidade de deformação ($\dot{\varphi}$) e temperatura (T), que caracterizam as condições de deformação do material durante os ensaios de tração. Esses dados são conectados à primeira camada oculta, que contém 256 neurônios. Em seguida, os sinais processados são transmitidos para uma segunda camada oculta com 128 neurônios. Ambas as camadas utilizam a função de ativação ELU (Exponential Linear Unit). A camada de saída possui apenas um neurônio, responsável por gerar o valor estimado de tensão

de escoamento (\vec{I}_F). Todas as conexões entre neurônios são densamente conectadas, ou seja, cada neurônio de uma camada está ligado a todos os neurônios da camada seguinte, permitindo que a rede capture interações complexas entre as variáveis de entrada.

As Figuras 9 e 10 mostram as curvas de aprendizado para MAE e MSE do modelo de RNA. As curvas demonstram um comportamento típico de um treinamento bem-sucedido de RNA [26]. Logo nas primeiras épocas (até cerca da 20ª), observa-se uma queda acentuada nos erros de treinamento e validação, indicando que o modelo está aprendendo rapidamente os padrões presentes nos dados.

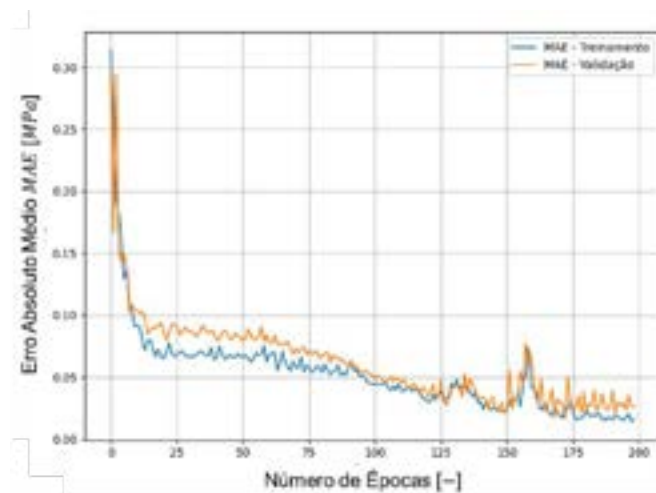


Figura 9 Curvas de aprendizado do modelo de RNA com MAE em função do número épocas.

Após esse ponto, ambos os erros continuam diminuindo de forma mais suave e estabilizam-se a partir de aproximadamente 100 épocas, com pequenas oscilações naturais, principalmente na curva de validação. Esse tipo de oscilação é esperado em RNAs bem ajustadas, sobretudo em problemas com dados experimentais que apresentam dispersão.

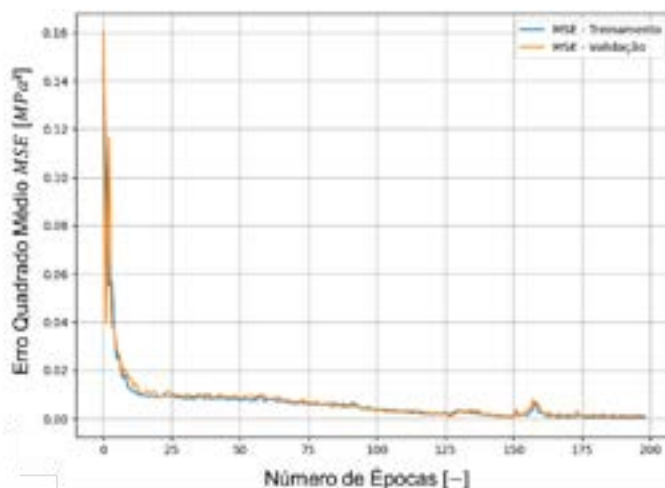


Figura 10 Curvas de aprendizado do modelo de RNA com MSE em função do número épocas.

A proximidade entre os valores de erro nos conjuntos de treinamento e validação indica que o modelo possui boa capacidade de generalização, sem sinais evidentes de overfitting. A arquitetura escolhida — com duas camadas ocultas de 256 e 128 neurônios, ativação elu e regularização via EarlyStopping — mostrou-se adequada à

natureza dos dados, que envolvem relações não lineares entre deformação, velocidade de deformação e temperatura.




Figura 11 Comparação das curvas de escoamento da liga AA 5052-H32 experimentais e previstas pelo modelo de RNA.

Os valores finais das métricas de desempenho no conjunto de teste foram MAE = 3,61 MPa e MSE = 19,09 MPa² evidenciando a alta acurácia do modelo e confirmam a robustez da Rede Neural Artificial (RNA) na predição da tensão de escoamento da liga AA 5052-H32 sob diferentes condições de deformação.

A Figura 11 reforça esses resultados ao apresentar a sobreposição entre as curvas de escoamento experimentais e aquelas previstas pelo modelo de RNA, evidenciando sua capacidade de capturar com precisão o comportamento não linear do material. Diferentemente do modelo de Hensel-Spittel, que apresentou limitações na previsão da resposta do material sob deformação a 450 °C, o desempenho da RNA mostrou-se consistente e robusto em todas as condições de ensaio, sem sensibilidade significativa às variações de temperatura e velocidade de deformação.

3.4 Modelo de eXtreme Gradient Boosting

O XGBoost é um algoritmo de aprendizado de máquina baseado em gradiente boosting com árvores de decisão como estimadores base [27]. Ele constrói uma sequência de árvores, onde cada nova árvore é treinada para corrigir os erros residuais da anterior, aprimorando progressivamente a previsão.

Neste trabalho, o modelo XGBoost foi treinado para prever a tensão de escoamento da liga AA 5052-H32 com base em dados experimentais. Foi utilizada uma configuração com 100 árvores de decisão. O aumento no número de árvores tende a melhorar a capacidade do modelo de capturar padrões complexos, mas também pode aumentar o risco de overfitting, especialmente se não houver controle sobre outros hiperparâmetros [28].

Foi definida uma profundidade máxima de 4 para cada árvore. Esse parâmetro controla o número de divisões (níveis) que uma árvore pode realizar. Árvores com profundidade menor são menos propensas a se ajustar ao ruído dos dados (overfitting), resultando em modelos mais simples e generalizáveis. Ao limitar a

profundidade a 4, o modelo é incentivado a combinar várias árvores fracas, o que favorece a robustez do conjunto preditivo final.

A taxa de aprendizado do modelo foi definida como 0,1, o que significa que cada nova árvore adiciona apenas 10% da sua contribuição prevista à predição final. Esse parâmetro atua como um fator de regularização, tornando o processo de aprendizado mais lento e controlado. Dessa forma, o modelo é capaz de ajustar-se aos dados de maneira mais estável, reduzindo o risco de oscilações bruscas ou sobreajuste precoce. Embora exija mais iterações para convergir, essa abordagem tende a gerar modelos com melhor capacidade de generalização [29].

A Figura 12 ilustra esquematicamente o funcionamento do modelo de regressão XGBoost desenvolvido para prever a tensão de escoamento da liga AA 5052-H32 com base em dados experimentais de deformação (φ), velocidade de deformação ($\dot{\varphi}$) e temperatura (T). Durante o processo de treinamento, o modelo constrói sucessivamente 100 árvores de decisão. Cada árvore pode receber um subconjunto dos dados utilizar os resíduos do modelo anterior como alvo para aprimorar as previsões, D_1, D_2, \dots, D_n representam os dados que alimentam cada uma dessas árvores em diferentes etapas do boosting. Cada árvore produz uma predição parcial da tensão de escoamento (representadas como W_1, W_2, \dots, W_n), que corrige os erros acumulados nas etapas anteriores.

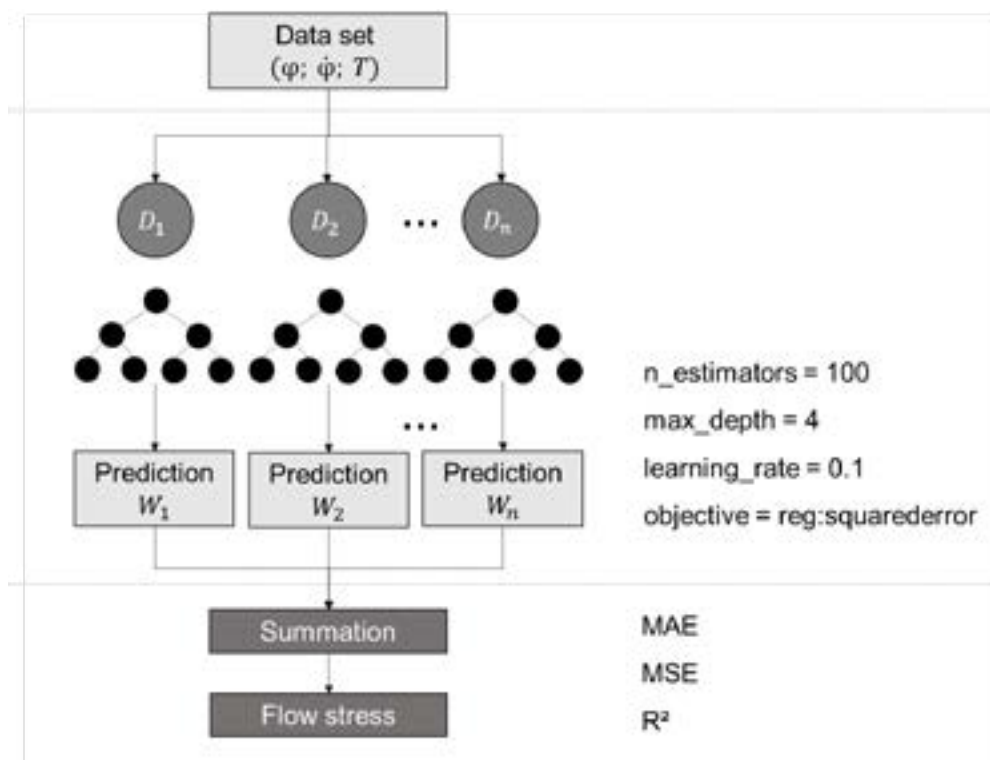


Figura 12 Desenho esquemático do funcionamento do modelo de regressão XGBoost.

As previsões parciais de cada árvore não são somadas integralmente. Em vez disso, o modelo aplica um fator de aprendizado ($learning_rate = 0,1$). A soma ponderada de todas as árvores resulta na previsão final da tensão de escoamento. As curvas de aprendizado do modelo XGBoost, apresentadas em função do número de árvores de decisão (Figuras 13 e 14), revelam uma tendência de convergência estável tanto para o erro absoluto médio (MAE) quanto para o erro quadrático médio (MSE). Observa-se que, após cerca de 60 estimadores, os erros se estabilizam, indicando que o modelo atinge um equilíbrio entre ajuste e generalização.

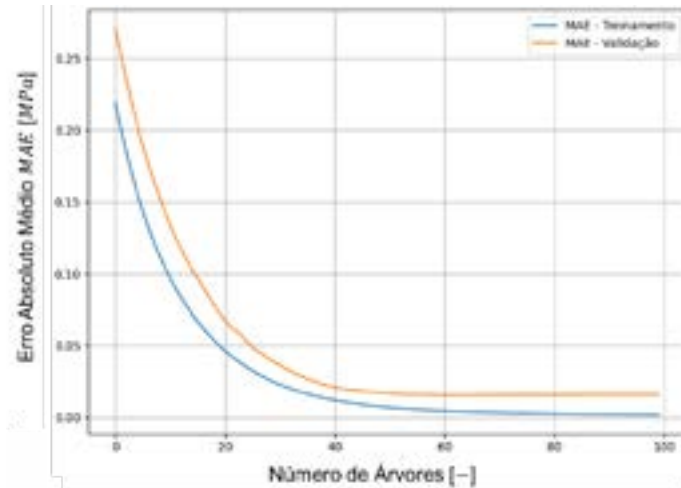


Figura 13 Curvas de aprendizado do modelo XGBoost, com MAE em função do número de árvores de decisão.

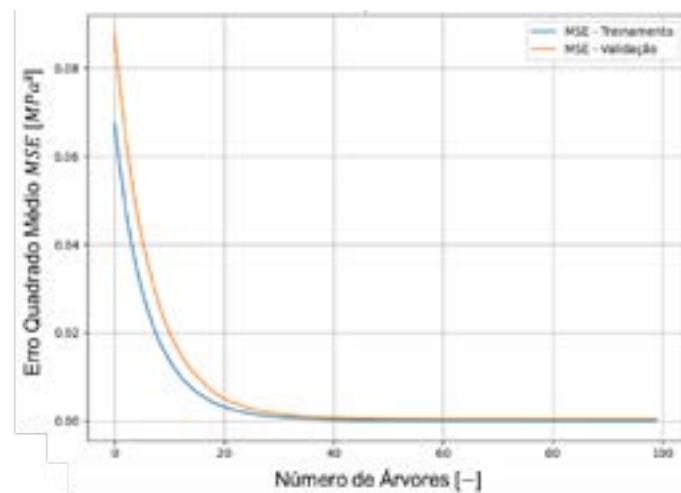


Figura 14 Curvas de aprendizado do modelo XGBoost, com MSE em função do número de árvores de decisão.

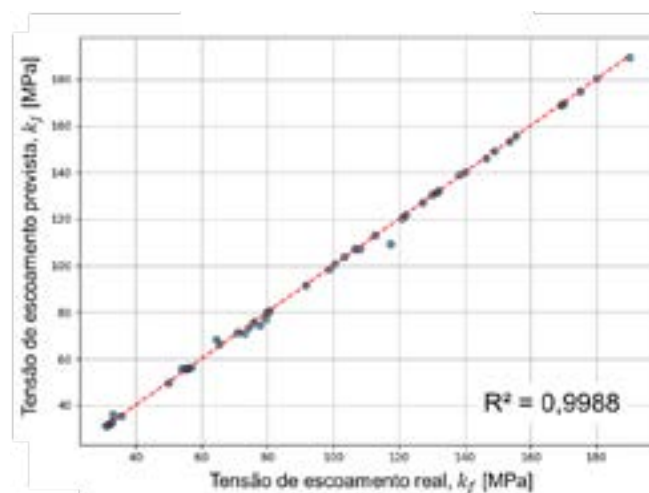


Figura 15 Gráfico de dispersão entre os valores reais e previstos pelo modelo XGBoost.

Ao final do treinamento com 100 árvores, o modelo apresentou um MAE de 0,7389 MPa e um MSE de 2,4585 MPa², valores notavelmente baixos no contexto da previsão da tensão de escoamento da liga AA 5052-H32. A proximidade entre os erros

nos conjuntos de treinamento e validação sugere que o modelo aprendeu de forma eficiente sem apresentar overfitting, confirmando sua capacidade de capturar com precisão os padrões complexos presentes nos dados experimentais.

O excelente desempenho do modelo também é evidenciado pela análise do gráfico de dispersão entre os valores reais e previstos da tensão de escoamento (Figura 15). A maior parte dos pontos está concentrada ao longo da linha de referência 1:1, demonstrando uma correspondência quase perfeita entre os valores observados e as previsões do modelo. O coeficiente de determinação (R^2) foi de 0,9988, indicando que mais de 99,8% da variabilidade dos dados reais é explicada pelas previsões geradas.




Figura 16 Comparação das curvas de escoamento da liga AA 5052-H32 experimentais e previstas pelo modelo XGBoost.

A Figura 16 apresenta a comparação entre as curvas de escoamento obtidas experimentalmente e aquelas previstas pelo modelo XGBoost para a liga AA 5052-H32. Observa-se um excelente alinhamento entre os dados reais e os valores estimados, evidenciando a alta capacidade preditiva do modelo para todas as condições analisadas. Esse desempenho confirma a robustez e a eficácia do XGBoost como abordagem de modelagem para descrever o comportamento de escoamento do material, mesmo diante da complexidade não linear das relações entre deformação, velocidade de deformação e temperatura.

O excelente desempenho obtido pelo modelo XGBoost na previsão da tensão de escoamento pode ser atribuído a uma combinação de fatores inerentes à sua arquitetura e ao tipo de dados utilizados. Primeiramente, trata-se de um algoritmo baseado em árvores de decisão, o que o torna especialmente eficaz para lidar com relações não lineares, como aquelas observadas em curvas de escoamento de materiais metálicos. Além disso, o XGBoost é reconhecido por sua eficiência mesmo em bases de dados relativamente pequenas, o que é particularmente vantajoso em contextos experimentais, nos quais a obtenção de grandes quantidades de dados pode ser limitada [29]. Outro diferencial importante é sua capacidade de capturar interações complexas entre as variáveis de entrada (φ , $\dot{\varphi}$, T), o que permite modelar adequadamente a influência combinada desses parâmetros sobre a resistência do

material, Por fim, o algoritmo incorpora técnicas de regularização durante o processo de treinamento, o que contribui para evitar overfitting e melhorar a capacidade de generalização do modelo. Esses aspectos tornam o XGBoost particularmente adequado para problemas de previsão em ciência dos materiais e engenharia de processos.

4. CONCLUSÕES

Este trabalho apresentou a caracterização experimental do comportamento de deformação a quente da liga de alumínio AA 5052-H32, submetida a ensaios de tração em diferentes temperaturas e velocidades de deformação. Com base nos dados experimentais, o comportamento mecânico do material foi modelado por meio de três abordagens distintas: o modelo fenomenológico de Hensel-Spittel e dois modelos baseados em Inteligência Artificial — Redes Neurais Artificiais (RNA) e o algoritmo eXtreme Gradient Boosting (XGBoost).

O modelo de Hensel-Spittel apresentou bom desempenho preditivo, com coeficiente de determinação $R^2 = 0,9847$, sendo eficaz para representar as principais tendências do escoamento do material. No entanto, observou-se que as abordagens baseadas em IA apresentaram desempenho superior, especialmente na modelagem de relações não lineares complexas entre as variáveis de entrada.

A RNA, treinada com arquitetura otimizada e função de ativação ELU, alcançou métricas satisfatórias (MAE = 3,61 MPa e MSE = 19,09 MPa²), demonstrando boa capacidade de generalização e estabilidade de aprendizado. Por sua vez, o modelo XGBoost apresentou os melhores resultados entre os métodos avaliados, com MAE = 0,74 MPa, MSE = 2,46 MPa² e $R^2 = 0,9988$, revelando excelente acurácia na predição da tensão de escoamento da liga AA 5052-H32.

As técnicas baseadas em Inteligência Artificial, em especial o XGBoost, representam ferramentas promissoras para a modelagem do comportamento de materiais em processos de conformação a quente, sendo capazes de superar abordagens tradicionais em termos de precisão, adaptabilidade e robustez preditiva.

REFERÊNCIAS

- [1] LAHAYE, C., et al. Contribution of Aluminium to the Multi-Material Light-Weight BIW Design of SuperLight-Car (SLC). *Aluminium International Today*. V. 21 No. 5. 2009.
- [2] AUMÜLLER M., Sicherheit und Leichtbau mit AMAG Aluminium, *AluReport*, AMAG TopForm UHS: Durchbruch im Karosserieleitbau. pp. 14 a 15. 2014.
- [3] HIRSCH, J., et al. Hot Forming of Aluminium for Light-Weight Car Design. *Aluminium International Today*. Aachen, Germany. pp. 2388 a 2393. 2008.
- [4] AKKIREDDY, L. A., et al. Formability Studies of Automotive Aluminium Alloy Sheet series: A Review, *E3S Web of Conferences*. Vol. 184. 2020.
- [5] JU, L., ALTAN, T., Forming Al Alloys at Elevated Temperatures, Part I - Stamping Journal. 2015.
- [6] ZHOU, J. et al. Forming Defects in Aluminum Alloy Hot Stamping of Side-Door Impact Beam, *Transactions of Nonferrous Metals Society of China*, Volume 24, Issue 11, 2014.
- [7] BRÜNGER, E., ENGLER, O., HIRSCH, J. Al-Mg-Si Sheet for Autobody Application. *Virtual Fabrication of Aluminium Products*. Chapter 1–6. Weinheim: Wiley-VCH Verlag. pp. 51–61. 2006
- [8] ZHOU, J., ZHANG, J., MA, M. Study on the Formability of Aluminum Alloy Sheets at Room and Elevated Temperatures. *Materials Science Forum*. Vol. 877. P. 393 – 399. 2017.
- [9] GAO, Song; SANG, Ye; LI, Qihan; SUN, Yingli; WU, Yuhang; WANG, Haoran. Constitutive modeling and microstructure research on the deformation mechanism of Ti-6Al-4V alloy under hot forming condition. *Journal of Alloys and Compounds*, v. 892, p. 162128, 5 fev. 2022.
- [10] CHEN, Yiqi; LI, Hong; ZHANG, Song; LUO, Jiao; TENG, Junfei; LV, Yanlong; LI, Miaoqian. Hot tensile deformation behavior and constitutive models of GH3230 superalloy double-sheet. *Materials*, v. 16, n. 2, p. 803, 2023.
- [11] MEHTEDI, M. El; MUSHARAVATI, F.; SPIGARELLI, S. Modelling of the flow behaviour of wrought aluminium alloys at elevated temperatures by a new constitutive equation. *Materials and Design*, v. 54, p. 869–873, 2014.

- [12] J.D. Yoo, M.C. Kim, E.J. Kim, M.K. Razali, M.S. Joun, Flow stress characterization of magnesium alloys at elevated temperatures: A review, *J. Phys. Conf. Ser.* 2047 (1) (2021) 012002.
- [13] SAVAEDI, Zeinab; MOTALLEBI, Reza; MIRZADEH, Hamed. A review of hot deformation behavior and constitutive models to predict flow stress of high-entropy alloys. *Journal of Alloys and Compounds*, v. 903, 2022, p. 163964.
- [14] Cao, J., Bambach, M., Merklein, M., Mozaffar, M., & Xue, T. (2024). Artificial intelligence in metal forming. *CIRP Annals - Manufacturing Technology*, 73(1), 561-587.
- [15] P. Opěla, I. Schindler, P. Kawulok, R. Kawulok, S. Ruzs, K. Rodak, Hot flow curve description of CuFe₂ alloy via different artificial neural network approaches, *J. Mater. Eng. Perform.* 28 (8) (2019) 4863–4870.
- [16] S.A. Sani, G.R. Ebrahimi, H. Vafaenezhad, A.R. Kiani-Rashid, Modeling of hot deformation behavior and prediction of flow stress in a magnesium alloy using constitutive equation and artificial neural network (ANN) model, *J. Magnes. Alloy.* 6 (2) (2018) 134–144.
- [17] H. Ahmadi, H.R. Ashtiani, M. Heidari, A comparative study of phenomenological, physically-based and artificial neural network models to predict the hot flow behavior of API 5CT-L
- [18] Rosiak, A., Schmeling, M., Marcelino, R. et al. Machine learning applied to predict the flow curve of steel alloys. *Int J Adv Manuf Technol* 134, 5481–5492 (2024).
- [19] S. Mandal, P.V. Sivaprasad, S. Venugopal, Capability of a feed-forward artificial neural network to predict the constitutive flow behavior of as cast 304 stainless steel under hot deformation, *J. Eng. Mater. Technol.* 129 (2007) 242–247.
- [20] Y.C. Lin, J. Zhang, J. Zhong, Application of neural networks to predict the elevated temperature flow behavior of a low alloy steel, *Comput. Mater. Sci.* 43 (4) (2008) 752–758.
- [21] H. Mirzadeh, J.M. Cabrera, A. Najafzadeh, Modeling and prediction of hot deformation flow curves, *Metall. Mater. Trans. A* 43 (1) (2012) 108–123.
- [22] LI, Yantao; DONG, Wenzheng; LIN, Qiquan; WANG, Zhigang. Constitutive model and plate forging ability of 5052 aluminum alloy under different temperatures. In: DAEHN, G. et al. (eds.). *Forming the Future. The Minerals, Metals & Materials Series*, 2021.
- [23] Wang, Y.; Wu, X.; Li, X.; Xie, Z.; Liu, R.; Liu, W.; Zhang, Y.; Xu, Y.; Liu, C. Prediction and Analysis of Tensile Properties of Austenitic Stainless Steel Using Artificial Neural Network. *Metals* 2020, 10, 234.
- [24] ÇATALBAŞ, Burak; MORGÜL, Ömer. Deep learning with Extended Exponential Linear Unit (DELU). *Neural Computing and Applications*, v. 35, p. 22705–22724, 2023.
- [25] WANG, Yingying; LI, Yibin; SONG, Yong; RONG, Xuewen. The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, v. 10, n. 5, p. 1897, 2020.
- [26] Fernández D.M., Rodríguez-Prieto A., Xamacho A.M., Prediction of the Bilinear Stress-Strain Curve of Aluminum Alloys Using Artificial Intelligence and Big Data, *Metals* 2020, 10(7), 904.
- [27] CHEN, Tianqi; GUESTRIN, Carlos. XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining – KDD '16*. p. 785–794, 2016.
- [28] NGUYEN, Hoang D.; DAO, Nhan D.; SHIN, Myoungsu. Prediction of seismic drift responses of planar steel moment frames using artificial neural network and extreme gradient boosting. *Engineering Structures*, v. 242, p. 112518, 1 set. 2021.
- [29] BENTÉJAC, Candice; CSÖRGÓ, Anna; MARTÍNEZ-MUÑOZ, Gonzalo. A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, v. 54, p. 1937–1967, 2021.