

**44° SENAFOR**

28ª Conferência Internacional de Forjamento - Brasil  
14ª Conferência Internacional de Conformação de Chapas / 11º Congresso do BrDDRG  
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](http://www.senafor.com)

# APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE DUREZA DE PEÇAS FORJADAS A QUENTE

Peterson Duarte Diehl <sup>(1)</sup>  
André Rosiak <sup>(2)</sup>  
Roderval Marcelino <sup>(3)</sup>  
Lirio Schaeffer <sup>(4)</sup>

## RESUMO

Este estudo investiga a aplicação de técnicas de aprendizado de máquina para a predição da dureza de aços bainíticos forjados, com o objetivo de aprimorar o controle inteligente do processo. Para tal finalidade, foi desenvolvida uma base de dados experimental, incluindo parâmetros termomecânicos-chave do processo e os valores de dureza dos componentes forjados. O desempenho dos modelos Rede Neural Artificial (RNA), Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF) foi avaliado. A RNA, configurada com três camadas ocultas (64, 128 e 256 neurônios), apresentou o melhor desempenho, alcançando um Erro Absoluto Médio (MAE) de 1,3518 HV, Erro Quadrático Médio (MSE) de 8,8448 HV<sup>2</sup> e um Coeficiente de Determinação (R<sup>2</sup>) de 0,994. Testes de inferência confirmaram a robustez e a aplicabilidade prática do modelo, validando seu uso em cenários reais de forjamento, como a previsão da dureza de bielas forjadas. Os resultados demonstram que a utilização de modelos baseados em inteligência artificial pode apoiar de forma eficaz a tomada de decisão e o ajuste dinâmico do processo de forjamento, possibilitando a identificação de inconsistências produtivas e a implementação de correções em tempo real.

**Palavras-chave:** Inteligência Artificial, Forjamento, Aço Bainítico, Aprendizado de Máquina.

## 1. INTRODUÇÃO

Grandes esforços têm sido realizados para melhorar as propriedades mecânicas dos aços forjados para aplicações críticas em peças de segurança. Entre os desenvolvimentos estão os aços bainíticos [1]. Os aços bainíticos combinam as propriedades ideais dos aços temperados e revenidos (Q&T) com uma rota de produção curta. A versatilidade e os custos racionais de produção tornaram estes aços a escolha ideal para componentes estruturais na engenharia automotiva. Os valores de resistência mecânica e tenacidade dos bainíticos estão dentro da faixa alcançada pelos aços Q&T temperados e revenidos, como o DIN 42CrMo4. As análises de resistência à fadiga também indicam melhores propriedades dinâmicas do que os aços Q&T [2].

A rota de processamento termomecânico dos aços bainíticos inclui o aquecimento a temperaturas em torno de 1200°C, forjamento e resfriamento contínuo. A aplicação do resfriamento contínuo, em detrimento ao uso de longos tratamentos isotérmicos ou têmpera e revenimento convencionais, é capaz de reduzir significativamente o consumo de energia e, conseqüentemente, os custos de fabricação [3].

As propriedades finais de peças forjadas são determinadas tanto pela composição química quanto pelas condições de processamento. Em particular, os parâmetros de conformação e resfriamento são extremamente sensíveis e exercem influência direta na robustez da produção. Diferenças no histórico térmico entre a superfície e o núcleo da peça podem resultar em microestruturas distintas, levando à formação de gradientes nas propriedades mecânicas [4]. A capacidade de correlacionar dados de produção coletados em tempo real com a qualidade do produto final — permitindo a identificação precoce de desvios e fornecendo suporte ágil e preciso à tomada de decisões — torna as ferramentas de Inteligência Artificial altamente promissoras para o ajuste dinâmico do processo de forjamento de aços bainíticos.

A aplicação de ferramentas de Inteligência Artificial (IA) tem demonstrado grande potencial para transformar a indústria, impulsionando avanços significativos em eficiência, qualidade e inovação. No contexto da conformação mecânica, modelos baseados em IA já foram desenvolvidos com o objetivo de otimizar rotas de processamento [5,6], prever falhas e defeitos [7–11], além de estimar o comportamento de materiais sob condições complexas de carga, capturando relações não lineares entre tensões e deformações [12–17]. A IA também tem sido aplicada no controle em tempo real de processos de conformação, especialmente em sistemas com monitoramento de qualidade, nos quais redes neurais são treinadas para ajustar automaticamente os parâmetros do processo com base em dados fornecidos por sensores [18-20].

Este estudo investiga a aplicação de técnicas de aprendizado de máquina para o controle da qualidade de produtos forjados bainíticos, por meio da predição da dureza das peças com base em dados experimentais do processo. O processo analisado envolve um aço microligado de baixo carbono, com composição química 0,18C–1,38Mn–0,36Si–0,47Cr–0,03Mo–0,05Al–0,04Nb–0,01Ti, que é aquecido a altas temperaturas, forjado e resfriado continuamente ao ar. O forjamento é realizado em corpos de prova com geometria de cunha, permitindo a geração de diferentes combinações de parâmetros termomecânicos ao longo da peça. Os dados obtidos por sensoriamento e simulação numérica resultam em um banco de dados com 2.955 registros, utilizados no treinamento e na calibração de modelos de Redes Neurais Artificiais (RNA), Máquinas de Vetores de Suporte (SVM) e Florestas Aleatórias (RF).

A definição de um modelo capaz de compreender as complexas correlações entre os dados de dureza final e os parâmetros termomecânicos constitui uma ferramenta eficaz para o controle do processo de forjamento, permitindo a identificação de inconsistências produtivas e a implementação de correções em tempo real.

## 2. MATERIAIS E MÉTODOS

Este estudo investiga o uso de técnicas de aprendizado de máquina para prever a dureza de produtos forjados com base em dados experimentais. A Figura 1 mostra esquematicamente a metodologia empregada. O trabalho é desenvolvido em três fases principais compostas, respectivamente, pela (i) criação do conjunto de dados; (ii) previsão e análise (iii) teste de inferência. A seguir, cada uma destas etapas é detalhada.

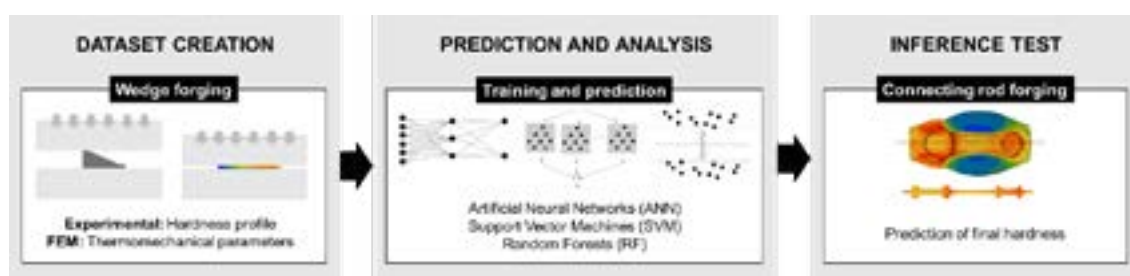


Figura 1 Metodologia empregada.


### 2.1 Criação do banco de dados

A dureza de um componente bainítico forjado a quente é determinada pelas condições do processamento termomecânico [21]. O desenvolvimento de ferramentas baseadas em inteligência artificial (IA) para prever a dureza desses componentes exige a construção de um banco de dados robusto [22,23], capaz de capturar as inter-relações entre os diversos parâmetros termomecânicos do processo e a dureza final. Para isso, é necessário gerar um grande número de combinações entre parâmetros de processo e os correspondentes valores de dureza.

Uma estratégia eficiente para obter diferentes combinações de parâmetros termomecânicos e respectivos valores de dureza, consiste no forjamento de amostras na forma de cunha entre matrizes planas paralelas [24]. Como resultado, as amostras sofrem deformações que variam ao longo do corpo de prova. A combinação do procedimento experimental com análises numéricas gera uma ampla gama de resultados sem a necessidade de um número elevado de testes. Essa é uma forma econômica e ágil de avaliar o efeito da deformação e da velocidade de deformação nas mudanças microestruturais que ocorrem durante a deformação a quente.

Essa abordagem foi empregada para gerar o conjunto de dados utilizado no treinamento e na calibração dos modelos de inteligência artificial. O processo de forjamento das cunhas é representado esquematicamente na Figura 2. O material investigado, um aço microligado com a composição química 0,18C–1,38Mn–0,36Si–0,47Cr–0,03Mo–0,05Al–0,04Nb–0,01Ti, foi forjado em três temperaturas distintas,

após o aquecimento em forno resistivo a 1000°C, 1100°C e 1200°C. A realização dos ensaios em diferentes temperaturas teve como objetivo ampliar a diversidade do banco de dados, incorporando múltiplas combinações de condições de resfriamento. As informações técnicas detalhadas do processo de forjamento das cunhas, incluindo parâmetros termomecânicos e operacionais relevantes, estão apresentadas na Tabela 1. Mais detalhes sobre os ensaios de cunha estão disponíveis em [21].



**Figura 2** Forjamento das cunhas.

Durante os testes, foi realizada a aquisição de dados de força e deslocamento. O deslocamento da prensa foi monitorado por um transdutor de deslocamento variável linear (Linear Variable Differential Transformer-LVDT) e a força por uma célula de carga montada na mesa inferior da prensa. A temperatura das peças também foi monitorada a partir de um termopar tipo K introduzido no núcleo de cada amostra. Os sinais foram adquiridos pelo aparelho Spider 8 da marca HBM e tratados pelo software Catman Express.

Os dados de força, deslocamento e temperatura foram utilizados como variáveis de entrada na análise inversa do procedimento experimental, realizada por meio do software QForm UK. Aplicando o método dos elementos finitos, foram efetuadas simulações tridimensionais (3D) dos ensaios de forjamento. Os dados experimentais e numéricos foram complementados pelos correspondentes valores de dureza obtidos em cada cunha. As amostras forjadas foram seccionadas, e o perfil de microdureza foi determinado ao longo da seção longitudinal de cada cunha.

O conjunto de dados foi composto por informações de dureza, deformação equivalente ( $\bar{\epsilon}$ ), velocidade de deformação ( $\dot{\bar{\epsilon}}$ ), temperatura inicial ( $\theta_i$ ) — correspondente à temperatura de aquecimento das cunhas — e temperatura final ( $\theta_f$ ),

referente à temperatura ao final do forjamento, imediatamente após a abertura da prensa. Ao todo, foram gerados 2.955 registros. A relação entre os dados dos parâmetros termomecânicos e os valores de dureza está apresentada na Figura 3. Observa-se que a dureza apresenta uma variação não linear em função de todos os parâmetros analisados, o que evidencia a complexidade das interações envolvidas no processo de forjamento a quente.

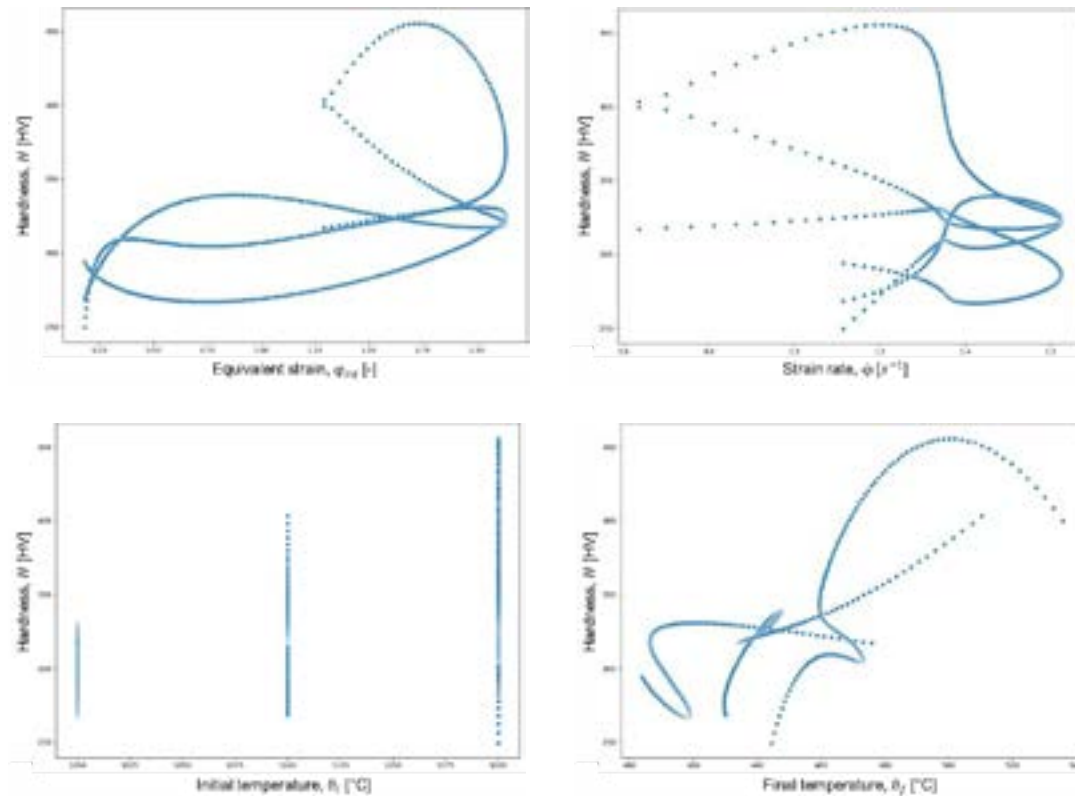
**Tabela 1** Informações técnicas detalhadas do processo de forjamento das cunhas.

Material	0,18C–1,38Mn–0,36Si–0,47Cr–0,03Mo–0,05Al–0,04Nb–0,01Ti
Temperatura do material	1000°C
	1100°C
	1200°C
Método de aquecimento do material	Forno resistivo
Tempo de aquecimento	30min
Temperatura das ferramentas	150°C
Lubrificação	Solução a base de grafite
Equipamento de forjamento	Prensa hidráulica ( $v = 5\text{mm/s}$ )
Redução de altura	82%
Resfriamento após o forjamento	Contínuo ao ar

**Tabela 2** Estatísticas descritivas do conjunto de dados

Variável	Média	Desvio Padrão	Mínimo	Máximo
Deformação, $\phi$ [-]	1,549	0,657	0,180	2,135
Velocidade de deformação, $\dot{\phi}$ [ $s^{-1}$ ]	1,395	0,178	0,636	1,623
Temperatura inicial, $\theta_i$ [°C]	1100°C	81,718	1000	1200
Temperatura final, $\theta_f$ [°C]	443,7°C	26,695	43,9	535,8
Dureza, H [HV]	319,99	40,223	249,7	455,5

A Tabela 2 apresenta as estatísticas descritivas do conjunto de dados. É importante considerar que os modelos de inteligência artificial (IA) desenvolvidos serão capazes de prever as propriedades de forjados produzidos por rotas termomecânicas cujos parâmetros estejam contidos dentro das faixas representadas no banco de dados. Processos de fabricação que envolvam condições distintas requerem a geração de novos dados para ampliar a cobertura e, conseqüentemente, a precisão e a capacidade de generalização dos modelos.



**Figura 3** Relação entre os dados dos parâmetros termomecânicos e os valores de dureza.

## 2.2 Predição e análise

A etapa de predição e análise foi realizada por meio do desenvolvimento de modelos de Redes Neurais Artificiais (RNA) utilizando as bibliotecas TensorFlow e Keras, que oferece uma plataforma flexível e eficiente para a construção, o treinamento e a validação de modelos de aprendizado profundo.

Previamente ao treinamento dos modelos de inteligência artificial, o conjunto de dados foi submetido a uma etapa de pré-processamento, visando garantir a consistência e a eficiência do processo de modelagem. Inicialmente, todos os atributos contínuos foram normalizados. A normalização é uma etapa fundamental no pré-processamento de dados, especialmente em problemas que envolvem algoritmos de aprendizado de máquina. Ela consiste em ajustar os valores das variáveis para que todos fiquem dentro de uma mesma escala, evitando que atributos com magnitudes maiores dominem o processo de treinamento [25,26].

No presente trabalho, foi utilizada a normalização Min-Max, que transforma cada valor da variável de entrada para a faixa [0, 1], de acordo com a seguinte fórmula:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Onde  $X$  é o valor original e  $X_{norm}$  o valor normalizado.  $X_{min}$  e  $X_{max}$  correspondem, respectivamente, ao menor e maior valor observados para a variável. Este procedimento foi implementado utilizando o MinMaxScaler da biblioteca scikit-

learn, que automatiza o cálculo e a aplicação dessa transformação em todos os atributos selecionados.

O conjunto de dados normalizados foi dividido aleatoriamente, sendo 70% destinado ao treinamento e 30% à validação do modelo. A divisão aleatória, repetida em diferentes execuções, visa aumentar a robustez estatística dos resultados, reduzindo o risco de que padrões específicos ou distribuições anômalas em uma única partição afetem negativamente o desempenho e a capacidade de generalização da RNA.

Para a otimização dos pesos da rede, optou-se pelo algoritmo Adam (Adaptive Moment Estimation), amplamente reconhecido por sua eficiência e estabilidade, especialmente em problemas que envolvem conjuntos de dados complexos e funções de perda potencialmente não convexas. O Adam combina as vantagens dos métodos de gradiente estocástico com a adaptação individual das taxas de aprendizado para cada parâmetro, o que favorece uma convergência mais rápida e confiável [27].

A função de perda escolhida foi o Erro Quadrático Médio (MSE), em virtude de sua adequação a problemas de regressão contínua, como a previsão de dureza, e de sua propriedade de penalizar de forma mais intensa os erros de maior magnitude, estimulando ajustes mais precisos do modelo.

Para evitar o sobreajuste (overfitting) — um risco inerente em modelos de aprendizado profundo, especialmente quando o número de parâmetros da rede é elevado — foi implementado o mecanismo de parada antecipada (early stopping). Esse procedimento monitora o desempenho do modelo no conjunto de validação e interrompe o treinamento automaticamente caso não seja observada melhoria após um número predefinido de épocas consecutivas, evitando que o modelo se ajuste excessivamente ao ruído dos dados de treinamento. O número máximo de épocas foi estabelecido em 300, como um limite prudencial que equilibra a necessidade de permitir a convergência adequada da RNA sem incorrer em excessivo custo computacional ou risco de sobreajuste.

A avaliação do desempenho preditivo da rede foi realizada a partir de três métricas complementares: o Erro Médio Absoluto (MAE), que fornece uma medida direta da média dos erros absolutos cometidos pelo modelo; o Erro Quadrático Médio (MSE), que quantifica a média dos erros elevados ao quadrado, dando maior peso a desvios mais expressivos; e o Coeficiente de Determinação ( $R^2$ ), que expressa a proporção da variância total dos dados que é explicada pelo modelo, sendo um indicador global da qualidade do ajuste e da capacidade preditiva.

Com o objetivo de avaliar a robustez e a capacidade preditiva da Rede Neural Artificial (RNA) desenvolvida, foram também implementados e testados dois outros modelos amplamente utilizados em tarefas de regressão: Máquinas de Vetores de Suporte (SVM) e Floresta Aleatória (RF).

As Máquinas de Vetores de Suporte (SVM) são modelos baseados na teoria de maximização de margens, originalmente concebidos para problemas de classificação, mas que podem ser adaptados para regressão por meio da técnica conhecida como Support Vector Regression (SVR). A SVM busca encontrar uma função que aproxime


os dados dentro de uma margem de tolerância aceitável, minimizando ao mesmo tempo a complexidade do modelo [28,29]. Neste trabalho, foi utilizado o kernel RBF (Radial Basis Function), uma função amplamente empregada por sua capacidade de modelar relações não lineares, ajustando-se de forma flexível às características do conjunto de dados [30]. O modelo SVM foi desenvolvido com a normalização prévia dos dados e o ajuste dos hiperparâmetros por meio de validação cruzada, buscando otimizar o equilíbrio entre viés e variância [31,32].

A Floresta Aleatória (Random Forest, RF), por sua vez, é um modelo baseado no princípio de ensemble learning, que consiste na combinação de múltiplas árvores de decisão para produzir um resultado mais robusto e menos suscetível a overfitting [33-35]. Neste estudo, a RF foi implementada com 100 árvores de decisão, configuradas com profundidade e número mínimo de amostras ajustados por meio de validação cruzada, com o objetivo de otimizar a generalização do modelo.

### 2.3 Testes de inferência

Com o objetivo de ampliar a avaliação da capacidade preditiva e de generalização do modelo desenvolvido, foram realizados testes de inferência utilizando dados não pertencentes ao conjunto originalmente empregado para o treinamento e a validação da Rede Neural Artificial. Essa abordagem visa simular condições reais de aplicação, em que o modelo é exposto a novos cenários, distintos daqueles previamente conhecidos.

Nos testes de inferência, o modelo foi aplicado para prever a dureza do material investigado após o forjamento a quente de uma biela. O processo experimental, representado esquematicamente na Figura 4, consistiu no aquecimento do material a 1200°C, seguido de sua transferência para uma prensa hidráulica, onde foi realizada a operação de forjamento. Após a extração da peça, o resfriamento foi conduzido de forma contínua ao ar até a temperatura ambiente.



**Figura 4** Forjamento da biela.

As informações técnicas detalhadas do processo de forjamento da biela, incluindo parâmetros termomecânicos e operacionais relevantes, estão apresentadas na Tabela 3. Posteriormente ao forjamento, as bielas foram seccionadas e o perfil de

microdureza foi determinado ao longo da seção longitudinal, conforme ilustrado na Figura 5.

**Tabela 3** Informações técnicas detalhadas do processo de forjamento da biela.

Material	0,18C–1,38Mn–0,36Si–0,47Cr–0,03Mo–0,05Al–0,04Nb–0,01Ti
Temperatura do material	1200°C
Método de aquecimento do material	Forno resistivo
Tempo de aquecimento	30min
Temperatura das ferramentas	150°C
Lubrificação	Solução a base de grafite
Equipamento de forjamento	Prensa hidráulica ( $v = 5\text{mm/s}$ )
Resfriamento após o forjamento	Contínuo ao ar

Essa metodologia permitiu a comparação direta entre as previsões geradas pelo modelo de IA e os valores reais de dureza obtidos experimentalmente, constituindo uma etapa essencial para validar a eficácia e a aplicabilidade prática do modelo desenvolvido fora do domínio específico de treinamento.

### 3. RESULTADOS E DISCUSSÕES

#### 3.1 Desempenho da Rede Neural Artificial


Como resultado das análises realizadas, foi definida uma arquitetura de Rede Neural Artificial composta por três camadas ocultas, configuradas com 64, 128 e 256 neurônios, respectivamente (Figura 5). Em todas as camadas ocultas foi utilizada a função de ativação ReLU (Rectified Linear Unit), dada a sua simplicidade computacional e capacidade de mitigar problemas relacionados ao gradiente desvanescente, favorecendo a eficiência e a estabilidade no treinamento de modelos profundos.

A escolha desse número de neurônios e da estrutura em múltiplas camadas reflete um equilíbrio entre a complexidade do modelo — necessária para capturar as inter-relações não lineares entre os parâmetros termomecânicos e a dureza — e a necessidade de evitar o sobreajuste, especialmente considerando a dimensão do conjunto de dados disponível.

Essa arquitetura se mostrou adequada para o problema proposto, permitindo que o modelo aprendesse com eficiência os padrões subjacentes aos dados e apresentasse bom desempenho nas etapas de validação e inferência. A camada de entrada da Rede Neural Artificial é composta pelos quatro parâmetros termomecânicos principais: deformação equivalente, velocidade de deformação, temperatura inicial e temperatura final do forjamento. Esses atributos foram

selecionados por representarem as variáveis mais relevantes para a definição da microestrutura e, conseqüentemente, da dureza do material forjado.

A camada de saída consiste em um único neurônio, cuja função é prever o valor correspondente de dureza para cada combinação específica de parâmetros de entrada. Essa configuração caracteriza um modelo típico de regressão, adequado para a previsão de variáveis contínuas.




**Figura 5** Arquitetura da Rede Neural Artificial proposta.

A complexidade da topologia da rede desempenha um papel fundamental no seu desempenho. Estruturas mais complexas, como a arquitetura adotada neste estudo — composta por três camadas ocultas configuradas com 64, 128 e 256 neurônios —, são capazes de capturar relações não lineares altamente intrincadas entre as variáveis, superando as limitações típicas de arquiteturas mais simples. Contudo, esse aumento expressivo de capacidade implica também a necessidade de maiores recursos computacionais, incluindo tempo de processamento, potência de hardware e, frequentemente, volumes mais amplos de dados de entrada para garantir um treinamento eficaz [35].

No desenvolvimento do modelo, buscou-se estabelecer um equilíbrio adequado entre a profundidade e a largura da rede, de modo a otimizar o desempenho preditivo sem comprometer excessivamente a eficiência computacional. Essa abordagem visa maximizar a eficácia do modelo, assegurando um aprendizado robusto e preciso, ao mesmo tempo que evita a complexidade desnecessária, que poderia conduzir ao sobreajuste ou à inviabilidade prática de sua aplicação.

A análise de convergência do modelo indicou uma redução consistente dos valores de Erro Médio Absoluto (MAE) e Erro Quadrático Médio (MSE) ao longo do processo de treinamento, conforme ilustrado na Figura 6. Inicialmente, observou-se uma redução progressiva dos valores de MAE e MSE, à medida que o modelo ajustava seus parâmetros para se adequar aos padrões presentes nos dados de treinamento. Esse comportamento evidencia o processo de aprendizado da rede, que busca minimizar as discrepâncias entre as previsões e os valores reais. Com o avanço das iterações, os erros convergiram para valores relativamente baixos, indicando que a RNA estava aprendendo de forma eficaz e se aproximando de uma solução ótima. Posteriormente, os gráficos da Figura 6 revelam uma estabilização nas métricas de erro, com variações mínimas ao longo das últimas épocas. Esse padrão sugere que o

modelo atingiu um ponto de saturação, no qual ajustes adicionais não resultam em melhorias significativas no desempenho, caracterizando a convergência do processo de treinamento e confirmando a adequação da arquitetura e dos hiperparâmetros adotados.



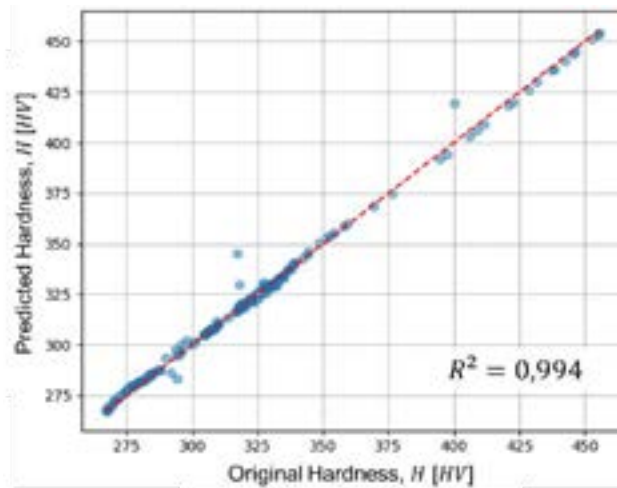
**Figura 6** Análise de convergência do modelo através da evolução do Erro Quadrático Médio (MSE) e do Erro Médio Absoluto (MAE) em função do número de iterações.

Os resultados obtidos para o modelo desenvolvido demonstram um desempenho preditivo altamente satisfatório. Após as 300 iterações, o Erro Absoluto Médio foi de 1,3518 HV e o Erro Quadrático foi de 8,8448 HV<sup>2</sup>. O valor do Erro Médio Absoluto (MAE) de 1,3518 HV indica que, em média, as previsões da Rede Neural Artificial diferem menos de 2 unidades de dureza Vickers em relação aos valores reais. Esse nível de erro é extremamente baixo, sobretudo considerando a variabilidade típica de processos de forjamento a quente e a complexidade das relações não lineares entre os parâmetros termomecânicos e a dureza. De forma complementar, o Erro Quadrático Médio (MSE) de 8,8448 HV<sup>2</sup> confirma a precisão do modelo, evidenciando que os desvios mais expressivos foram raros e de baixa magnitude. O valor reduzido do MSE reforça a capacidade do modelo de capturar com fidelidade os padrões subjacentes aos dados, minimizando tanto os erros sistemáticos quanto as flutuações aleatórias.

Esses indicadores atestam a eficácia da arquitetura de RNA definida, bem como a adequação do conjunto de dados e dos procedimentos de pré-processamento e treinamento adotados. Além disso, os baixos valores de erro sugerem que o modelo possui elevada capacidade de generalização.

O valor obtido para o Coeficiente de Determinação ( $R^2$ ) foi de 0,994, indicando que o modelo desenvolvido é capaz de explicar aproximadamente 99,4% da variância presente nos dados de dureza, o que evidencia uma excelente capacidade preditiva. Esse resultado confirma que a Rede Neural Artificial foi altamente eficaz na modelagem das complexas relações não lineares entre os parâmetros termomecânicos e a dureza resultante do material forjado.


A análise gráfica da relação entre os valores de dureza previstos e reais (Figura 7) reforça essa conclusão. Observa-se que a maioria dos pontos está fortemente concentrada ao longo da linha de referência (traçado vermelho), que representa a correspondência ideal entre previsão e realidade. A distribuição próxima dessa linha, com pequenas dispersões, indica que o modelo apresenta baixo erro sistemático e boa generalização, mesmo diante de variações naturais do processo.



**Figura 7** Predição da dureza em função do respectivo valor original.

A presença de alguns pontos ligeiramente afastados sugere ocorrências pontuais de maior erro, possivelmente associadas a regiões do espaço de parâmetros com menor densidade de dados no conjunto de treinamento ou a variabilidades inerentes ao processo de forjamento. No entanto, esses desvios são poucos e de pequena magnitude, como já evidenciado pelos baixos valores de MAE e MSE.

A Figura 8 mostra a análise da distribuição dos erros da Rede Neural Artificial (RNA) e revela um comportamento aproximadamente simétrico e centrado em torno de zero, o que é característico de um modelo bem ajustado. A elevada concentração de erros próximos de zero indica que, na maioria das previsões, as discrepâncias entre os valores previstos e os reais foram muito pequenas, confirmando a precisão e a consistência do modelo.



**Figura 8** Análise da distribuição dos erros da RNA proposta.

A presença de uma curva suavizada com formato próximo ao de uma distribuição normal reforça a adequação do modelo ao problema, sugerindo que não há tendências sistemáticas de superestimação ou subestimação das previsões. Além disso, a ocorrência de poucos outliers, com erros mais expressivos situados nas extremidades, é natural em processos industriais, principalmente quando se considera a variabilidade intrínseca associada ao forjamento a quente e possíveis regiões de menor densidade no espaço de dados.

Os erros foram classificados em faixas de valor para quantificar sua frequência em diferentes intervalos, permitindo uma análise mais granular do comportamento do modelo. As faixas foram definidas como: < -10, -10 a -5, -5 a -2, -2 a 0, 0 a 2, 2 a 5, 5 a 10 e > 10. A Tabela 4 apresenta a distribuição dos erros de previsão por intervalo.


A baixa dispersão dos erros e a assimetria reduzida evidenciam a robustez do treinamento e a capacidade da arquitetura definida em generalizar bem para diferentes combinações de parâmetros termomecânicos. Esses resultados complementam as evidências fornecidas pelas métricas de avaliação e pelo coeficiente de determinação ( $R^2$ ), confirmando a eficiência e a confiabilidade do modelo desenvolvido.

**Tabela 4** Quantidade de valores encontrados por Grandeza de erro.

Grandeza do erro [HV]	Quantidade de valores encontrados
<-10	3
-10 a -5	0
-5 a -2	3
-2 a 0	70
0 a 2	84
2 a 5	16
5 a 10	2
>10	0

### 3.2 Comparação de Desempenho com Outros Modelos de Aprendizado de Máquina

A avaliação dos modelos alternativos revelou desempenhos satisfatórios, embora inferiores ao da Rede Neural Artificial, como mostra a Figura 9. A Máquina de Vetores de Suporte (SVM) apresentou um Erro Médio Absoluto (MAE) de 2,891 HV e um Erro Quadrático Médio (MSE) de 27,287 HV<sup>2</sup>, com um Coeficiente de Determinação ( $R^2$ ) de 0,984. Esses resultados indicam uma boa capacidade preditiva, porém com uma dispersão de erros relativamente maior, especialmente quando se considera o valor do MSE, que reflete maior sensibilidade a desvios mais expressivos.




**Figura 9** Comparação do desempenho dos modelos investigados com relação ao Erro Quadrático Médio (MSE) e ao Erro Médio Absoluto (MAE).

O modelo de Floresta Aleatória (Random Forest, RF), por sua vez, obteve um MAE de 1,654 HV e um MSE de 34,929 HV<sup>2</sup>, com um  $R^2$  de 0,980. Embora o erro médio absoluto tenha sido próximo ao da Rede Neural, o elevado MSE sugere maior ocorrência de erros extremos, que impactam negativamente a precisão global do modelo. Além disso, o  $R^2$ , embora elevado, foi o mais baixo entre os três modelos, indicando menor capacidade explicativa da variabilidade presente nos dados.

Embora tanto a SVM quanto a RF tenham se mostrado modelos adequados para a tarefa de predição da dureza em função dos parâmetros termomecânicos, a RNA se destacou como a opção mais eficiente e robusta, conciliando baixa margem de erro com elevada fidelidade preditiva, sendo, portanto, a mais indicada para aplicações que exigem altos níveis de confiabilidade e precisão.

A análise da relação entre os valores previstos e reais para os modelos de Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF) (Figura 10) evidencia que ambos os métodos apresentaram um bom desempenho preditivo, com forte alinhamento dos pontos ao longo da linha de identidade (linha vermelha tracejada), que representa a correspondência ideal entre previsão e realidade. No entanto, observa-se que o modelo SVM apresenta uma maior dispersão dos pontos, especialmente na faixa superior das durezas, a partir de aproximadamente 375 HV. Nessa região, há uma tendência a subestimar os valores mais altos de dureza, com previsões mais afastadas da linha ideal. Esse comportamento contribui para o erro médio e quadrático mais elevados observados para a SVM, refletindo uma menor capacidade de generalização em comparação aos demais modelos, especialmente em extremos de dureza.

Por outro lado, o modelo de Floresta Aleatória (RF) apresentou uma distribuição mais concentrada dos pontos ao longo da linha de referência, com menores desvios sistemáticos. Embora existam alguns outliers isolados, principalmente na faixa intermediária e superior dos valores de dureza, a dispersão geral é menor que a observada na SVM, o que se reflete em um desempenho superior no Erro Médio Absoluto (MAE). Ainda assim, a maior sensibilidade a erros quadráticos, conforme evidenciado pelo MSE, indica que a RF apresentou dificuldades em controlar erros mais expressivos, possivelmente relacionados a combinações específicas de parâmetros termomecânicos com baixa representatividade no conjunto de dados.




**Figura 10** Predição da dureza em função do respectivo valor original para os modelos de SVM e RF.

O heatmap do erro absoluto por amostra (Figura 11) fornece uma visão comparativa detalhada da distribuição dos erros ao longo de todas as previsões realizadas pelos três modelos. Observa-se que a RNA apresenta, de maneira geral, uma distribuição mais homogênea dos erros, com a grande maioria das amostras associadas a baixos valores de erro absoluto, indicados pelas tonalidades mais escuras (roxo profundo). Apenas alguns poucos pontos isolados apresentam erros moderados, o que reforça a robustez e a estabilidade preditiva do modelo ao longo de diferentes regiões do espaço de entrada.

O modelo SVM, por sua vez, evidencia uma maior frequência de erros moderados ao longo de diversas amostras, com uma distribuição mais irregular e dispersa. As tonalidades mais claras indicam a presença de vários casos com erros mais elevados, o que corrobora a observação anterior de que a SVM apresentou maior sensibilidade a desvios e dificuldade em generalizar adequadamente, especialmente em regiões mais complexas do espaço de parâmetros.

Já a Floresta Aleatória (RF) apresenta um comportamento intermediário: embora a maior parte das amostras também esteja associada a erros baixos, há ocorrência de erros extremos, como destacado pela presença de uma faixa amarela intensa, correspondente a um erro superior a 50 HV em uma amostra específica. Essa ocorrência pontual, embora isolada, eleva significativamente o erro quadrático médio (MSE) do modelo, indicando uma vulnerabilidade a outliers ou a casos pouco representados no conjunto de treinamento.



**Figura 11** Heatmap do erro absoluto por amostra.

De modo geral, o heatmap reforça a superioridade da RNA na tarefa de predição da dureza, apresentando menor variabilidade nos erros e maior consistência em comparação com os outros modelos. Além disso, evidencia que, embora tanto a SVM quanto a RF sejam capazes de realizar previsões aceitáveis, ambas apresentam fragilidades específicas: a SVM com maior dispersão de erros e a RF com sensibilidade a outliers extremos.

A complexidade computacional é um fator crucial na escolha do modelo mais adequado, especialmente quando se considera a aplicação prática em ambientes industriais ou de pesquisa. No presente estudo, a Rede Neural Artificial (RNA) demandou um maior tempo de treinamento, totalizando aproximadamente 1 minuto e 25 segundos. Esse tempo mais elevado está diretamente relacionado à complexidade da arquitetura adotada, com múltiplas camadas e um número significativo de neurônios, além da necessidade de ajustes iterativos intensivos para a otimização dos pesos e minimização da função de perda.

Contudo, esse maior custo computacional é compensado pela alta acurácia do modelo, que apresentou o melhor desempenho preditivo entre as abordagens testadas, tanto em termos de baixa margem de erro quanto de elevada capacidade explicativa. Assim, a RNA se justifica plenamente em contextos onde a precisão é crítica, e o tempo de treinamento não é um fator limitante.

Por outro lado, os modelos de Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF) apresentaram tempos de treinamento significativamente menores, de aproximadamente 10 segundos e 30 segundos, respectivamente. Essa eficiência computacional torna essas técnicas vantajosas em situações onde a rapidez na obtenção do modelo é essencial, ou quando os recursos computacionais são limitados.

Entretanto, essa rapidez é acompanhada por um desempenho inferior em relação à RNA, com maiores erros médios e quadráticos, além de menor capacidade de generalização. Assim, a escolha entre os modelos envolve um trade-off clássico entre tempo computacional e desempenho preditivo: enquanto a RNA oferece maior precisão a um custo computacional mais elevado, a SVM e a RF possibilitam soluções mais rápidas, porém menos precisas.

Esse balanço deve ser cuidadosamente considerado conforme as demandas específicas da aplicação: se o objetivo for máxima precisão e robustez, a RNA se destaca; se, por outro lado, for necessária uma implementação rápida com precisão aceitável, SVM e RF podem ser alternativas viáveis.

### 3.3 Testes de Inferência

A fim de validar a capacidade de generalização e robustez dos modelos desenvolvidos, foram realizados testes de inferência utilizando dados que não participaram do treinamento ou validação prévia. O desempenho dos modelos foi analisado por meio da comparação direta das previsões com os valores reais de dureza de bielas forjadas, bem como pela avaliação das distribuições dos desvios em relação aos valores esperados.

A Figura 12 apresenta a comparação entre os 10 primeiros valores previstos e os valores reais. Observa-se que, de modo geral, todos os modelos — Rede Neural Artificial (RNA), Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF) — conseguiram aproximar-se dos valores reais com razoável precisão. Entretanto, nota-se que a RNA mantém uma maior regularidade, com previsões sistematicamente mais próximas dos valores reais em comparação aos demais métodos, enquanto a SVM e a RF apresentam desvios mais visíveis em algumas amostras, especialmente em casos de valores de dureza mais elevados.

A análise da distribuição dos desvios foi realizada através de dois métodos complementares: o boxplot (Figura 13) e o violin plot (Figura 14). O boxplot evidencia que a RNA possui uma dispersão menor dos desvios em relação aos demais modelos, com a maioria dos erros concentrados próximos de zero e poucos outliers de baixa magnitude. Em contrapartida, tanto a SVM quanto a RF apresentam distribuições mais amplas, com maior número de outliers e desvios mais acentuados, especialmente no caso da SVM, onde se observam erros sistematicamente mais elevados em alguns casos.

O violin plot complementa essa análise ao ilustrar a densidade das distribuições dos desvios para cada modelo. A RNA apresenta uma distribuição mais estreita e concentrada, reforçando sua capacidade de produzir previsões com menor variabilidade e maior precisão. Por outro lado, a SVM e a RF exibem distribuições mais largas, indicando uma maior variabilidade dos erros e maior propensão a desvios significativos, principalmente nas extremidades, com casos isolados de erros elevados.

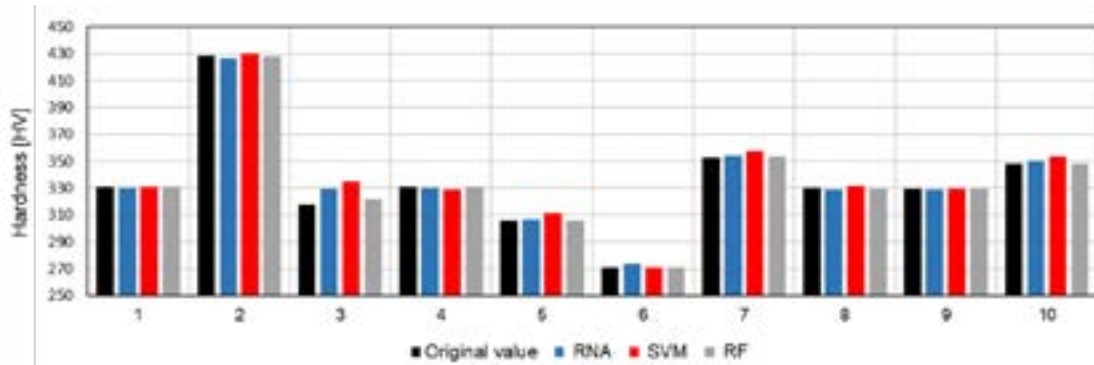


figura 12 Comparação entre valores previstos e os valores reais dos modelos analisados. F

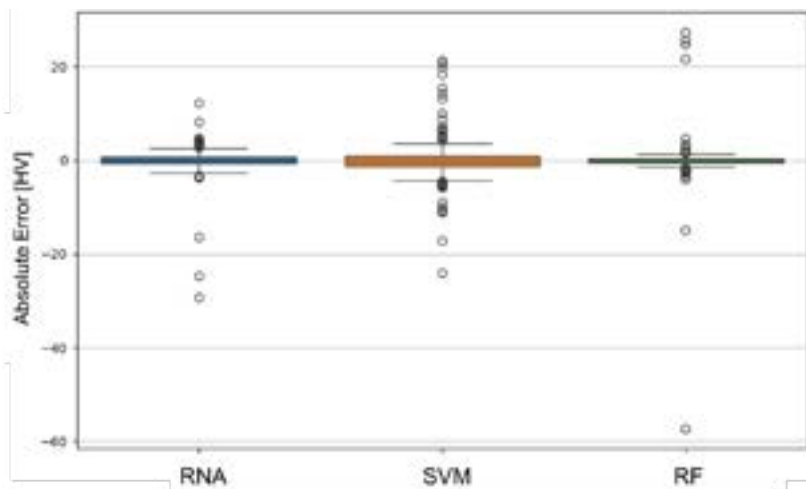


Figura 13 Análise da distribuição dos desvios através do boxplot.

Esses resultados demonstram, de forma consistente com as análises anteriores, que a Rede Neural Artificial oferece a melhor performance preditiva, combinando baixa variabilidade, reduzida incidência de outliers e menores desvios médios em relação aos valores reais. A SVM, apesar de eficiente, mostra-se mais sensível a erros em alguns cenários, enquanto a Floresta Aleatória tende a apresentar erros mais dispersos e, ocasionalmente, desvios extremos, como evidenciado pelos outliers identificados.

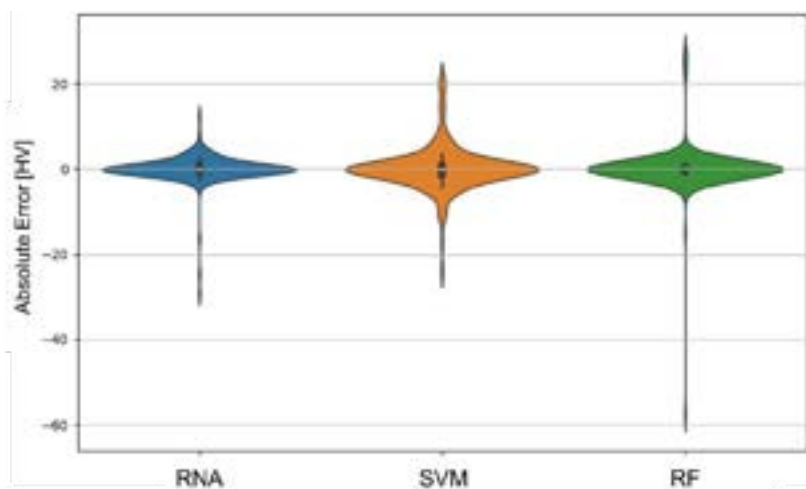


Figura 14 Análise da distribuição dos desvios através do violin plot.

#### 4. CONCLUSÕES

Este estudo investigou a viabilidade e a eficácia da aplicação de técnicas de inteligência artificial na predição da dureza de aços bainíticos forjados, com base em parâmetros termomecânicos obtidos a partir de dados experimentais e simulações numéricas.

A Rede Neural Artificial (RNA), com arquitetura composta por três camadas ocultas (64, 128 e 256 neurônios), apresentou o melhor desempenho preditivo, alcançando um Erro Médio Absoluto (MAE) de 1,3518 HV, um Erro Quadrático Médio (MSE) de 8,8448 HV<sup>2</sup> e um Coeficiente de Determinação (R<sup>2</sup>) de 0,994.

Os modelos alternativos, Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF), embora apresentem vantagens em termos de menor tempo de treinamento, mostraram desempenho inferior, com maiores erros médios e quadráticos e menor capacidade explicativa dos dados.

Os testes de inferência, realizados com dados provenientes do forjamento de bielas, validaram a robustez e aplicabilidade prática do modelo desenvolvido, demonstrando que a RNA manteve um desempenho superior mesmo quando exposta a cenários distintos dos utilizados para treinamento.

Os resultados obtidos neste estudo representam uma contribuição relevante para o projeto e controle inteligente de processos de forjamento de aços bainíticos, demonstrando o potencial das técnicas de aprendizado de máquina como ferramentas eficazes de apoio à tomada de decisão e ao ajuste dinâmico de processos industriais. O modelo desenvolvido pode ser utilizado para auxiliar engenheiros na definição dos parâmetros termomecânicos ideais durante o projeto do processo, proporcionando uma base preditiva robusta para a otimização das condições operacionais. Além disso, sua aplicação direta no controle em tempo real do processo de forjamento permite a identificação precoce de inconsistências produtivas e a implementação ágil de correções, contribuindo para a melhoria contínua da qualidade e eficiência.

Nesse contexto, destaca-se ainda a possibilidade de ampliar o banco de dados utilizado, incorporando dados reais provenientes da produção, o que permitirá que os modelos se tornem ainda mais precisos e adaptados às condições específicas de operação, promovendo uma evolução contínua da capacidade preditiva e da robustez das soluções baseadas em inteligência artificial no setor de conformação mecânica.

#### REFERÊNCIAS

- [1] HUI W., ZHANG Y., ZHAO X., XIAO N. HU F., High cycle fatigue behavior of V-microalloyed medium carbon steels: A comparison between bainitic and ferritic-pearlitic microstructures, *International Journal of Fatigue*, 2016.
- [2] BUCHMAYR B., Critical Assessment 22: bainitic forging steels, *Materials Science and Technology*, 2016.
- [3] GRAMLICH A., LANGE R., ZITZ U., BÜßENSCHÜTT K., Air-Hardening Die-Forged Con-Rods—Achievable Mechanical Properties of Bainitic and Martensitic Concepts, *Metals*, 2022.
- [4] WIRTHS W., WAGENER R., BLECK W., MELZ, T., Bainitic Forging Steels for Cyclic Loading. *Adv. Mat. Res.*, 2014.
- [5] H.-S. Park, T.-V. Anh, Optimization of Bending Sequence in Roll Forming Using Neural Network and Genetic Algorithm *Journal of Mechanical Science and Technology*, 25 (2011), pp. 2127-2136
- [6] C. Hartmann, D. Opritescu, W. Volk, An Artificial Neural Network Approach for Tool Path Generation in Incremental Sheet Metal Free-Forming, *Journal of Intelligent Manufacturing*, 30 (2) (2019), pp. 757-770.

- [7] R. Di Lorenzo, G. Ingarao, F. Micari, On the Use of Artificial Intelligence Tools for Fracture Forecast in Cold Forming Operations, *Journal of Materials Processing Technology*, 177 (1-3) (2006), pp. 315-318
- [8] D.D. Stoerkle, P. Seim, L. Thyssen, B. Kuhlenkoetter, Machine Learning in Incremental Sheet Forming, *Proceedings of ISR 2016: 47st International Symposium on Robotics, VDE* (2016), pp. 1-7.
- [9] M.A. Yatkin, M. Kõrgesaar, Machine Learning Enabled Identification of Sheet Metal Localization, *International Journal of Solids and Structures*, 288 (2024), Article 112592
- [10] S. Di, P.F. Thomson, Neural Network Approach for Prediction of Wrinkling Limit in Square Metal Sheet Under Diagonal Tension *Journal of Testing and Evaluation*, 25 (1) (1997), pp. 74-81
- [11] SPATHOPOULOS S.C., STAVROULAKIS G.E., Springback Prediction in Sheet Metal Forming, Based on Finite Element Analysis and Artificial Neural Network Approach, *Appl. Mech.*, 2020.
- [12] C. Jaremenko, N. Ravikumar, E. Affronti, M. Merklein, A. Maier, Determination of forming limits in sheet metal forming using deep learning, *Materials*, 12 (7) (2019), p. 1051
- [13] Derogar, A., & Djavanroodi, F. (2011). Artificial Neural Network Modeling of Forming Limit Diagram. *Materials and Manufacturing Processes*, 26(11), 1415–1422. <https://doi.org/10.1080/10426914.2010.544818>
- [14] M. Mozaffar, R. Bostanabad, W. Chen, K. Ehmman, J. Cao, M. Bessa. Deep Learning Predicts Path-Dependent Plasticity, *Proceedings of the National Academy of Sciences*, 116 (52) (2019), pp. 26414-26420
- [15] 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). <https://doi.org/10.1007/s00170-024-14472-0>
- [16] CHEN, L. et al. Hybrid deep learning model for simultaneous prediction of hardness and grain size in titanium alloys. *Materials & Design*, 2021.
- [17] WANG, H. et al. Prediction of Vickers hardness in aluminum alloys using artificial neural networks. *Journal of Materials Processing Technology*, 2020.
- [18] D. Wu, C. Jennings, J. Terpenney, R.X. Gao, S. Kumara, A Comparative Study On Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests, *Journal of Manufacturing Science and Engineering*, 139 (7) (2017)
- [19] MRZYGLÓD B., HAWRYLUK M., JANIK M., OLEJARCZYK-WOŹEŃSKA I., Sensitivity analysis of the artificial neural networks in a system for durability prediction of forging tools to forgings made of C45 steel, *The International Journal of Advanced Manufacturing Technology*, 2020
- [20] WANG, J.; Li, Y.; Zhao, R.; Gao, R. Physics guided neural network for machining tool wear prediction. 2020.
- [21] ROSIAK, André; DE LUCCA DE COSTA, Luana; GOMES DOS SANTOS, Thomas; SCHAEFFER, Lirio. Analysis of Hot Forging of a Bainitic Steel Hardened by Continuous Cooling Using Wedge Test. *JMEPEG*, 2025. <https://doi.org/10.1007/s11665-025-11091-y>.
- [22] CAO, Jian et al. Artificial intelligence in metal forming. *CIRP Annals*, v. 73, n. 2, p. 561-587, 2024.
- [23] Pelt, D.M.; Sethian, J.A. A mixed-scale dense convolutional neural network for image analysis. *Proc. Natl. Acad. Sci. USA* 2018, 115, 254–259.
- [24] DIETER, G. E., KUHN, H. A., SEMIATIN, S. L., *Handbook of Workability and Process Design*, ASM International, 2003.
- [25] Agrawal, A.; Deshpande, P.D. Exploration of data science techniques to predict fatigue strength of steel from composition and processing parameters. *Integr. Mater. Manuf. Innov.* 2014, 3, 90–108.
- [26] 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. <https://doi.org/10.3390/met10020234>
- [27] OKEWU, Emmanuel; MISRA, Sanjay; FERNANDEZ-SANZ, Lius. Parameter Tuning Using Adaptive Moment Estimation in Deep Learning Neural Networks. In: *Computational Science and Its Applications – ICCSA 2020*. Conference paper, p. 261-272. Publicado online em 30 set. 2020.
- [28] WANG, Ling; MU, Zhichun; GUO, Hui. Application of support vector machine in the prediction of mechanical property of steel materials. *Journal of University of Science and Technology Beijing, Mineral, Metallurgy, Material*, v. 13, n. 6, p. 512-515, 2006. [https://doi.org/10.1016/S1005-8850\(06\)60104-7](https://doi.org/10.1016/S1005-8850(06)60104-7).
- [29] LU, Wen-Cong; JI, Xiao-Bo; LI, Min-Jie; LIU, Liang; YUE, Bao-Hua; ZHANG, Liang-Miao. Using support vector machine for materials design. *Advances in Manufacturing*, v. 1, p. 151-159, 2013.
- [30] YAN, Cheng; SHEN, Xiuli; GUO, Fushui; ZHAO, Shiqi; ZHANG, Lizhang. A novel model modification method for support vector regression based on radial basis functions. *Structural and Multidisciplinary Optimization*, v. 60, p. 983-997, 2019.
- [31] BROWN, Tom et al. Language models are few-shot learners. *Advances in neural information processing systems*, 2020.
- [32] SMITH, Shaden et al. Using deepspeed and megatron to train megatron-turing nlg 530b, a large-scale generative language model., 2022.
- [33] KWAK, Seungmi; KIM, Jaehwang; DING, Hongsheng; XU, Xuesong; CHEN, Ruirun; GUO, Jingjie; FU, Hengzhi. Machine learning prediction of the mechanical properties of  $\gamma$ -TiAl alloys

- produced using random forest regression model. *Journal of Materials Research and Technology*, v. 18, p. 520-530, 2022.
- [34] SCHUBERT, M.; LUKOVIĆ, M.; CHRISTEN, H. Prediction of mechanical properties of wood fiber insulation boards as a function of machine and process parameters by random forest. *Wood Science and Technology*, v. 54, p. 703-713, 2020.
- [35] AKBARI, Parand; ZAMANI, Masoud; MOSTAFAEI, Amir. Machine learning prediction of mechanical properties in metal additive manufacturing. *Additive Manufacturing*, v. 91, 104320, 5 jul. 2024. <https://doi.org/10.1016/j.addma.2024.104320>.
- [36] Merayo, D.; Rodríguez-Prieto, A.; Camacho, A. Prediction of Physical and Mechanical Properties for Metallic Materials Selection Using Big Data and Artificial Neural Networks. *IEEE Access* 2020, 8, 13444–13456.