MINISTÉRIO DA EDUCAÇÃO

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Escola de Engenharia

Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais - PPGE3M

PREDIÇÃO DE DUREZA DE COMPONENTES FORJADOS A QUENTE BASEADA EM APRENDIZADO DE MÁQUINA

MSc. Eng. Peterson Duarte Diehl

Tese para a obtenção do Título de Doutor em Engenharia

Porto Alegre

2026

MINISTÉRIO DA EDUCAÇÃO

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Escola de Engenharia

Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais - PPGE3M

PREDIÇÃO DE DUREZA DE COMPONENTES FORJADOS A QUENTE BASEADA EM APRENDIZADO DE MÁQUINA

MSc. Peterson Duarte Diehl

Engenheiro Metalurgista

Proposta submetida à banca examinadora do Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais, PPGE3M, da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como parte dos requisitos para a obtenção do Título de Doutor em Engenharia.

Área de Concentração: Processos de Fabricação.

Orientador: Prof. Dr. Ing. Lirio Schaeffer

Coorientador: Prof. Dr. Roderval Marcelino

Banca Examinadora:

Dr. André Rosiak (UFRGS - RS)

Dr. Diego Pacheco Wermuth (UFRGS - RS)

Dr. Vilson Gruber (UFSC – SC)

Prof. Dr. Rodrigo de Lemos Peroni

Coordenador do PPGE3M

Esta tese foi julgada adequada para a obtenção do título de Doutor em Engenharia, área de concentração Processos de Fabricação, e aprovada em sua forma final pelo Orientador e pela banca Examinadora do curso de Pós-Graduação.

Orientador: Prof. Dr. Ing. Lirio Schaeffer

Coorientador: Prof. Dr. Roderval Marcelino

Banca Examinadora:

Dr. André Rosiak (UFRGS - RS)

Dr. Diego Pacheco Wermuth (UFRGS - RS)

Dr. Vilson Gruber (UFSC – SC)

Prof. Dr. Rodrigo de Lemos Peroni

Coordenador do PPGE3M

Diehl, Peterson Duarte
PREDIÇÃO DE DUREZA DE COMPONENTES FORJADOS A QUENTE BASEADA EM APRENDIZADO DE MÁQUINA / Peterson Duarte Diehl. -- 2026.
128 f.
Orientador: Lirio Schaeffer.

Coorientador: Roderval Marcelino.

Tese (Doutorado) -- Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais, Porto Alegre, BR-RS, 2026.

1. Indústria 4.0. 2. Forjamento. 3. Inteligência Artificial. 4. Propriedades Mecânicas. 5. Processamento Termomecânico. I. Schaeffer, Lirio, orient. II. Marcelino, Roderval, coorient. III. Título.

“No one was going to hand me my future. It was up to me to reach for my dream, grab it tight and make it come true.” (Coco, 2017)

AGRADECIMENTOS

Ao Brasil, por ainda oferecer excelente educação pública, federal e de acesso universal.

À UFRGS por ter me proporcionado excelentes cursos de graduação e pós-graduação.

Aos meus pais Jaime Nataniel e Vera Lúcia pelo dom da vida e pela educação que me deram.

À Emília, por todo apoio, força e amor em todos os momentos, principalmente por estar sempre presente nas situações difíceis, muito obrigado.

À família Hilgert, em especial João Eduardo (*in memoriam*), Gema e Eduarda por serem a família que eu precisava quando era tudo comigo, vocês são demais.

Aos amigos Fernando Bombassaro, Renan Richter, Rui Alles por terem compartilhado moradia quando precisei.

Aos meus colegas de trabalho e muitas outras pessoas suporte, apoio e parceria em todos os momentos.

Aos senhores Prof. Dr. Telmo Roberto Strohaecker (in memoriam), Prof. Dr. Antônio Shigueaki Takimi, Prof. Dr. Ing. Lirio Schaeffer, Dr. Eng. André Rosiak e Prof. Dr. Roderval Marcelino pelo apoio, orientação e estímulo para que eu nunca deixasse de estudar.

A todos os colegas do Centro Brasileiro de Inovação em Conformação Mecânica (CBCM) da Universidade Federal do Rio Grande do Sul.

SUMÁRIO

LISTA DE FIGURAS IX
LISTA DE TABELAS X
LISTA DE ABREVIATURAS XI
LISTA DE SÍMBOLOS XII
RESUMO XIII
ABSTRACT XIV
1 INTRODUÇÃO 1
2 REVISÃO BIBLIOGRÁFICA 4
2.1 Digitalização de processos industriais 4
2.2 Geração e organização de dados em ambientes industriais 7
2.3 Fundamentos de modelagem preditiva 9
2.4 Abordagens estatísticas e inteligentes para otimização de processos metalúrgicos 10
2.5 Inteligência artificial aplicada à metalurgia 12
2.5.1 Arquiteturas de RNA e topologias mais comuns 14
2.5.2 Técnicas de pré-processamento e seleção de atributos 16
2.5.3 Confiabilidade e generalização em ambientes industriais 20
2.6 Métodos comparativos de modelagem 22
2.6.1 Máquinas de Vetores de Suporte (SVM) na Modelagem de Propriedades Mecânicas 22
2.6.2 Floresta Aleatória (RF) e sua Aplicação na Metalurgia 25
2.6.3 Validação cruzada e métricas de desempenho 27
2.7 Aplicações em propriedades mecânicas 27
2.8 Desafios na Implementação Industrial 29
2.8.1 Integração com sistemas legados de forjaria 29
2.8.2 Escalabilidade e custo computacional 30
2.8.3 Considerações de segurança e manutenção 32
3 MATERIAIS E MÉTODOS 34
3.1 Contextualização do trabalho 34
3.2 Criação do banco de dados 35
3.2.1 Aço Hardox450® 36
3.2.2 Teste da Cunha 37
3.3 Determinação de parâmetros, coleta e preparação do banco de dados e pré-processamento 39
3.4 Avaliação de modelos lineares como etapa preliminar à modelagem com redes neurais 41

3.5 Modelagem com Redes Neurais Artificiais (RNA) 43
3.6 Modelagem com Máquina de Vetores de Suporte (SVM) 48
3.7 Modelagem com Floresta Aleatória (RF) 49
3.8 Testes de inferência 50
4 RESULTADOS EXPERIMENTAIS E DISCUSSÃO 52
4.1 Análise do banco de dados 52
4.2 Avaliação Preliminar com Modelos Lineares 55
4.3 Avaliação do Desempenho da Rede Neural Artificial (RNA) 57
4.4 Outras modelagens e abordagens 70
4.4.1 Modelagem com Máquinas de Vetores de Suporte (SVM) 71
4.4.2 Modelagem com Floresta Aleatória (RF) 72
4.5 Análise Comparativa dos Modelos Preditivos 73
4.6 Análise da correlação entre valores reais e previstos 76
4.7 Análise dos Testes de inferência 79
5 CONCLUSÕES 81
6 SUGESTÔES PARA TRABALHOS FUTUROS 84
REFERÊNCIAS BIBLIOGRÁFICAS 86
GLOSSÁRIO 90
ANEXO I – BANCO DE DADOS 94
ANEXO II – ALGORITMOS 108

LISTA DE FIGURAS

Figura 1 Tecnologias digitais adotadas pela Indústria 4.0 6
Figura 2 Camadas de neurônios artificiais em RNA. 17
Figura 3 Função de ativação em RNA. 17
Figura 4 Princípio fundamental do modelo Support Vector Machine (SVM). 24
Figura 5 Interpretação geométrica da função de decisão 24
Figura 6 Princípio de funcionamento de um modelo Random Forest aplicado a um problema de regressão. 26
Figura 7 Fluxograma detalhando o processo de seleção, organização de dados, treinamento e escolha da RNA. 35
Figura 8 Desenho esquemático do teste de forjabilidade de cunha. 38
Figura 9 Desenho esquemático do processo de forjamento. 38
Figura 10 Arquitetura da Rede Neural Artificial Densa proposta. 45
Figura 11 Processo de forjamento de uma biela para avaliação da capacidade preditiva dos modelos de IA. 50
Figura 12 Relação entre os parâmetros termomecânicos e os valores de dureza 53
Figura 13 Mapa de calor dos coeficientes de determinação (R^2)..... 54
Figura 14 Comparação dos valores de MSE entre as diferentes arquiteturas e funções de ativação. 59
Figura 15 Comparação dos valores de MAE entre as diferentes arquiteturas e funções de ativação. 59
Figura 16 Evolução dos Erros 256-128-64 (ReLU) 60
Figura 17 Evolução dos Erros 128-64-32 (ReLU). 60
Figura 18 Evolução dos Erros 64-64 (ReLU). 61
Figura 19 Tempo de treinamento. 61
Figura 20 Comparação dos coeficientes de determinação (R^2). 62
Figura 21 Comparação multivariada entre as arquiteturas 128-64-32, 256-128-64 e 64-64. 63
Figura 22 Comparação multivariada entre as arquiteturas 128-64-32, 256-128-64 e 64-64. 66
Figura 23 Histograma da distribuição dos erros, sobreposto a uma curva de densidade (KDE). 68
Figura 24 Comparação de resultados entre os modelos. 76
Figura 25 Comparação entre pares de valores reais e previstos para cada modelo. 77
Figura 26 Erro absoluto ao longo das amostras. 77
Figura 27 Erro absoluto ao longo das amostras – Boxplots..... 78
Figura 28 Erro absoluto ao longo das amostras - Violin plots..... 78
Figura 29 Erro absoluto ao longo das amostras – Heatmap. 79

LISTA DE TABELAS

Tabela 1 Resultados de pesquisa sobre o uso de tecnologias digitais no Brasil. (Valente, 2022) 5
Tabela 2 Comparativo entre Regressão Linear e Ferramentas de Inteligência Artificial 12
Tabela 3 Resumo dos algoritmos supervisionados de ML mais comuns. 13
Tabela 4 Composição química nominal do material de trabalho - % em peso (Certificado de Qualidade do Fabricante, 2024). 36
Tabela 5 Informações técnicas detalhadas do processo de forjamento das cunhas. 39
Tabela 6 Estatísticas do conjunto de dados utilizado para treinar os modelos. 40
Tabela 7 Ações Realizadas/Métodos e Ferramentas utilizados para treinar os modelos. 41
Tabela 8 Modelagem Preditiva com Algoritmos de Regressão Linear .. 43
Tabela 9 Modelagem Preditiva com Algoritmos de Redes Neurais Artificiais (RNA) 47
Tabela 10 Modelagem Preditiva com Algoritmos de Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF) 49
Tabela 11 Informações técnicas detalhadas do processo de forjamento das bielas. 51
Tabela 12 Coeficientes das Equações de Regressão 56
Tabela 13 Métricas de Desempenho dos Modelos Lineares 57
Tabela 14 Desempenho Comparativo das Arquiteturas de RNA 58
Tabela 15 Top 3 Arquiteturas por Desempenho 58
Tabela 16 Quantidade de valores encontrados por Grandeza de erro. . 70
Tabela 17 Comparativo do desempenho dos modelos desenvolvidos. . 75
Tabela 18 Resultados após teste de inferência. 80

LISTA DE ABREVIATURAS

ABDI - Agência Brasileira de Desenvolvimento Industrial

AISI − American Iron and Steel Institute

ANN - Artificial Neural Network

ASTM − American Society for Testing and Materials

CBCM - Centro Brasileiro de Inovação em Conformação Mecânica

CNI - Confederação Nacional da Indústria

EN − European Norm

HV − Dureza Vickers

IA - Inteligência Artificial

IBGE - Instituto Brasileiro de Geografia e Estatística

LVDT − Linear Variable Differential Transformer

MAE – Erro Absoluto Médio

ML - Machine Learning

MSE – Erro Quadrático Médio

MVS - Máquinas de Vetores de Suporte

PIB - Produto Interno Bruto

Q&T − Quench and Tempered

R^2 - Coeficiente de Determinação

ReLU - Rectified Linear Unit ou Unidade Linear Retificada

RF – Random Forests

RNA - Redes Neurais Artificiais

SAE − Society of Automotive Engineers International

SSAB − Svenskt Stål AB

SVM - Support Vector Machines

LISTA DE SÍMBOLOS

- Sequência numérica para amostras

$t-$ Tempo $[s]$

$t\gamma-$ Tempo de austenitização $[s]$

$T-$ Temperatura $[°C]$

$T\gamma-$ Temperatura de austenitização $[°C]$

$TR-$ Temperatura de recristalização $[°C]$

T_0- Temperatura inicial $[°C]$

$T0-$ Temperatura de encharque $[°C]$

$Tamb-$ Temperatura ambiente $[°C]$

$Tf-$ Temperatura final de forjamento $[°C]$

Símbolos Gregos

ε – Deformação relativa [%]

$\Delta h-$ Redução em altura [%]

μ – Coeficiente de atrito [−]

$\sigma-$ Tensão de engenharia $[MPa]$

$\varphi-$ Deformação verdadeira [−]

$\dot{\varphi}-$ Velocidade de Deformação [−]

$\varphi p-$ Deformação de pico na curva de escoamento [−]

RESUMO

A Indústria 4.0 tem impulsionado a modernização dos setores industriais por meio da integração de tecnologias digitais, com foco na otimização de processos e na redução de custos operacionais. No Brasil, a indústria de transformação mecânica enfrenta desafios relacionados à competitividade e ao atraso tecnológico, o que motiva a adoção de soluções baseadas em inteligência artificial. Este estudo investiga a aplicação de técnicas de aprendizado de máquina para a predição da dureza em aço Hardox 450® submetidas a processos termomecânicos, como o forjamento a quente. Inicialmente, o problema foi tratado como um caso potencialmente solucionável por regressão linear multivariada. No entanto, os resultados apresentaram baixo desempenho preditivo e incapacidade de capturar a relação não linear entre as variáveis do processo e a dureza resultante, indicando que modelos paramétricos tradicionais não eram suficientes. Diante disso, optou-se pela utilização de métodos mais avançados de aprendizado de máquina. Foram avaliados três algoritmos: redes neurais artificiais (RNA), máquinas de vetores de suporte (SVM) e floresta aleatória (RF), utilizando como variáveis de entrada a deformação, a velocidade de deformação, a temperatura inicial e a temperatura final. O banco de dados experimental, composto por 2960 registros, foi dividido em 70% para treinamento e 30% para validação. Os modelos foram comparados com base no coeficiente de determinação (R^2), erro absoluto médio (MAE) e erro quadrático médio (MSE). Dentre os algoritmos avaliados, o modelo de Redes Neurais Artificiais (RNA), configurado com arquitetura 256-128-64 e função de ativação ReLU, demonstrou o desempenho superior, alcançando $R^2 = 0,992$, MAE = 1,93 HV e MSE = 13,68 HV^2, demonstrando excelente capacidade preditiva e consistência na estimativa dos valores de dureza. Os resultados indicam que ferramentas de aprendizado de máquina podem contribuir significativamente para a eficiência de processos industriais, reduzindo a dependência de ensaios físicos custosos e demorados, além de oferecer maior confiabilidade na tomada de decisão técnica.

Palavras-chave: Indústria 4.0, Inteligência Artificial, Forjamento, Propriedades Mecânicas, Processamento Termomecânico.

ABSTRACT

Industry 4.0 has been driving the modernization of industrial sectors through the integration of digital technologies, focusing on process optimization and cost reduction. In Brazil, the mechanical transformation industry faces challenges related to competitiveness and technological obsolescence, encouraging the adoption of artificial intelligence-based solutions. This study investigates the application of machine learning techniques for predicting the hardness of Hardox 450® steel subjected to thermomechanical processes such as hot forging. Initially, the problem was approached as one potentially solvable through multivariate linear regression. However, the results showed low predictive performance and an inability to capture the nonlinear relationship between process variables and the resulting hardness, indicating that traditional parametric models were insufficient. Therefore, more advanced machine learning methods were adopted. Three algorithms were evaluated: artificial neural networks (ANN), support vector machines (SVM), and random forest (RF), using deformation, strain rate, initial temperature, and final temperature as input variables. The experimental dataset, consisting of 2,960 data, was divided into 70% for training and 30% for validation. Model performance was assessed using the coefficient of determination (R^2), mean absolute error (MAE), and mean squared error (MSE). The ANN model designed with 256-128-64 architecture employing the ReLU activation function, achieved the best results (R^2 = 0.992, MAE = 1.93 HV e MSE = 13.68 HV^2), demonstrating superior predictive capability. The findings indicate that machine learning tools can significantly enhance industrial process efficiency by reducing the need for costly and time-consuming experimental testing.

Keywords: Industry 4.0; Artificial Intelligence; Forging; Mechanical Properties; Thermomechanical Processing.

1 INTRODUÇÃO

Em 2019, o Instituto Brasileiro de Geografia e Estatística (IBGE) apontou que a participação da indústria brasileira no Produto Interno Bruto (PIB) sofreu uma redução significativa, passando de aproximadamente 20% na década de 1980 para cerca de 11%. A Agência Brasileira de Desenvolvimento Industrial (ABDI) destaca que a reindustrialização tecnológica é um fator essencial para a retomada do crescimento do setor industrial, enfatizando que a digitalização de processos contribui para o aumento da produtividade, a redução de custos e o fortalecimento dos ecossistemas produtivos, com impactos positivos na economia local.

A Confederação Nacional da Indústria (CNI), em relatório publicado em 2018, indica que, mantidas as condições atuais, o Brasil poderá levar mais de meio século para alcançar níveis de PIB comparáveis aos de países desenvolvidos. Contudo, o mesmo estudo aponta que existem caminhos viáveis para o aumento da competitividade industrial, especialmente por meio da inovação, da inserção em cadeias globais de valor e da adoção de práticas sustentáveis. Nesse cenário, o fortalecimento da Indústria 4.0, com a incorporação de tecnologias digitais avançadas, é apresentado como um elemento central para o aumento da produtividade e, consequentemente, para o crescimento econômico do país.

Tecnologias como Internet das Coisas (IoT), computação em nuvem, Inteligência Artificial e gêmeos digitais (*digital twins*) apresentam elevado potencial de aplicação industrial, ainda pouco explorado no contexto brasileiro. Nesse ambiente, a modelagem preditiva em processos industriais emerge como uma estratégia relevante para antecipar o comportamento de variáveis críticas, tais como propriedades mecânicas, desempenho de processos e ocorrência de falhas operacionais. Essa modelagem pode ser conduzida por abordagens estatísticas tradicionais, como a regressão linear, ou por técnicas mais avançadas de inteligência artificial. A escolha da abordagem mais adequada depende de diversos fatores, como a natureza do fenômeno analisado, a disponibilidade e a qualidade dos dados, os requisitos de interpretabilidade e os recursos computacionais disponíveis.

Ao permitir a previsão de estados futuros, essas técnicas viabilizam a otimização de processos produtivos e a redução de perdas. No âmbito da manufatura, a predição de propriedades mecânicas de produtos configura-se como um campo de grande interesse. Em particular, no forjamento a quente, o processamento termomecânico exerce papel decisivo na definição das propriedades finais das ligas metálicas. A dureza, uma das propriedades mais relevantes nesses materiais, é fortemente influenciada por variáveis como a deformação imposta, a velocidade de deformação e as temperaturas de aquecimento e resfriamento. Tradicionalmente, as relações entre esses parâmetros de processo e as propriedades mecânicas têm sido investigadas por meio de ensaios experimentais e modelagens empíricas, abordagens que demandam elevado tempo e consumo de recursos (SCHMIDHUBER, 2015). Esses modelos baseiam-se, em geral, em equações derivadas da metalurgia física para correlacionar variáveis como temperatura e velocidade de deformação às propriedades mecânicas finais (CALLISTER; RETHWISCH, 2014).

Tais metodologias apresentam limitações significativas quando aplicadas a processos termomecânicos complexos. A variabilidade inerente aos materiais e as interações não lineares entre os parâmetros de processo dificultam a obtenção de previsões precisas e robustas (DAVIM, 2011). O uso de modelos de inteligência artificial em processos historicamente controlados com base na experiência prática pode gerar avanços significativos, promovendo ganhos em eficiência operacional, maior precisão no ajuste de parâmetros de processo e melhoria da qualidade dos produtos finais.

Nesse contexto, este trabalho propõe o desenvolvimento e a comparação de modelos baseados em três abordagens de inteligência artificial — redes neurais artificiais, máquinas de vetores de suporte e floresta aleatória — para a predição da dureza de ligas metálicas a partir de dados experimentais obtidos em ensaios de forjamento. O desempenho dos modelos é avaliado por meio de métricas estatísticas, e os resultados são analisados com o objetivo de verificar a viabilidade dessas técnicas como ferramentas de apoio à otimização de processos industriais.

Este trabalho tem como objetivo geral:

Investigar e comparar o desempenho de técnicas de Inteligência Artificial (RNA, SVM e Random Forest) na predição da dureza em aço Hardox450®, visando ampliar a eficiência de forjarias e reduzir custos de ensaio.

E como objetivos específicos:

1. Levantar, na literatura, métodos tradicionais e avanços em IA aplicados à metalurgia.
2. Descrever o protocolo experimental de forjamento e coleta de dados.
3. Implementar e parametrizar modelos de RNA, SVM e Random Forest.
4. Avaliar comparativamente acurácia, robustez e tempo de treinamento de cada método.
5. Discutir as implicações práticas dos resultados para o setor industrial.

A contribuição original deste trabalho reside na modelagem preditiva da dureza do aço Hardox450® utilizando dados de um processo de forjamento a quente. Embora a aplicação de IA na metalurgia seja crescente, este estudo se diferencia pela comparação sistemática de três algoritmos (RNA, SVM e RF) com um banco de dados experimental substancial (2960 registros), focado em um material de alta resistência e complexidade microestrutural. O desenvolvimento de um modelo robusto oferece uma alternativa direta e de baixo custo aos ensaios mecânicos convencionais, permitindo a otimização de parâmetros de processo em tempo real e contribuindo para o avanço da manufatura digital no setor de conformação mecânica.

2 REVISÃO BIBLIOGRÁFICA

A aplicação de ferramentas de Inteligência Artificial (IA) nos processos de conformação de metais tem revolucionado a indústria como um todo e esse trabalho irá buscar contextualizar como está a situação na indústria metalúrgica, onde algumas das vantagens proporcionadas são os avanços significativos em eficiência, qualidade e inovação. Esta revisão detalhada explora as diversas aplicações das RNAs que são um subconjunto da IA no forjamento a quente, destacando os principais métodos, benefícios, desafios e tendências futuras.

2.1 Digitalização de processos industriais

A conformação de metais é um processo fundamental na fabricação de componentes metálicos, envolvendo operações como estampagem, extrusão, laminação e forjamento. Tradicionalmente, esses processos dependem de métodos empíricos e simulações numéricas para otimização. Com o advento da IA, novas oportunidades surgiram para aprimorar o controle de processos, prever falhas e otimizar parâmetros de produção.

Segundo dados de 2019 do Instituto Brasileiro de Geografia e Estatística (IBGE) e de 2023 da Confederação Nacional da Indústria (CNI) mostram que a participação da Indústria Brasileira no Produto Interno Bruto (PIB) caiu de 20%, nos anos 1980, para 11% (Esfera Brasil, 2023). Igor Calvet, Presidente da Agência Brasileira de Desenvolvimento Industrial (ABDI) em entrevista publicada em 30 de maio de 2023 para Esfera Brasil (2023) diz que a reindustrialização tecnológica será fundamental para o setor Industrial voltar a crescer. Calvet também cita que a digitalização de processos aumenta a produtividade, reduz custos e melhoram os ecossistemas que impactam a economia local.

Em 2018 a CNI trouxe um relatório que estima que o Brasil levará mais de meio século para alcançar o PIB de países desenvolvidos, entretanto traz como alternativas para o aumento da competitividade, inovação, globalização e sustentabilidade ações que consolidem o desenvolvimento da Industria 4.0 com

a inserção de tecnologias digitais que serão essenciais para o aumento da produtividade e consequente crescimento do país.

A empresa de consultoria PwC (2016) diz que a digitização ou digitalização está entre uma das tecnologias que já vinha mudando a forma como competem e interagem as indústrias. Citam que enquanto as outras revoluções industriais foram catalisadores para o aumento da demanda por muitos recursos, esta no entanto busca e gira em torno da redução da demanda por recursos. Pesquisas do World Economic Forum (2015) estimam que, a partir de diversas respostas coletadas, pelo menos 80% das atividades do nosso dia a dia estarão de alguma forma conectada à internet, digitalizada ou sendo realizada de forma autônoma até 2025.

Em Valente (2022) traz que a partir de pesquisa realizada pela CNI, 7 em cada 10 empresas no Brasil já utilizam algum tipo de tecnologia totalmente digital e mostra que em pesquisa realizada apenas 5 anos antes este número não chegava a 5. Entretanto, mesmo com um aumento expressivo no uso de tecnologias digitais, o estudo também mostra que majoritariamente se utilizam tecnologias em fases iniciais. A Tabela 1 mostra o número de tecnologias digitais e o percentual de empresas que as utilizam.

Tabela 1 Resultados de pesquisa sobre o uso de tecnologias digitais no Brasil. (Valente, 2022)

Quantidade de tecnologias digitais	Empresas entrevistadas
1 a 3	26%
4 a 6	22%
7 a 9	14%
Mais de 10	7%

Na Figura 1 a CNI (2018) cita algumas das tecnologias de digitalização que estão sendo adotadas pela indústria 4.0. HAWRYLUK e MRZYGŁÓD (2017) em artigo que traz à tona o uso de diversas tecnologias como: Inteligência Artificial, *Big Data*, Sistemas de Simulação, entre outras, mostram que as atuais tecnologias proporcionam novos métodos e abordagens que tornam possíveis o uso de experimentos virtuais reduzindo custos fabris e de materiais para

validação de melhorias. No trabalho de Katayama et al. (2004) foi desenvolvido um sistema que determinava parâmetros de processo para forjamento a frio.



Figura 1 Tecnologias digitais adotadas pela Indústria 4.0 (CNI,2017)

Valente (2022) mostra que em 2021 o número de Indústrias que responderam que utilizam algum tipo de “Coleta, processamento e análise de grandes quantidades de dados (*big data*) no processo produtivo” passou para 21% e para “Aplicações de inteligência artificial para soluções na fábrica” foi para 9%, para ambas as perguntas na pesquisa realizada no ano de 2016 não foi registrada nenhuma resposta. Isso mostra o quanto há de oportunidades a serem exploradas na trilha da digitalização industrial.

No artigo publicado pela CNI (2018, p17) é dito que:

> A combinação do *Big Data* com o emprego da Inteligência Artificial propicia a manutenção preditiva das máquinas e dos equipamentos e assegura maior precisão nos procedimentos, eficiência no uso de insumos e maior qualidade nos serviços executados. O emprego dessas tecnologias pode desenvolver ambientes interativos autônomos, isto é, sem a intervenção humana.

2.2 Geração e organização de dados em ambientes industriais

A digitalização dos processos industriais tem promovido uma crescente disponibilidade de dados provenientes de sensores, sistemas de controle, bancos de dados e plataformas de Internet das Coisas (IoT). No entanto, a simples coleta de dados não é suficiente para garantir sua aplicabilidade em modelos preditivos. A geração de dados em ambientes industriais envolve múltiplas fontes heterogêneas, como sistemas SCADA, controladores lógicos programáveis (PLCs), sensores embarcados e registros manuais, o que exige uma abordagem sistemática para garantir a qualidade, consistência e integridade das informações.

Os sistemas SCADA (Supervisory Control and Data Acquisition) são plataformas computacionais utilizadas para supervisão e controle de processos industriais em tempo real. Eles permitem a aquisição contínua de dados de campo, o monitoramento de variáveis críticas e a emissão de comandos de controle. Esses sistemas são fundamentais para a coleta estruturada de dados operacionais, pois integram sensores, atuadores e controladores em uma interface centralizada, geralmente com capacidade de armazenamento histórico e exportação de dados para análise posterior (Boyer, 2009).

Já os PLCs (Programmable Logic Controllers) são dispositivos eletrônicos robustos, projetados para executar lógicas de controle em ambientes industriais. Eles operam em tempo real, recebendo sinais de entrada de sensores e enviando sinais de saída para atuadores, com base em programas lógicos definidos pelo usuário. Os PLCs são amplamente utilizados em linhas de produção, fornos, prensas e outros equipamentos metalúrgicos, sendo uma das principais fontes de dados operacionais (Petruzella, 2016).

A Internet das Coisas (do inglês *Internet of Things* IoT), por sua vez, representa uma evolução significativa na conectividade de dispositivos industriais. Trata-se de uma rede de objetos físicos equipados com sensores, software e outras tecnologias que permitem a coleta e troca de dados com outros dispositivos e sistemas pela internet. Em ambientes industriais, a IoT permite o monitoramento contínuo de variáveis como temperatura, pressão, vibração e

consumo energético, viabilizando a tomada de decisão em tempo real e a implementação de estratégias preditivas (Lee, Bagheri & Kao, 2015). A IoT também facilita a integração entre o chão de fábrica e os sistemas corporativos, promovendo uma visão holística do processo produtivo.

Tao et al. (2018) destacam que a fragmentação dos dados entre os mundos físico e digital representa uma das principais barreiras para a construção de sistemas inteligentes e eficientes. A proposta de gêmeos digitais (*digital twins*) surge como uma solução para integrar dados de diferentes domínios, promovendo uma representação virtual contínua e sincronizada dos ativos físicos. Essa integração é essencial para alimentar modelos de inteligência artificial com dados confiáveis e representativos.

A organização dos dados requer etapas rigorosas de aquisição, limpeza, transformação e armazenamento. A aquisição envolve a coleta contínua de dados em tempo real, enquanto a limpeza trata da remoção de ruídos, preenchimento de lacunas e padronização de formatos. A transformação dos dados, por sua vez, visa torná-los compatíveis com os algoritmos de modelagem, o que inclui normalização, codificação e seleção de atributos relevantes. O armazenamento eficiente, utilizando bancos de dados relacionais ou estruturas distribuídas como *data lakes*, garante a escalabilidade e a acessibilidade dos dados ao longo do tempo.

Xu, He e Li (2014) argumentam que a interoperabilidade entre sistemas legados e plataformas modernas é um desafio recorrente, sendo necessário o uso de arquiteturas orientadas a serviços e protocolos padronizados, como OPC-UA, para garantir a integração fluida entre diferentes camadas da automação industrial. Além disso, a governança dos dados, incluindo controle de acesso, versionamento e rastreabilidade, é fundamental para assegurar a confiabilidade e a auditabilidade dos modelos desenvolvidos.

Portanto, a geração e organização de dados em ambientes industriais não é apenas uma etapa preparatória, mas um componente estratégico para o sucesso de qualquer iniciativa baseada em inteligência artificial ou aprendizado de máquina.

2.3 Fundamentos de modelagem preditiva

A modelagem preditiva em ambientes industriais representa uma das principais estratégias para antecipar o comportamento de variáveis críticas, como propriedades mecânicas, desempenho de processos e falhas operacionais. Essa modelagem pode ser realizada por meio de abordagens estatísticas tradicionais, como a regressão linear, ou por técnicas mais avançadas de inteligência artificial, como redes neurais artificiais, máquinas de vetores de suporte e algoritmos de ensemble. A escolha entre essas abordagens depende de múltiplos fatores, incluindo a natureza do fenômeno a ser modelado, a disponibilidade e qualidade dos dados, a necessidade de interpretabilidade e os recursos computacionais disponíveis.

A regressão linear, conforme discutido por Harrell (2015), continua sendo uma ferramenta robusta e amplamente utilizada para modelar relações entre variáveis quantitativas. Sua principal vantagem reside na simplicidade e na interpretabilidade dos coeficientes, o que permite uma compreensão direta da influência de cada variável independente sobre a variável resposta. Em contextos industriais onde há uma fundamentação física clara e relações aproximadamente lineares, a regressão linear pode oferecer resultados satisfatórios com baixo custo computacional.

Entretanto, em sistemas complexos e não lineares, como os encontrados em processos metalúrgicos, a regressão linear pode apresentar limitações significativas. A presença de interações entre variáveis, efeitos de saturação, ruídos e não linearidades estruturais exige modelos mais flexíveis e adaptativos. Nesse contexto, técnicas de aprendizado de máquina têm se destacado por sua capacidade de capturar padrões complexos e generalizar a partir de grandes volumes de dados. Segundo Sarker (2021), algoritmos como redes neurais profundas, florestas aleatórias e máquinas de vetores de suporte têm demonstrado desempenho superior em tarefas como previsão de dureza, resistência mecânica e falhas em equipamentos.

A escolha do modelo preditivo deve considerar não apenas o desempenho estatístico, mas também aspectos como interpretabilidade,

robustez, escalabilidade e facilidade de integração com os sistemas industriais existentes. Modelos baseados em inteligência artificial, embora mais precisos em muitos casos, tendem a ser menos transparentes e mais exigentes em termos de dados e processamento. Por outro lado, modelos estatísticos tradicionais oferecem maior controle e explicabilidade, o que pode ser decisivo em ambientes regulados ou com baixa maturidade digital.

Além disso, a avaliação dos modelos deve ser conduzida com rigor metodológico, utilizando técnicas como validação cruzada, análise de resíduos e métricas de desempenho como erro quadrático médio (MSE), erro absoluto médio (MAE) e coeficiente de determinação (R^2). A combinação de diferentes abordagens, por meio de modelos híbridos ou comitês de especialistas, também tem se mostrado promissora para equilibrar precisão e interpretabilidade em aplicações industriais.

Em síntese, a modelagem preditiva em ambientes industriais exige uma abordagem criteriosa e contextualizada, que considere tanto os aspectos técnicos dos algoritmos quanto as restrições operacionais e organizacionais do ambiente onde serão aplicados.

2.4 Abordagens estatísticas e inteligentes para otimização de processos metalúrgicos

A escolha entre métodos estatísticos tradicionais e técnicas de inteligência artificial (IA) é uma decisão crítica na modelagem e otimização de processos metalúrgicos. Entre as abordagens estatísticas, a regressão linear é uma das mais utilizadas devido à sua simplicidade e interpretabilidade. Trata-se de uma técnica que busca modelar a relação entre uma variável dependente e uma ou mais variáveis independentes, assumindo que essa relação seja linear. Essa abordagem é particularmente eficaz quando os dados apresentam baixa variabilidade, as relações entre variáveis são bem compreendidas e o objetivo principal é a explicação causal ou a análise exploratória. Em contextos metalúrgicos, a regressão linear pode ser aplicada, por exemplo, para prever a

dureza de um aço em função da composição química e da taxa de resfriamento, desde que essas variáveis se relacionem de forma aproximadamente linear.

Por outro lado, quando os processos envolvem múltiplas variáveis interdependentes, relações não lineares, dados ruidosos ou incompletos, as técnicas de IA se tornam mais apropriadas. Modelos como redes neurais artificiais, árvores de decisão e arquiteturas híbridas são capazes de capturar padrões complexos e realizar previsões com alta acurácia, mesmo em cenários onde os métodos estatísticos tradicionais falham. A IA é especialmente útil quando o volume de dados é elevado e o objetivo é a previsão precisa, mesmo que isso implique em menor interpretabilidade dos modelos. Um exemplo típico é a previsão da evolução microestrutural durante tratamentos térmicos, onde múltiplos parâmetros interagem de forma não trivial e a resposta do material depende de condições operacionais dinâmicas, a Tabela 2 traz um comparativo entre Regressão Linear e Ferramentas de Inteligência Artificial.

A decisão entre utilizar regressão linear ou IA deve considerar diversos fatores, como a natureza do problema, a qualidade e quantidade dos dados disponíveis, a necessidade de interpretabilidade e os recursos computacionais. Em muitos casos, a melhor abordagem é híbrida, combinando o melhor dos dois mundos. Por exemplo, pode-se utilizar regressão linear para uma análise preliminar e seleção de variáveis, e posteriormente aplicar redes neurais para refinar a previsão. Além disso, modelos guiados por física, como os propostos por Wang et al. (2020), demonstram que é possível incorporar conhecimento físico diretamente na estrutura de redes neurais, aumentando a robustez e a consistência das previsões, especialmente em ambientes industriais onde os dados são escassos ou as condições operacionais variam significativamente.

Tabela 2 Comparativo entre Regressão Linear e Ferramentas de Inteligência Artificial

Critério	Regressão Linear	Inteligência Artificial
Relação entre variáveis	Linear	Não linear
Volume de dados necessário	Pequeno a moderado	Grande
Robustez a ruído e outliers	Baixa	Alta
Interpretabilidade	Alta	Baixa a média
Facilidade de implementação	Alta	Média a baixa
Exigência computacional	Baixa	Alta
Aplicações típicas	Modelos explicativos, análise causal	Previsão, controle de processo, otimização em tempo real
Adaptação a novas condições	Limitada	Alta

Em resumo, a escolha da ferramenta analítica mais adequada depende do equilíbrio entre simplicidade, precisão e aplicabilidade. A regressão linear continua sendo uma ferramenta valiosa em muitos contextos, mas a crescente complexidade dos processos metalúrgicos e a disponibilidade de dados tornam a IA uma aliada poderosa na busca por soluções mais eficientes e inteligentes.

2.5 Inteligência artificial aplicada à metalurgia

A Inteligência Artificial (IA) refere-se a programas computacionais que automatizam tarefas associadas ao pensamento humano, como percepção, resolução de problemas e planejamento (Cao et al., 2024). Desde sua primeira aplicação em 1952, um programa de damas, a IA transformou diversos setores, especialmente no processamento de linguagem natural, visão computacional e sistemas de recomendação. Esses avanços devem-se em grande parte ao progresso significativo no Aprendizado de Máquina (ML), um subcampo da IA no qual os programas aprendem diretamente a partir de dados, diferentemente de sistemas baseados em regras pré-definidas (Cao et al., 2024). Os métodos de ML são comumente classificados em três categorias conforme o tipo de dado processado: aprendizado supervisionado (dados rotulados), não supervisionado (dados não rotulados) e por reforço (dados interativos). No entanto, técnicas como aprendizado semissupervisionado, autossupervisionado e contrastivo, além do uso de métodos supervisionados em problemas de reforço, tornaram essas fronteiras menos definidas (Cao et al., 2024). Para ilustrar, a Tabela 3

resume três algoritmos supervisionados típicos, destacando suas características e aplicações.

Tabela 3 Resumo dos algoritmos supervisionados de ML mais comuns.

	Modelos Lineares	**Métodos Baseados em Árvores**	**Redes Neurais Artificiais (RNA)**
Algoritmos	Regressão Linear, Regressão Logística, SVM	Árvore de Decisão, Random Forest, CART	FCNN, CNN, RNN, GNN
Tipos de Dados de Entrada	Numéricos, Categóricos	Numéricos, Categóricos	Numéricos, Imagens, Texto, Áudio, Vídeo
Quantidade de Dados Necessária	Moderada	Moderada	Grande
Velocidade de Treinamento	Moderada	Moderada	Lenta
Explicabilidade	Interpretável (com Kernel Linear)	Baixa a Moderada	Complexa
Aplicações Típicas	Classificação, Regressão	Classificação, Regressão	Reconhecimento de Imagens, NLP, Previsão de Séries Temporais, Análise de Sentimento, Reconhecimento de Fala, etc.

A aplicação de técnicas de inteligência artificial (IA) na metalurgia tem permitido avanços significativos na previsão de propriedades mecânicas e na otimização de processos. RNAs, por exemplo, têm sido amplamente utilizadas para modelar relações não lineares entre variáveis de processo e propriedades finais dos materiais (SCHMIDHUBER, 2015). Estudos mostram que RNAs são capazes de superar as limitações de modelos empíricos ao aprender padrões diretamente de dados experimentais (CHOLLET, 2017). Em aplicações metalúrgicas, têm sido utilizadas para prever dureza, resistência à tração, e evolução microestrutural com elevada precisão (ZHANG et al., 2019). A flexibilidade das RNAs, aliada à sua capacidade de operar com conjuntos de dados incompletos ou ruidosos, as torna ideais para aplicações industriais em tempo real. Com a evolução das redes convolucionais e do aprendizado profundo, as possibilidades de aplicação da IA na metalurgia continuam a se expandir, incluindo a integração com sistemas de visão computacional e simulações multiescala (LI et al., 2022).

2.5.1 Arquiteturas de RNA e topologias mais comuns

A utilização de RNAs na indústria metalúrgica já demonstrou resultados promissores em diversas frentes, especialmente na previsão de propriedades mecânicas em componentes forjados. Gorni e Silva (2009) aplicaram RNAs na previsão de propriedades de bobinas laminadas a quente, demonstrando que a composição química é uma variável crítica para a dureza. Schmeling (2024) mostrou que RNAs são eficazes na modelagem do comportamento de escoamento em ligas metálicas, com resultados mais precisos que os obtidos com métodos empíricos. Chen et al. (2021) desenvolveram uma arquitetura híbrida (CNN-LSTM) que permitiu prever simultaneamente a dureza e a estrutura de grão de ligas de titânio com elevado grau de acurácia. Tais aplicações mostram o potencial das RNAs na automação de processos industriais e no desenvolvimento de sistemas inteligentes de controle de qualidade. Em resumo, a capacidade de adaptação e previsão das RNAs representa uma alternativa robusta e eficiente frente às abordagens tradicionais na engenharia de materiais.

A abordagem híbrida de combinar dados reais com ferramentas digitais também foi explorada por Wang et al. (2020), que desenvolveram uma rede neural guiada por física para a previsão de desgaste de ferramentas no contexto do forjamento. O modelo proposto por Wang et al. foi concebido para superar as limitações inerentes aos modelos puramente baseados em dados, que, embora eficientes em muitos cenários, enfrentam desafios significativos em situações em que os dados de treinamento são escassos ou onde as condições operacionais variam de maneira imprevisível. Ao integrar diretamente princípios físicos que regem os mecanismos de desgaste, como o desgaste por atrito, adesão e abrasão, a rede neural foi capaz de fornecer previsões mais precisas e robustas, independentemente das mudanças nas condições de operação.

Uma das inovações-chave do modelo foi a fusão entre dados empíricos e informações físicas durante o treinamento e a previsão. Enquanto as redes neurais convencionais tendem a aprender padrões diretamente dos dados, a rede proposta por Wang et al. (2020) foi estruturada de modo que princípios físicos conhecidos fossem incorporados como restrições dentro do processo de aprendizado. Isso permitiu que o modelo evitasse previsões fisicamente

inconsistentes, algo comum em abordagens baseadas exclusivamente em dados. Um dos desafios enfrentados pelos autores foi garantir que o modelo fosse capaz de capturar tanto os aspectos determinísticos do processo, representados pelas leis físicas, quanto os componentes estocásticos, frequentemente observados no desgaste de ferramentas, que são influenciados por fatores aleatórios, como microvariações no material da ferramenta ou flutuações na temperatura de operação.

Além disso, o modelo foi desenvolvido para ser adaptável a diferentes cenários de operação. Isso é particularmente importante em forjamento, onde as condições podem variar amplamente entre lotes de produção, resultando em padrões de desgaste que não seguem um comportamento linear previsível. A capacidade de integrar esses fatores físicos e dinâmicos diretamente no processo de previsão fez com que a rede neural fosse capaz de ajustar-se a essas variações de forma eficaz, fornecendo previsões mais consistentes.

Os resultados experimentais apresentados por Wang et al. (2020) mostraram que a rede neural guiada por física não apenas forneceu previsões mais precisas, mas também demonstrou maior robustez em comparação com as redes neurais convencionais e outros métodos puramente baseados em dados. Ao comparar a média do erro absoluto (MAE) e o erro percentual absoluto médio (MAPE) de seu modelo com modelos tradicionais, os autores encontraram uma redução significativa nos erros de previsão, especialmente em condições operacionais extremas ou de alta variabilidade. Um dos cenários testados foi o desgaste de ferramentas sob diferentes cargas e variações na temperatura de forjamento, onde o modelo de Wang et al. foi capaz de manter a precisão, enquanto modelos baseados unicamente em dados apresentaram erros crescentes à medida que as condições de operação divergiam dos dados de treinamento. Além disso, o modelo proposto foi capaz de aprender com dados limitados de desgaste, algo que é uma limitação comum em ambientes industriais onde a coleta de dados é frequentemente cara ou difícil de ser realizada de forma contínua. Ao incorporar princípios físicos diretamente na estrutura da rede neural, o modelo foi capaz de prever padrões de desgaste com precisão, mesmo em cenários onde os dados disponíveis eram insuficientes para treinar uma rede neural convencional. Essa capacidade de generalização foi

considerada uma das maiores vantagens da abordagem híbrida, uma vez que permitiu ao modelo realizar previsões robustas mesmo com dados limitados ou quando as condições operacionais mudavam drasticamente. A conclusão do estudo de Wang et al. foi que a integração de conhecimento físico nas redes neurais pode fornecer uma solução viável para a previsão de desgaste em processos de forjamento, especialmente em situações em que a coleta de grandes volumes de dados não é prática ou onde as condições operacionais variam constantemente. O modelo guiado por física demonstrou que a abordagem híbrida pode não apenas melhorar a precisão das previsões, mas também garantir consistência e robustez, proporcionando uma ferramenta poderosa para a otimização do ciclo de vida de ferramentas em ambientes industriais (Wang et al., 2020).

2.5.2 Técnicas de pré-processamento e seleção de atributos

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, compostos por camadas de neurônios artificiais ou nós interconectados conforme Figura 2. Essas camadas incluem:

- Camada de entrada, responsável por receber os atributos do problema;
- Camadas ocultas, onde ocorre o processamento e extração de padrões complexos;
- Camada de saída, que fornece a previsão ou classificação desejada.

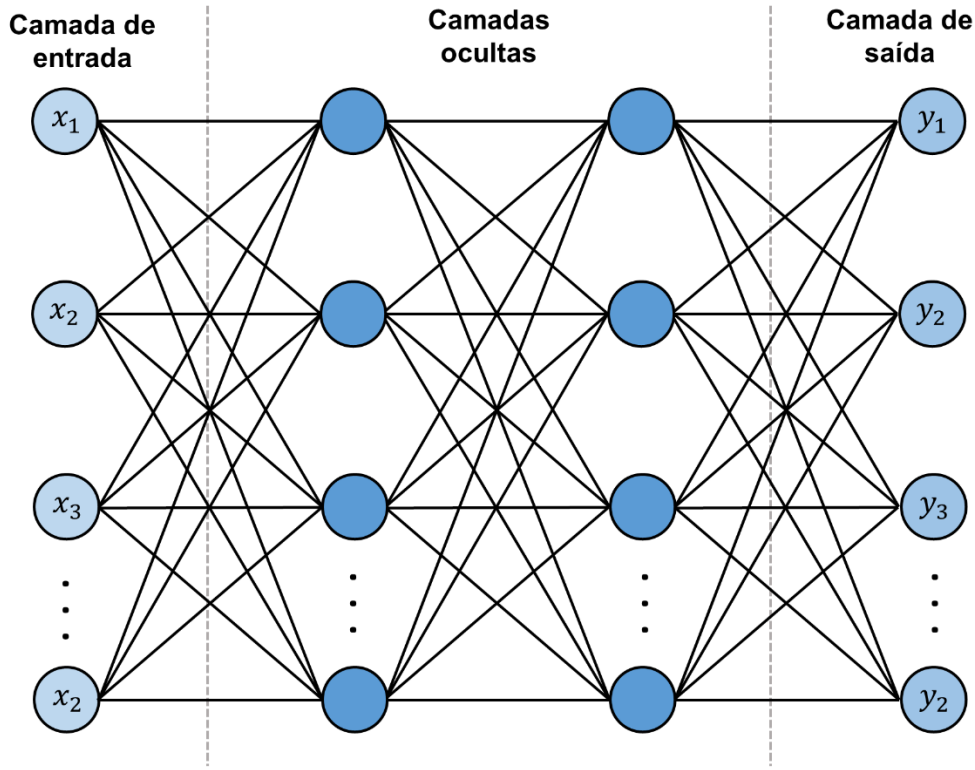


Figura 2 Camadas de neurônios artificiais em RNA.

Cada neurônio aplica uma função de ativação, detalhado na Figura 3 como ReLU, Sigmoid ou Tanh sobre a soma ponderada das entradas. A definição da arquitetura da rede — número de camadas ocultas, quantidade de neurônios por camada e funções de ativação — é um dos principais hiperparâmetros do modelo.

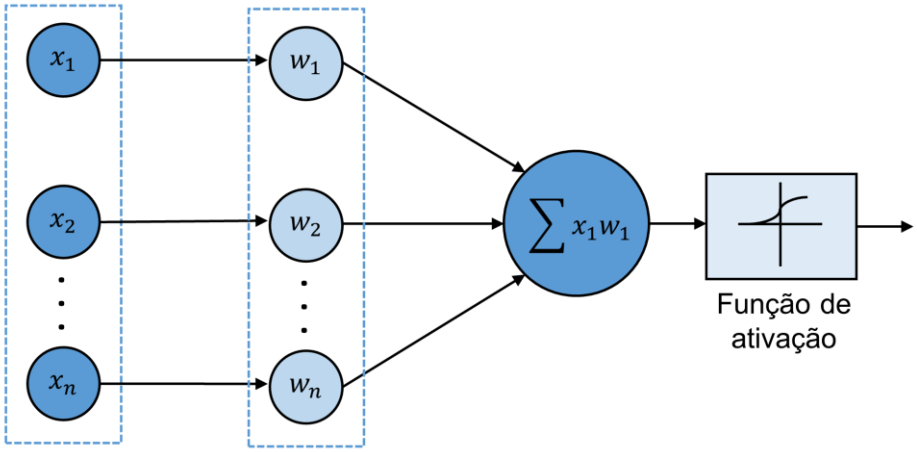


Figura 3 Função de ativação em RNA.

Outros hiperparâmetros relevantes incluem:

- Taxa de aprendizado;
- Número de épocas;
- Otimizador (Adam, SGD);
- Regularização (L2, dropout);
- Critérios de parada (early stopping).

A construção de modelos eficazes de RNAs para prever dureza em componentes forjados a quente exige rigor metodológico desde a coleta de dados até a validação dos modelos. Inicialmente, os dados devem ser cuidadosamente normalizados ou padronizados para evitar viés numérico durante o treinamento (HUANG et al., 2018). Também é essencial tratar valores faltantes e aplicar codificação adequada para variáveis categóricas. Em casos com grande número de variáveis, técnicas de redução de dimensionalidade, como PCA ou autoencoders, podem ser aplicadas.

A seleção de atributos é outro passo crítico, pois reduz ruído e melhora a capacidade de generalização. Métodos estatísticos (correlação, ANOVA), baseados em modelos (Random Forest, Gradient Boosting) ou técnicas como Recursive Feature Elimination (RFE) e regularização L1 (Lasso) são amplamente utilizados para identificar as variáveis mais relevantes. Zhang et al. (2019) mostraram que redes com três camadas ocultas e funções de ativação do tipo ReLU alcançam melhor desempenho em aplicações metalúrgicas. O uso de técnicas como validação cruzada e regularização L2 ajuda a evitar *overfitting*, promovendo maior capacidade de generalização (CHOLLET, 2017). Adicionalmente, algoritmos como Adam têm se mostrado eficazes na otimização de pesos das redes. A definição de métricas claras para avaliação, como o erro quadrático médio (MSE) e o coeficiente de determinação (R^2), é fundamental para validar o desempenho do modelo de maneira objetiva e comparável.

As Redes Neurais Artificiais (RNAs) têm se destacado como uma ferramenta poderosa para a modelagem e previsão de propriedades mecânicas complexas em materiais metálicos, especialmente em processos de fabricação que envolvem tratamentos térmicos e deformações plásticas. Entre essas propriedades, a dureza — essencial para aplicações estruturais e de resistência

ao desgaste — é fortemente influenciada por múltiplas variáveis interdependentes, como composição química, taxa de resfriamento, temperatura de austenitização ($T\gamma$), e grau de deformação.

Schmidhuber (2015) argumenta que a principal vantagem das RNAs está na sua capacidade de modelar relações não lineares, sendo particularmente úteis quando os dados experimentais são escassos ou ruidosos. Essa capacidade é crítica na previsão de dureza, onde pequenas variações no processo podem levar a grandes mudanças nas propriedades finais do material. Huang et al. (2018) reforçam que a normalização dos dados de entrada é essencial para garantir estabilidade numérica e melhor desempenho durante o treinamento da rede.

Além disso, práticas como o uso de early stopping, regularização L2, e o ajuste criterioso de hiperparâmetros (número de camadas, taxa de aprendizado, tipo de otimizador) têm sido fundamentais para evitar o sobreajuste e garantir a capacidade de generalização da rede, conforme enfatizado por Chollet (2017). Zhang et al. (2019) demonstraram que redes com três camadas ocultas, combinadas com funções de ativação não lineares como ReLU, obtêm melhor desempenho na previsão de dureza de aços carbono.

Outros estudos, como o de Wang et al. (2020), utilizaram RNAs para prever a dureza Vickers em ligas de alumínio tratadas termicamente, obtendo coeficientes de correlação superiores a 0,95 quando comparados com dados experimentais. Da mesma forma, Chen et al. (2021) desenvolveram uma arquitetura híbrida combinando redes LSTM com CNNs para prever simultaneamente dureza e estrutura de grão em ligas de titânio, com resultados promissores em ambientes de produção real.

Além das redes *feedforward* tradicionais, arquiteturas mais sofisticadas como autoencoders e redes neurais profundas (*deep neural networks*) também têm sido exploradas para identificar padrões latentes nos dados metalúrgicos, como mencionado por Li et al. (2022). A capacidade de extrair automaticamente características relevantes dos dados possibilita *insights* sobre como as variáveis do processo afetam as propriedades mecânicas.

Portanto, a utilização de RNAs na previsão da dureza em materiais metálicos não apenas oferece precisão superior em relação a métodos tradicionais empíricos, mas também permite maior flexibilidade e adaptabilidade na integração com sistemas de controle de processos em tempo real.

2.5.3 Confiabilidade e generalização em ambientes industriais

A confiabilidade das previsões em condições de operação desconhecidas ou variáveis continua sendo um dos principais desafios para os modelos de IA. Embora esses modelos possam apresentar alta precisão em cenários de treinamento controlados, sua capacidade de generalização para novas condições operacionais muitas vezes é limitada. Isso se deve ao fato de que os modelos tendem a ser otimizados para os dados com os quais foram treinados, e quando confrontados com variáveis desconhecidas ou não vistas durante o treinamento, sua performance pode cair drasticamente. Shen et al. (2020) investigaram o uso de técnicas avançadas de redes neurais para prever o desgaste de ferramentas sob uma variedade de condições de corte. Eles enfatizaram a importância de desenvolver modelos adaptáveis que possam lidar com condições operacionais imprevisíveis e desconhecidas. Os autores aplicaram algoritmos de aprendizado profundo e observaram que, ao treinar o modelo em um conjunto diversificado de condições, ele foi capaz de ajustar-se melhor a cenários não previamente observados.

Os resultados obtidos por Shen et al. (2020) indicam que o uso de redes neurais profundas em ambientes de alta variabilidade operacional melhorou significativamente a precisão das previsões. Em particular, o modelo foi capaz de prever o desgaste de ferramentas de maneira mais eficaz, mesmo quando exposto a condições de operação que estavam fora do escopo dos dados de treinamento. Essa capacidade de adaptação dinâmica foi considerada essencial para superar as limitações dos métodos tradicionais, que tendem a falhar em situações de operação variável. A abordagem demonstrou que, com técnicas adequadas de aprendizado profundo, é possível criar modelos que generalizam melhor para cenários industriais complexos, tornando-os mais confiáveis e úteis

em situações reais de manufatura onde as condições de operação podem mudar frequentemente (Shen et al., 2020).

Uma abordagem promissora para lidar com condições operacionais desconhecidas ou variáveis é o uso de autoencoders variacionais (VAEs) e modelos generativos adversariais (GANs). Essas técnicas são projetadas para identificar condições anômalas ou fora do padrão, o que permite que o sistema reconheça quando uma situação inesperada ocorre e ajuste suas previsões de acordo. Os VAEs capturam a distribuição dos dados de entrada e são capazes de gerar novas amostras que seguem essa distribuição, ajudando a detectar anomalias em tempo real. Por outro lado, os GANs usam uma arquitetura competitiva entre dois modelos (gerador e discriminador), o que também os torna eficazes para detectar padrões anômalos. Ao aplicar esses modelos em processos de forjamento, seria possível prever o desgaste das ferramentas mesmo quando condições não observadas previamente surgirem, uma vez que os modelos poderiam identificar rapidamente a anomalia e ajustar suas previsões.

Gittler et al. (2021) investigaram o uso de aprendizado não supervisionado para agrupar dados de sensores e prever estados de degradação de ferramentas no contexto da fresagem. Embora o estudo tenha sido voltado para processos de fresagem, os princípios empregados podem ser facilmente adaptados ao forjamento, onde as condições de operação podem variar significativamente de um lote de produção para outro. A utilização de técnicas não supervisionadas, como a aplicada por Gittler et al. (2021), oferece uma maneira eficiente de lidar com a falta de rotulagem nos dados de sensores, o que é comum em ambientes industriais. Em processos como o forjamento, onde as mudanças nas condições operacionais podem ser súbitas e extremas, a capacidade de identificar automaticamente novos padrões de degradação é essencial para melhorar a precisão das previsões de desgaste (Gittler et al., 2021).

Além disso, a implementação de ensembles de modelos pode aumentar significativamente a confiabilidade das previsões. Combinar diferentes técnicas de machine learning permite capturar várias dimensões do processo de desgaste, especialmente em situações de grande variabilidade nos dados. Os modelos de ensemble integram as previsões de vários modelos individuais,

proporcionando uma estimativa mais robusta e estável. Isso é particularmente útil em ambientes industriais complexos, onde um único modelo pode não ser capaz de lidar adequadamente com todas as nuances dos dados. A combinação de modelos reduz o risco de erro de previsão, já que os pontos fortes de cada modelo podem complementar as fraquezas dos outros. Além disso, a utilização de técnicas de quantificação de incerteza permite que o sistema indique a confiança em suas previsões, alertando os operadores quando o modelo está operando fora de suas áreas de maior precisão, o que melhora a segurança e a eficiência do processo preditivo.

2.6 Métodos comparativos de modelagem

A escolha do método de modelagem é um fator determinante para a precisão e a robustez das previsões em processos metalúrgicos. Diferentes algoritmos apresentam características específicas que podem influenciar diretamente o desempenho do modelo, dependendo da natureza dos dados e da complexidade das relações envolvidas. Entre os métodos mais utilizados para previsão de propriedades mecânicas, destacam-se as Máquinas de Vetores de Suporte (SVM) e a Floresta Aleatória (RF), que oferecem abordagens complementares: enquanto as SVMs se destacam pela capacidade de lidar com alta dimensionalidade e relações não lineares, as RFs apresentam maior interpretabilidade e resistência ao sobreajuste. A seguir, serão discutidas as principais características, vantagens e limitações de cada técnica, com foco em sua aplicação na modelagem de propriedades mecânicas de materiais.

2.6.1 Máquinas de Vetores de Suporte (SVM) na Modelagem de Propriedades Mecânicas

As SVMs são frequentemente aplicadas em problemas de previsão de propriedades mecânicas devido à sua capacidade de encontrar hiperplanos ótimos para separação de dados em espaços de alta dimensionalidade (Li et al., 2020). Raschka (2018) destaca que o uso de kernels, especialmente o radial (RBF), pode melhorar significativamente a precisão dos modelos em problemas de regressão. Marques et al. (2022) utilizaram SVM para prever a ductilidade de ligas metálicas e verificaram que a escolha adequada do hiperparâmetro *C* e da largura do kernel são cruciais para o desempenho do modelo.

As vantagens de utilizar Máquinas de Vetores de Suporte são:

- Elevada precisão em conjuntos de dados com poucas amostras e alta dimensionalidade.
- Capacidade de modelar relações não lineares por meio de kernels.
- Robustez contra overfitting quando bem parametrizada.

Já as limitações do modelo são:

- Sensibilidade à escolha dos hiperparâmetros (C, epsilon, tipo de kernel).
- Alto custo computacional para grandes volumes de dados.
- Baixa interpretabilidade em comparação com modelos baseados em árvores.

A Figura 4 ilustra o princípio fundamental do modelo Support Vector Machine (SVM) em sua formulação baseada em funções de kernel. Cada amostra de treinamento x_1 é utilizada para construir uma transformação não linear por meio do cálculo das similaridades $K(x, x_1)$ entre a nova entrada x e todos os vetores de suporte do conjunto de dados. Esses valores de kernel atuam como "neurônios" intermediários que representam implicitamente o mapeamento de x para um espaço de maior dimensionalidade, onde a separação linear se torna possível. Em seguida, cada saída do kernel é ponderada por um coeficiente w_1, aprendido durante o treinamento, e combinada em uma soma ponderada à qual se adiciona o termo de viés b para compor a função de decisão $f(x) = \sum_i w_1 K(x, x_1) + b$.

O sinal resultante determina a fronteira de decisão. Assim, o modelo SVM opera como um classificador baseado na combinação linear de similaridades entre o ponto avaliado e as amostras de suporte, explorando o truque do kernel para tratar relações altamente não lineares sem necessidade de explicitar o espaço transformado.

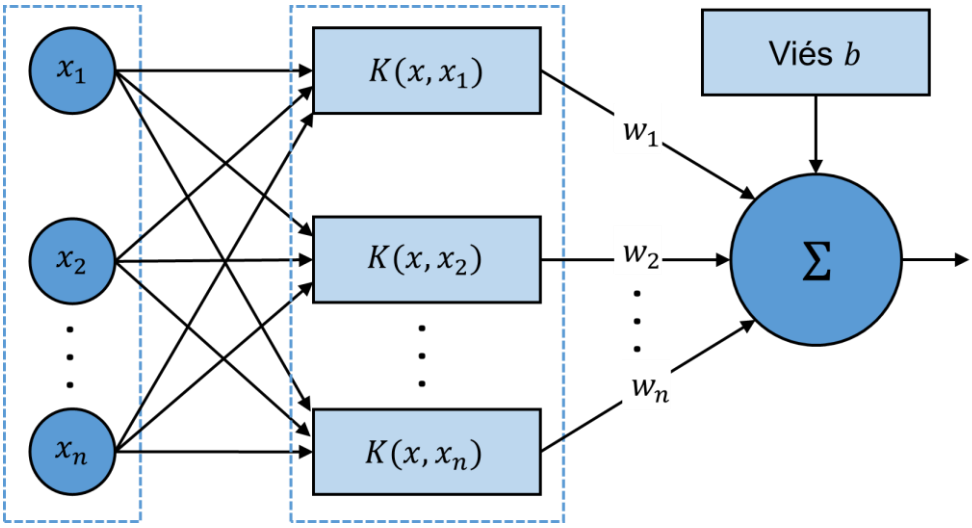


Figura 4 Princípio fundamental do modelo Support Vector Machine (SVM).

A Figura 5 apresenta a interpretação geométrica da função de decisão. Um hiperplano $w\,.\,x - b = 0$ separa as amostras em duas classes, enquanto as margens $w\,.\,x - b = \pm 1$ definem a região de máxima separação possível compatível com os dados. Os vetores de suporte — pontos que tocam essas margens — são fundamentais na determinação dos parâmetros w e b. A distância entre as margens, dada por $2/\| w \|$, representa a largura do intervalo de separação que o SVM procura maximizar.

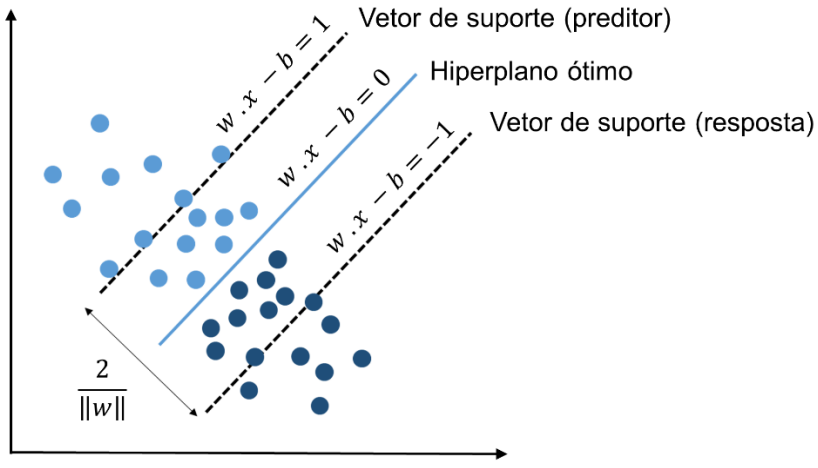


Figura 5 Interpretação geométrica da função de decisão

2.6.2 Floresta Aleatória (RF) e sua Aplicação na Metalurgia

A Floresta Aleatória é uma técnica baseada em múltiplas árvores de decisão que melhora a precisão da previsão ao reduzir o sobreajuste (Géron, 2019). Fernandes et al. (2021) avaliaram o uso de RF na previsão da resistência à tração de aços, demonstrando que a interpretabilidade do modelo permite identificar as variáveis mais influentes no processo. Diferentemente das RNAs e das SVMs, os modelos RF não exigem uma normalização extensa dos dados, tornando sua implementação mais acessível.

As vantagens de utilizar Floresta Aleatória são:

- Alta capacidade de generalização e resistência ao sobreajuste.
- Interpretabilidade superior, permitindo análise da importância das variáveis.
- Funciona bem com dados heterogêneos e sem necessidade de normalização.

Por outro lado, as limitações da técnica são:

- Pode apresentar menor precisão em problemas altamente não lineares.
- Alto consumo de memória para grandes conjuntos de dados.
- Menor capacidade de capturar interações complexas entre variáveis em comparação com redes profundas.

A Figura 6 ilustra, de forma esquemática, o princípio de funcionamento de um modelo *Random Forest* aplicado a um problema de regressão, destacando o fluxo de processamento desde a entrada de uma nova amostra até a geração da predição final do ensemble. Inicialmente, a amostra de entrada x é encaminhada de maneira independente para cada uma das M árvores de decisão que compõem a floresta. Cada árvore é treinada com subconjuntos amostrais distintos — obtidos por *bootstrap* — e com subconjuntos aleatórios de variáveis, o que introduz diversidade estrutural entre os modelos e reduz a variância em relação a uma única árvore de decisão.

À medida que a amostra percorre cada árvore, ela é roteada através de sucessivas decisões binárias até atingir um nó terminal, resultando em uma

predição individual. Esses valores representam estimativas parcialmente correlacionadas, mas não idênticas, obtidas a partir de modelos estruturados de maneira aleatória e independente. Na etapa final, o *Random Forest* combina essas predições por meio de um operador de agregação, no caso da regressão, a média aritmética.

Esse procedimento permite reduzir a variância e melhorar a capacidade de generalização do modelo, explorando o princípio estatístico de que a média de vários estimadores fracos e pouco correlacionados tende a produzir um estimador mais robusto e preciso. A figura, portanto, sintetiza o comportamento coletivo do ensemble e evidencia como a diversidade entre as árvores contribui para a robustez do Random Forest.

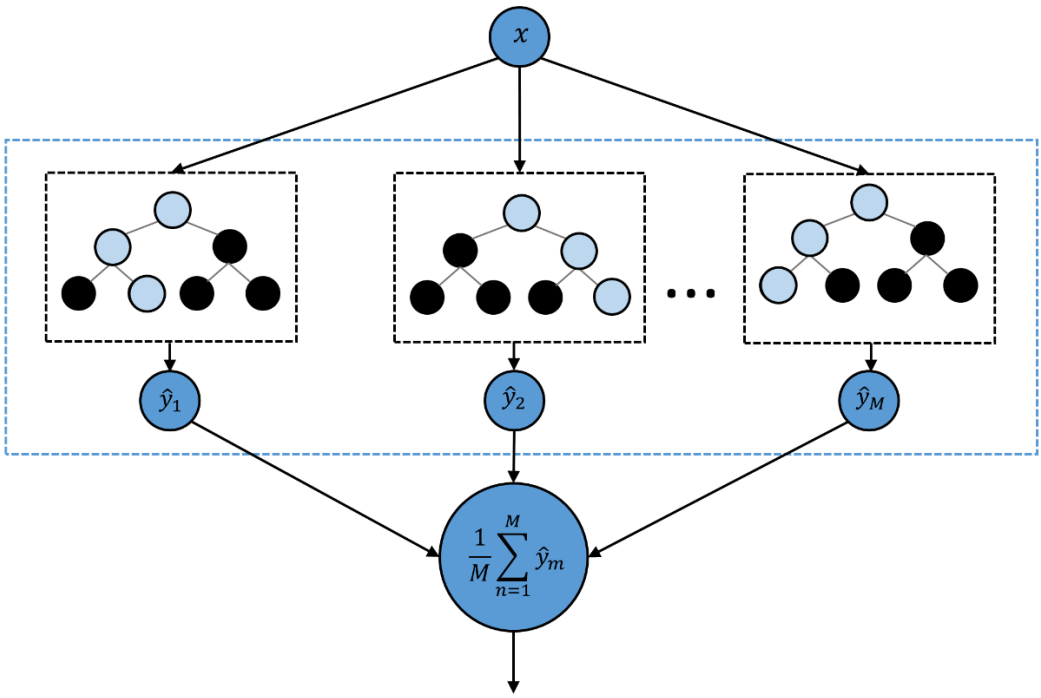


Figura 6 Princípio de funcionamento de um modelo Random Forest aplicado a um problema de regressão.

A seguir, serão apresentados os métodos utilizados para modelagem da dureza do material, incluindo a descrição do conjunto de dados e os processos de treinamento dos modelos RNA, SVM e RF.

2.6.3 Validação cruzada e métricas de desempenho

A avaliação criteriosa do desempenho dos modelos de RNAs é uma etapa crucial para garantir previsões confiáveis em contextos industriais. Métricas como erro quadrático médio (MSE), erro absoluto médio (MAE) e coeficiente de determinação (R^2) são amplamente utilizadas para avaliar a precisão do modelo (WANG et al., 2020). Um R^2 próximo de 1 indica elevada correlação entre os valores previstos e observados. A validação cruzada do tipo *k-fold* permite testar a robustez do modelo em diferentes subconjuntos de dados, reduzindo o risco de *overfitting* (ZHANG et al., 2019). Além disso, a análise de resíduos pode indicar padrões de erro sistemático, sugerindo ajustes na estrutura do modelo ou nos dados de entrada. Para uso industrial, é necessário não apenas que o modelo tenha bom desempenho estatístico, mas que seja interpretável e facilmente integrável aos sistemas de produção existentes (LI et al., 2022). Por isso, métricas quantitativas devem ser complementadas com validações empíricas em ambiente real.

2.7 Aplicações em propriedades mecânicas

A previsão de propriedades mecânicas a partir de dados de processo representa uma das aplicações mais promissoras da modelagem preditiva na metalurgia. Em particular, a dureza, a resistência à tração, o limite de escoamento e a tenacidade são propriedades críticas para a qualificação de produtos forjados, laminados ou tratados termicamente. Tradicionalmente, essas propriedades são determinadas por meio de ensaios destrutivos, o que implica em custos elevados, perda de material e limitação na representatividade estatística. Nesse contexto, modelos preditivos baseados em dados surgem como alternativas viáveis para reduzir a dependência de testes físicos, mantendo a confiabilidade dos resultados.

A literatura tem demonstrado que variáveis de processo como temperatura de aquecimento, tempo de tratamento térmico, taxa de resfriamento, composição química e parâmetros de deformação estão fortemente correlacionadas com as propriedades mecânicas finais dos materiais.

Segundo Zhang et al. (2020), redes neurais artificiais treinadas com dados históricos de produção foram capazes de prever a dureza Brinell de aços forjados com erro médio inferior a 5%, superando modelos estatísticos convencionais. De forma semelhante, estudos como o de Li et al. (2019) demonstraram que algoritmos de florestas aleatórias podem identificar interações não lineares entre variáveis metalúrgicas e prever o limite de escoamento com alta acurácia.

A aplicação desses modelos requer uma base de dados representativa, com variabilidade suficiente para capturar os efeitos combinados dos parâmetros de processo. Além disso, a seleção adequada de atributos é essencial para evitar redundância e sobreajuste. Técnicas como análise de componentes principais (PCA), seleção recursiva de atributos (RFE) e análise de importância de variáveis têm sido amplamente utilizadas para esse fim. A validação cruzada, por sua vez, garante a robustez dos modelos e sua capacidade de generalização para novos lotes de produção.

Em ambientes industriais, a integração dos modelos preditivos com sistemas de execução da manufatura (MES) e plataformas de supervisão (SCADA) permite a aplicação em tempo real, possibilitando o ajuste dinâmico de parâmetros de processo com base nas previsões de propriedades. Essa abordagem, conhecida como controle orientado por modelo, tem potencial para reduzir significativamente a variabilidade do produto final e aumentar a eficiência operacional.

Além da dureza, outras propriedades como resistência à tração e tenacidade também têm sido objeto de modelagem preditiva. Em ligas de alumínio, por exemplo, a previsão da resistência mecânica com base em parâmetros de envelhecimento artificial tem mostrado resultados promissores, conforme demonstrado por Huang et al. (2021). Esses avanços indicam uma tendência crescente de substituição parcial de ensaios destrutivos por modelos digitais, alinhando-se aos princípios da Indústria 4.0 e da manufatura inteligente.

Portanto, a aplicação de modelos preditivos para propriedades mecânicas não apenas contribui para a redução de custos e tempo de ciclo, mas também amplia a capacidade de controle e rastreabilidade dos processos metalúrgicos, promovendo maior confiabilidade e competitividade industrial.

2.8 Desafios na Implementação Industrial

Embora as RNAs apresentem excelente desempenho preditivo, sua implementação em ambientes industriais enfrenta barreiras práticas. Um dos principais desafios é a coleta de dados confiáveis, especialmente em ambientes ruidosos ou onde sensores são escassos (OHDA et al., 2003). Além disso, a integração dos modelos preditivos com sistemas de automação e controle requer infraestrutura computacional compatível e treinamento da equipe técnica. Modelos de aprendizado profundo, por exemplo, demandam maior poder de processamento e sofisticação na manutenção (CHEN et al., 2021). Outro obstáculo refere-se à interpretabilidade dos modelos: redes neurais muitas vezes operam como “caixas-pretas”, dificultando a compreensão das relações entre entrada e saída. Para superar isso, estratégias como IA explicável (XAI) vêm sendo adotadas para fornecer maior transparência (LI et al., 2022). Superar esses desafios é essencial para que os benefícios das RNAs possam ser plenamente aproveitados na predição de dureza e controle de qualidade em forjamento a quente.

2.8.1 Integração com sistemas legados de forjaria

A integração de modelos de *machine learning* (ML), ou aprendizado de máquina, com sistemas legados é uma etapa crítica para sua implementação industrial, especialmente em plantas com infraestrutura consolidada baseada em CLPs (Controladores Lógicos Programáveis), dispositivos eletrônicos robustos que executam lógicas de controle em tempo real, e em protocolos proprietários que dificultam a interoperabilidade. Para superar essa limitação, abordagens como o uso de gateways industriais, que atuam como pontes entre diferentes redes e protocolos, e APIs (*Application Programming Interfaces*) customizadas, que permitem a comunicação entre softwares distintos, têm sido empregadas para garantir a integração entre novas soluções de inteligência artificial (IA) e os sistemas existentes (Lopes, 2025).

A necessidade de sincronização dos dados preditivos com os ciclos operacionais exige também que os modelos sejam embarcados, ou seja, integrados diretamente aos dispositivos de controle, ou que operem em tempo real, processando dados à medida que são gerados. Estudos mostram que frameworks flexíveis (estruturas de desenvolvimento que facilitam a implementação de soluções de software) permitem essa integração mesmo em infraestruturas restritas, contribuindo para a manutenção da confiabilidade operacional (Fernandes, 2024).

Além disso, a adaptação de IA a arquiteturas industriais pode ser favorecida pela aplicação de *Digital Twins*, ou gêmeos digitais, que são representações virtuais dinâmicas de sistemas físicos. Esses modelos simulam o comportamento dos ativos reais e permitem ajustes contínuos sem comprometer o funcionamento do ambiente físico. Essa abordagem é especialmente relevante em contextos em que a substituição de sistemas legados é economicamente inviável, como destacado por Mendonça (2024) e Danta (2021).

2.8.2 Escalabilidade e custo computacional

A escalabilidade computacional representa uma das principais barreiras para a adoção ampla de modelos preditivos baseados em inteligência artificial (IA) na indústria. À medida que os algoritmos se tornam mais complexos, como no caso das redes neurais profundas (*deep neural networks*), o custo computacional associado ao treinamento e à inferência cresce de forma exponencial. Esse custo não se limita apenas ao tempo de processamento, mas também envolve consumo energético, necessidade de *hardware* especializado — como unidades de processamento gráfico (GPUs) ou unidades de processamento tensorial (TPUs) — e infraestrutura de armazenamento e rede.

Durante a fase de treinamento, modelos de grande porte podem demandar centenas de horas de processamento em clusters de alto desempenho, o que inviabiliza sua aplicação em ambientes industriais com recursos limitados. Além disso, mesmo após o treinamento, a fase de inferência

— ou seja, a aplicação do modelo em tempo real — pode representar um custo significativo, especialmente quando o modelo é utilizado em larga escala. Estudos recentes mostram que, em alguns casos, o custo energético da inferência pode superar o do treinamento após milhões de execuções, tornando-se um desafio crescente para a sustentabilidade computacional.

Para mitigar esses obstáculos, diversas estratégias têm sido adotadas. Entre elas, destacam-se a compressão de modelos, que reduz o número de parâmetros sem perda significativa de desempenho; o *pruning*, que elimina conexões irrelevantes nas redes neurais; e o uso de arquiteturas otimizadas para inferência embarcada, como redes convolucionais leves (*MobileNet, SqueezeNet*) e modelos quantizados. Essas abordagens permitem a execução eficiente dos modelos em dispositivos com capacidade computacional restrita, como controladores industriais ou *gateways* embarcados.

Outro fator relevante é a viabilidade da execução em ambientes locais (*on-premises*), onde a conectividade com a nuvem é limitada ou indesejável por razões de segurança ou latência. Nesse contexto, muitos estudos têm proposto o uso de infraestrutura híbrida, na qual o treinamento dos modelos é realizado em ambientes de nuvem, com maior capacidade de processamento, enquanto a inferência ocorre localmente, próxima ao processo físico. Essa abordagem reduz o custo total de operação e melhora a responsividade do sistema.

Nesse cenário, destaca-se o conceito de *edge computing*, ou computação de borda, que consiste na realização de processamento de dados diretamente nos dispositivos próximos à fonte de geração — como sensores, CLPs ou gateways industriais — em vez de depender exclusivamente de servidores remotos ou nuvem. A computação de borda permite que os modelos de IA operem com baixa latência, maior confiabilidade e menor consumo de banda, sendo especialmente útil em aplicações industriais que exigem resposta em tempo real. Além disso, ela contribui para a escalabilidade ao distribuir a carga computacional entre os diversos pontos da rede, evitando gargalos centralizados e reduzindo o custo operacional.

A escalabilidade também envolve a capacidade de integrar sistemas heterogêneos e suportar o crescimento contínuo no volume de dados gerados

por sensores, sistemas SCADA e dispositivos IoT. A manutenção da eficiência computacional, mesmo diante do aumento da complexidade dos dados, exige arquiteturas distribuídas, uso de *edge computing* e técnicas de gerenciamento inteligente de dados. Oliveira e Bacci (2024) destacam que a escalabilidade deve ser pensada não apenas em termos de capacidade de processamento, mas também de interoperabilidade, modularidade e sustentabilidade energética.

Por fim, o custo computacional da IA não é apenas técnico ou financeiro, mas também ambiental. O consumo de energia elétrica e água por data centers e clusters de treinamento tem sido objeto de crescente preocupação. Segundo o IEEE Technology Climate Center, a inferência em larga escala pode representar um impacto ambiental significativo, especialmente quando não há otimização dos modelos ou políticas de eficiência energética. Em alguns casos, o custo energético da inferência ultrapassa o do treinamento após cerca de 50 milhões de execuções, evidenciando a necessidade de práticas mais sustentáveis no desenvolvimento e operação de sistemas de IA.

2.8.3 Considerações de segurança e manutenção

A confiabilidade a longo prazo de soluções baseadas em inteligência artificial (IA) em ambientes industriais depende de dois pilares fundamentais: a segurança cibernética e a manutenção contínua dos modelos preditivos. Com o avanço da Indústria 4.0 e a crescente conectividade entre sistemas de automação, sensores, plataformas de dados e algoritmos de IA, a superfície de ataque digital se expande significativamente. Isso torna os sistemas industriais mais vulneráveis a ameaças como interceptação de dados, sabotagem de modelos e manipulação de parâmetros operacionais.

Nesse contexto, a segurança cibernética deve ser tratada como um requisito estrutural e não apenas como um complemento técnico. A adoção de protocolos robustos de autenticação, criptografia ponta a ponta, segmentação de redes industriais e monitoramento contínuo de tráfego são medidas essenciais para proteger os dados sensíveis e garantir a integridade dos modelos. Conforme destacado por Martins (2018), a ausência de políticas de segurança

bem definidas pode comprometer não apenas a performance dos sistemas, mas também a segurança física de operadores e equipamentos.

Além da proteção contra ameaças externas, a manutenção dos modelos de IA é igualmente crítica para garantir sua eficácia ao longo do tempo. Modelos preditivos treinados com dados históricos estão sujeitos ao fenômeno conhecido como *data drift*, que ocorre quando as distribuições dos dados de entrada mudam em relação ao conjunto de treinamento original. Isso pode levar à degradação do desempenho preditivo e à tomada de decisões incorretas. Para mitigar esse risco, é necessário implementar políticas de *model retraining* periódicas, utilizando dados atualizados do processo para readequar os parâmetros do modelo às novas condições operacionais.

O monitoramento contínuo dos modelos, por meio de indicadores de erro como MSE, MAE ou acurácia, permite a detecção precoce de desvios de desempenho. Além disso, a validação empírica dos resultados — por meio da comparação com medições reais ou inspeções de qualidade — contribui para manter a robustez dos modelos em diferentes contextos produtivos. Zonta (2022) ressalta que a manutenção preditiva dos próprios modelos de IA deve ser integrada ao ciclo de vida da solução, com mecanismos automatizados de atualização, *rollback* e versionamento.

Outro aspecto relevante é a integração entre IA e estratégias de manutenção preditiva dos ativos industriais. Ao combinar modelos de previsão de falhas com sistemas de gerenciamento inteligente de manutenção, é possível antecipar intervenções, reduzir paradas não planejadas e aumentar a disponibilidade dos equipamentos. Rodrigues (2017) demonstra que essa sinergia entre IA e manutenção preditiva não apenas melhora a eficiência operacional, mas também fortalece a resiliência do sistema como um todo.

Portanto, a segurança e a manutenção de soluções de IA devem ser tratadas de forma integrada e contínua, envolvendo desde a arquitetura de rede até a governança dos dados e a atualização dos modelos. Em ambientes industriais complexos, essa abordagem é essencial para garantir a confiabilidade, a escalabilidade e a sustentabilidade das aplicações baseadas em inteligência artificial.

3 MATERIAIS E MÉTODOS

Neste capítulo, serão detalhados todos os procedimentos metodológicos adotados para o desenvolvimento deste trabalho. A seção inicia com a descrição da caracterização dos materiais e a subsequente criação do banco de dados, que fundamenta toda a análise. Em seguida, são apresentadas as etapas de pré-processamento dos dados e a avaliação preliminar de modelos lineares. Por fim, descreve-se a arquitetura, o treinamento e a avaliação dos modelos de aprendizado de máquina mais complexos, incluindo Redes Neurais Artificiais (RNA), Máquinas de Vetores de Suporte (SVM) e Floresta Aleatória (RF), que compõem o núcleo da modelagem preditiva.

3.1 Contextualização do trabalho

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 7 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.

O objetivo principal deste estudo é desenvolver um modelo que possa prever a dureza após o forjamento a quente de um grupo de amostras de um mesmo lote e composição química de um aço chamado comercialmente de Hardox450® com base na velocidade de deformação, temperatura inicial e final aplicados a esse processo.

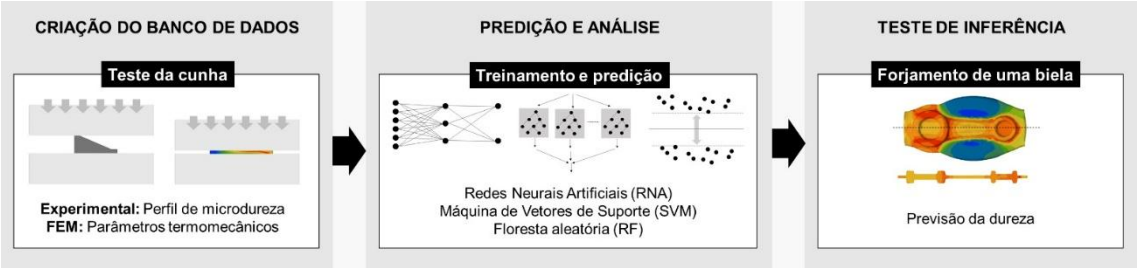


Figura 7 Fluxograma detalhando o processo de seleção, organização de dados, treinamento e escolha da RNA.

Esta seção detalhará os procedimentos adotados para o processamento dos dados, desenvolvimento e avaliação de um modelo preditivo baseado em Rede Neural Artificial (RNA) para estimar a dureza (HV) de um material submetido a processamento termomecânico.

3.2 Criação do banco de dados

O banco de dados utilizado neste trabalho foi construído a partir do estudo experimental conduzido por Rosiak (2025), que investigou o processamento termomecânico de um aço de baixo carbono, baixa liga e microligado ao Ti e ao Nb, com ênfase na obtenção de uma microestrutura bainítica otimizada após o forjamento a quente. Como as propriedades mecânicas de componentes bainíticos forjados são fortemente determinadas pelas condições de processamento, a pesquisa de Rosiak (2025) examinou de forma sistemática os efeitos combinados dos parâmetros térmicos e mecânicos sobre a evolução microestrutural. Esse conjunto de experimentos gerou um banco de dados robusto, contendo informações detalhadas sobre a interação entre material e processo, essencial para o desenvolvimento e avaliação dos modelos preditivos empregados neste estudo.

Para avaliar de forma econômica e ágil o efeito dos parâmetros termomecânicos na dureza da microestrutura bainítica forjada a quente, Rosiak (2025) empregou o teste da cunha. A seguir são apresentados o material investigado na pesquisa e a metodologia utilizada nos testes de forjamento da cunha.

3.2.1 Aço Hardox450®

O material investigado na pesquisa de Rosiak (2020) é o aço designado comercialmente como Hardox450®. Esse material é produzido pela empresa SSAB, na Suécia. Como o material é comercializado com uma microestrutura de martensita revenida, o aço foi normalizado ao ser recebido para eliminar os efeitos de tratamentos térmicos anteriores e facilitar o corte e a usinagem dos corpos de prova. A Tabela 4 mostra a composição química do material.

Tabela 4 Composição química nominal do material de trabalho - % em peso (Certificado de Qualidade do Fabricante, 2024).

Elemento quimico	C	Si	Mn	Cr	Mo	Ni	Al	Nb	Ti	B	N
% em peso	0,18	0,36	1,38	0,47	0,03	0,08	0,05	0,04	0,01	0,002	0,003

Rosiak (2025) demosntrou que a adição de elementos microligantes, combinada com processamento termomecânico, é capaz de gerar propriedades excelentes sem a necessidade de adição substancial de conteúdo de liga. As microligas Ti e Nb contribuem para o refino do grão austenítico e o endurecimento por precipitação da matriz por carbonitretos Ti,Nb(C,N) (Rana & Singh, 2016). Nióbio e titânio retardam significativamente a recristalização, resultando em um aumento da deformação acumulada. Isso, por sua vez, promove uma alta taxa de nucleação durante a transformação da austenita em bainita, levando à formação de grãos ferríticos extremamente finos (Padilha & Jr., 2005). Além disso, os precipitados de Ti e Nb são estáveis a altas temperaturas, permitindo o controle do tamanho de grão da austenita.

A adição de elementos de liga com manganês, cromo e molibdênio aumentam a temperabilidade do material (Ulewicz, et al. 2013). A adição de molibdênio altera significativamente a temperatura de transformação perlítica, atrasando o início da formação de perlita (Honeycombe & Bhadeshia, 1995).

O teor de enxofre é mantido em cerca de 0,01% em peso para ampliar a usinabilidade, sem prejudicar as propriedades relacionadas à fadiga. O Níquel é adicionado para melhorar a tenacidade (Engineer et al., 2011). O teor é limitado a cerca de 0,1% em peso devido ao elevado valore deste elemento. O boro é fundamental para garantir temperabilidade a componentes produzidos por resfriamento contínuo.

3.2.2 Teste da Cunha

A Figura 8 apresenta esquematicamente o princípio do teste de forjamento da cunha. Esse ensaio consiste no forjamento de corpos de prova com forma de cunha entre matrizes planas e paralelas, produzindo um gradiente de deformações, velocidade de deformação e temperaturas ao longo da amostra. Essa característica torna o teste altamente eficiente, permitindo a obtenção de um volume significativo de dados a partir de um único experimento. A variação das temperaturas de forjamento, combinada à integração do procedimento experimental com análises numéricas, amplia ainda mais o espectro de condições investigadas. Os dados obtidos são posteriormente confrontados com perfis de microdureza medidos nas seções das cunhas forjadas, o que possibilita estabelecer relações robustas entre os parâmetros do processo e a dureza resultante, sem a necessidade de um número elevado de ensaios.

Nos testes, as amostras foram aquecidas em forno resistivo até a completa homogeneização da temperatura ao longo da seção. Em seguida, o material foi transferido para as matrizes de forjamento montadas em uma prensa hidráulica marca FKL, com capacidade de 7000kN e velocidade de 5,3mm/s. As matrizes de forjamento são cobertas com lubrificante a base de grafite e pré-aquecidas a 150°C. Após o fechamento das matrizes, a peça é extraída e submetida a resfriamento contínuo ao ar em repouso, sem fluxo de ar artificial, (Figura 9).

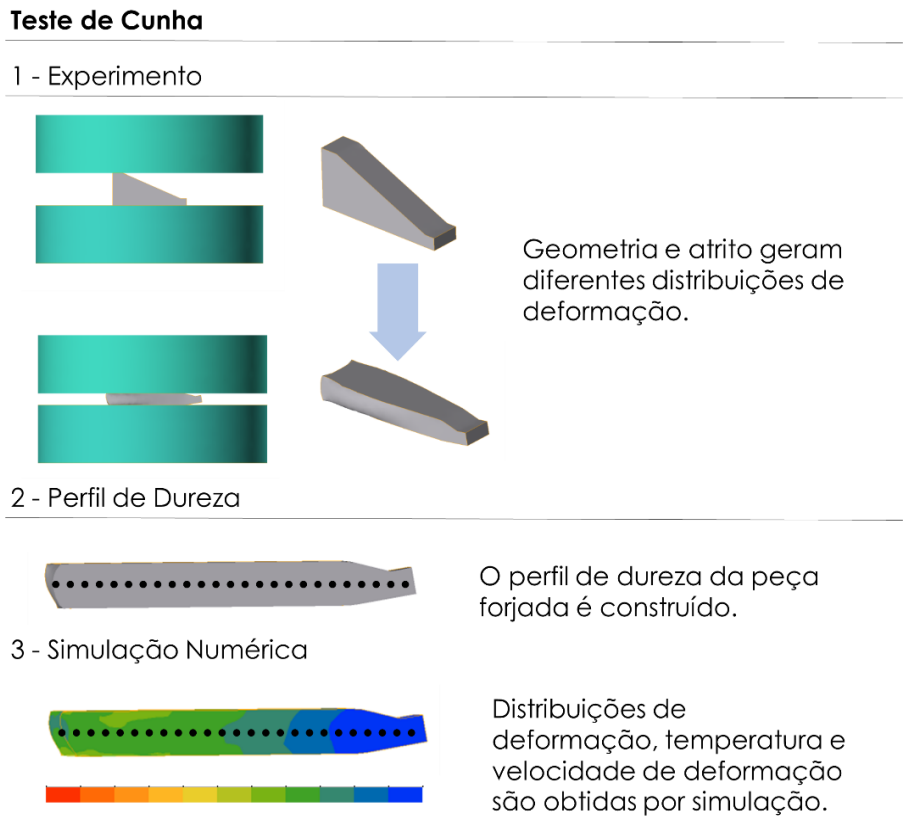


Figura 8 Desenho esquemático do teste de forjabilidade de cunha. (Rosiak, 2025)

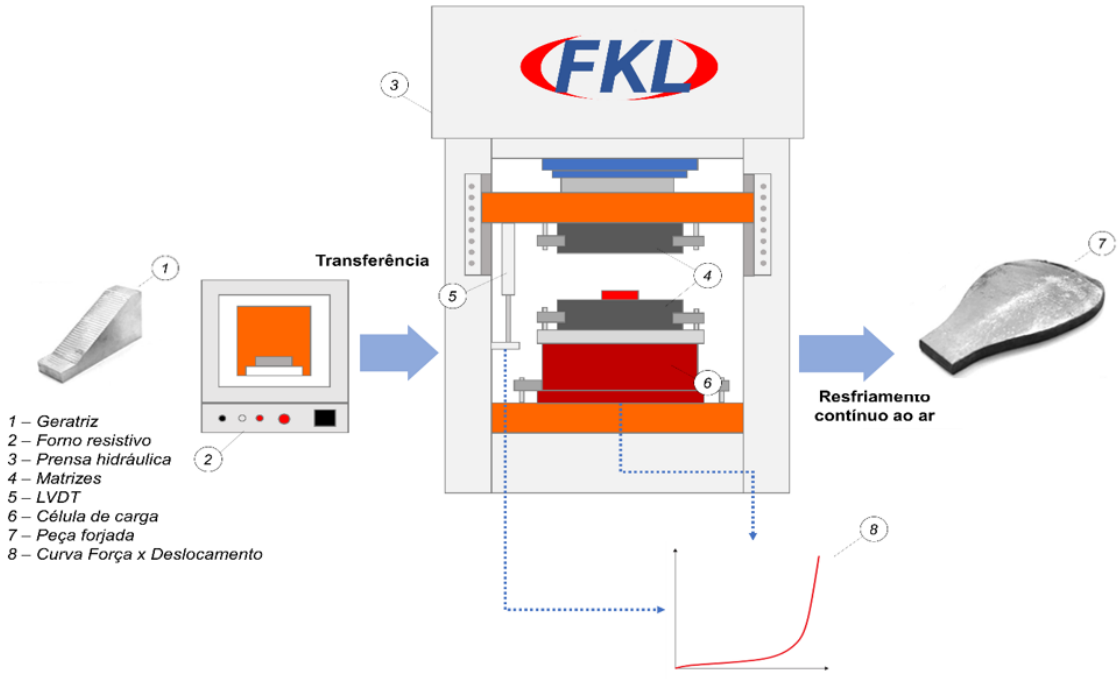


Figura 9 Desenho esquemático do processo de forjamento. Fonte: Rosiak (2025)

Foram analisadas as temperaturas listadas na Tabela 5. Em seguida foi rapidamente transferido para a prensa para a realização da etapa de conformação a quente. As amostras de cunha foram submetidas a uma redução em altura de 82%.

Tabela 5 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 ($v = 5{,}3mm/s$)
Redução de altura	82%
Resfriamento após o forjamento	Contínuo ao ar

Após a realização dos testes, as amostras foram seccionadas e, a partir da seção longitudinal, construiu-se o perfil de microdureza Vickers.

3.3 Determinação de parâmetros, coleta e preparação do banco de dados e pré-processamento

O banco de dados produzido pode ser encontrado no Anexo I contém informações detalhadas sobre as variáveis de processamento, incluindo deformação (φ), velocidade de deformação ($\dot{\varphi}$), temperatura inicial de aquecimento (T_0), temperatura final de forjamento (Tf) e a dureza (HV) final do material. Para cada valor de temperatura inicial de forjamento, foram registradas 591 combinações distintas de $\varphi, \dot{\varphi}$, T_0, Tf e HV, totalizando 2955 dados brutos. Esses dados fornecem uma base rica para modelar a relação complexa entre as

condições de processamento e a dureza do material, essencial para otimizar o processo de forjamento. A variável de saída é a dureza (HV) do material. A Tabela 6 abaixo apresenta as estatísticas descritivas do conjunto de dados.

Tabela 6 Estatísticas do conjunto de dados utilizado para treinar os modelos.

Variável	Média	Desvio Padrão	Mínimo	Máximo
Deformação (φ)	1,549	0,657	0,180	2,135
Velocidade de deformação ($\dot{\varphi}$)	1,395	0,178	0,636	1,623
Temperatura inicial (T_0)	1100	81,718	1000	1200
Temperatura final (Tf)	443,658	26,695	43,869	535,805
Dureza Vickers (HV0.5)	319,987	40,223	249,700	455,505

Com o uso da plataforma Google Colab, foi desenvolvido um algoritmo em Python, que pode ser encontrado no Anexo II deste trabalho, com o objetivo de pré-processar os dados experimentais e preparar o conjunto para aplicação de modelos de aprendizado de máquina. Inicialmente, os dados foram carregados a partir de uma planilha no formato .xlsx, contendo informações sobre deformação, velocidade de deformação, temperaturas inicial e final, e dureza do material.

Após o carregamento, foram selecionadas apenas as colunas relevantes para a análise, sendo padronizados os nomes das variáveis para facilitar o tratamento posterior. Em seguida, realizou-se uma verificação da existência de valores faltantes em cada coluna, bem como a geração de estatísticas descritivas básicas, como média, desvio padrão, valores mínimos e máximos.

Na etapa seguinte, as variáveis independentes (deformação, velocidade de deformação, temperatura inicial e temperatura final) foram separadas da variável dependente (dureza), e os dados foram divididos em dois subconjuntos: um conjunto de treino (70% dos dados) e outro de validação (30%), utilizando a função train_test_split da biblioteca Scikit-learn, com uma semente aleatória fixa para garantir reprodutibilidade. Adicionalmente, foram avaliadas outras proporções de divisão dos dados, como 80% para treino e 20% para validação, e 90% para treino e 10% para validação, com o objetivo de investigar o impacto da quantidade de dados de treinamento no desempenho dos modelos. Os resultados dessas diferentes abordagens encontram-se no Anexo II.

Por fim, os dados de entrada foram normalizados por meio da padronização (z-score), utilizando a classe StandardScaler, a fim de garantir que todas as variáveis apresentassem média zero e desvio padrão unitário, evitando a influência desproporcional de variáveis com magnitudes diferentes. Essa normalização foi aplicada inicialmente ao conjunto de treino e, em seguida, os mesmos parâmetros foram utilizados para transformar o conjunto de validação, assegurando a consistência da escala entre os conjuntos.

Os dados também foram normalizados para a escala [0, 1] utilizando a biblioteca Scikit-learn. As divisões dos dados em 70%/30%, 80%/20% e 90%/10% podem ser encontradas no Anexo II deste trabalho. Na Tabela 7 é apresentada de maneira detalhada as ações realizadas, métodos e Ferramentas utilizados para treinar os modelos.

Tabela 7 Ações Realizadas/Métodos e Ferramentas utilizados para treinar os modelos.

Etapa	Ações Realizadas/Métodos	Ferramentas
1. Ambiente	Desenvolvimento do algoritmo em Python	Google Colab
2. Carregamento	Leitura de dados experimentais (.xlsx) contendo deformação, velocidade de deformação, temperaturas e dureza	pandas/OpenPyXL
3. Seleção	Filtragem de colunas relevantes e padronização dos nomes das variáveis para uniformidade	pandas.DataFrame
4. Limpeza	Verificação de valores faltantes e geração de estatísticas descritivas (média, desvio padrão, min/max)	pandas.isna(), describe()
5. Divisão	Separação em variáveis independentes (X) e dependente (y). Divisão treino/validação (70/30%, 80/20%, 90/10%)	train_test_split (Scikit-learn)
6. Normalização	Padronização (z-score) com média=0 e desvio=1, aplicada primeiro ao treino e depois à validação (mesmos parâmetros)	StandardScaler
7. Escalonamento	Normalização adicional para escala [0, 1] para comparação de impacto nos modelos	MinMaxScaler (Scikit-learn)
8. Reprodutibilidade	Uso de semente aleatória fixa (random_state) para garantir replicabilidade dos resultados	Parâmetro random_state

3.4 Avaliação de modelos lineares como etapa preliminar à modelagem com redes neurais

Antes da aplicação de modelos baseados em Redes Neurais Artificiais (RNA), foi conduzida uma etapa de modelagem preditiva utilizando algoritmos de regressão linear, com o objetivo de verificar se o problema poderia ser

adequadamente resolvido por abordagens estatísticas mais simples. Essa análise preliminar é fundamental para avaliar a linearidade da relação entre as variáveis independentes e a variável de saída (dureza), além de fornecer uma linha de base para comparação com modelos mais complexos.

Inicialmente, foi aplicada a regressão linear múltipla, que assume uma relação linear entre as variáveis de entrada e a saída. Esse modelo, embora simples e interpretável, não possui mecanismos de controle da complexidade, o que pode torná-lo sensível à presença de multicolinearidade ou ruído nos dados. Para contornar essas limitações, foram testadas variantes com regularização, que introduzem penalizações sobre os coeficientes do modelo.

A regressão Ridge, por exemplo, utiliza uma penalização do tipo L2, que adiciona ao erro do modelo um termo proporcional ao quadrado dos coeficientes. Isso força os coeficientes a permanecerem pequenos, reduzindo a variância do modelo e tornando-o mais robusto a dados ruidosos ou altamente correlacionados. Já a regressão Lasso aplica uma penalização L1, baseada na soma dos valores absolutos dos coeficientes. Essa penalização tem um efeito adicional: além de reduzir a magnitude dos coeficientes, ela pode zerar completamente alguns deles, promovendo uma forma de seleção automática de variáveis. Isso é especialmente útil quando se suspeita que nem todas as variáveis de entrada são relevantes para a predição.

Por fim, foi testado o modelo ElasticNet, que combina as penalizações L1 e L2 em uma única formulação. Essa abordagem busca equilibrar os benefícios da robustez da Ridge com a capacidade de seleção de variáveis do Lasso, sendo recomendada quando há muitas variáveis correlacionadas e se deseja controlar a complexidade do modelo de forma mais flexível.

Todos os modelos foram treinados com os dados previamente normalizados e avaliados com base em métricas de desempenho como erro absoluto médio (MAE), erro quadrático médio (MSE) e coeficiente de determinação (R^2). Além disso, foram extraídas as equações de regressão correspondentes, permitindo a interpretação direta da influência de cada variável de entrada sobre a dureza do material.

Tabela 8 Modelagem Preditiva com Algoritmos de Regressão Linear

Etapa	Ações Realizadas/Métodos	Ferramentas/ Métricas
1. Objetivo	Avaliar a viabilidade de resolver o problema com abordagens estatísticas simples antes de aplicar outras ferramentas de inteligência artificial	-
2. Modelo Base	Aplicação de regressão linear múltipla para verificar relações lineares entre variáveis independentes e dureza	Scikit-learn (LinearRegression)
3. Regularização	Teste de modelos com penalização para controlar complexidade e multicolinearidade:	
	- Ridge (L2): Penaliza quadrado dos coeficientes, reduzindo variância	Ridge (Scikit-learn)
	- Lasso (L1): Penaliza valores absolutos, promovendo seleção de variáveis	Lasso (Scikit-learn)
	- ElasticNet: Combina L1 e L2 para equilibrar robustez e seleção de variáveis	ElasticNet (Scikit-learn)
4. Pré-processamento	Uso dos dados normalizados (etapa anterior) para treinamento dos modelos	StandardScaler/ MinMaxScaler
5. Avaliação	Métricas calculadas:	
	- Erro Absoluto Médio (MAE)	mean_absolute_error
	- Erro Quadrático Médio (MSE)	mean_squared_error
	- Coeficiente de Determinação (R^2)	r2_score
6. Interpretação	Extração das equações de regressão para análise da influência das variáveis independentes sobre a dureza	Coeficientes do modelo
7. Decisão	Comparação do desempenho (R^2 alto e erros baixos justificariam evitar modelos complexos; caso contrário, avançar para RNAs)	Resultados das métricas

A expectativa era que, caso os modelos lineares apresentassem desempenho satisfatório, com valores elevados de R^2 e erros reduzidos, não haveria necessidade de recorrer a modelos mais complexos. No entanto, caso os resultados indicassem limitações na capacidade preditiva dessas abordagens, justificaria-se a adoção de redes neurais, que são capazes de capturar relações não lineares entre as variáveis e, portanto, potencialmente oferecer melhor desempenho preditivo, na Tabela 8 é possível verificar em ordem as ações que continham o algoritmo e suas ferramentas ou métricas.

3.5 Modelagem com Redes Neurais Artificiais (RNA)

Para a modelagem preditiva da dureza do material, foi utilizada uma rede neural artificial implementada com o framework TensorFlow, por meio da API

Keras, executada na plataforma Google Colab. O modelo foi construído utilizando a arquitetura do tipo feedforward sequencial, composta por quatro camadas densas totalmente conectadas (fully connected).

O modelo de RNA foi configurado com 4 variáveis de entrada Figura 10: deformação (φ), velocidade de deformação ($\dot{\varphi}$), temperatura inicial de aquecimento ($T0$) e temperatura final de forjamento (Tf). A variável de saída escolhida foi a dureza (H), a qual o modelo foi treinado para prever. Durante o desenvolvimento do modelo, a estrutura da RNA foi ajustada para determinar o número ideal de camadas ocultas e o número de neurônios em cada camada.

Após experimentações, a configuração final da RNA foi determinada com a seguinte arquitetura: a primeira camada continha 256 neurônios, seguida por camadas com 128 e 64 neurônios, todas com a função de ativação ReLU (*Rectified Linear Unit*). A escolha dessa estrutura em forma de funil decrescente (256 → 128 → 64 → 1) visa permitir que o modelo capture inicialmente uma grande quantidade de padrões e relações complexas entre as variáveis de entrada e, gradualmente, realize abstrações mais refinadas ao longo das camadas ocultas. Esse tipo de arquitetura é vantajoso para problemas com múltiplas variáveis de entrada contínuas, pois oferece uma boa capacidade de aprendizado sem comprometer excessivamente a generalização. A camada de saída possuía um único neurônio, adequado à natureza da variável de saída contínua (dureza), sem ativação adicional, dado que se trata de um problema de regressão.

Adicionalmente, foram testadas pelo menos outras duas configurações distintas de camadas ocultas, como por exemplo (128 → 64 → 32) e (64 → 64), bem como diferentes funções de ativação (como tanh e sigmoid), com o objetivo de avaliar o impacto dessas escolhas na performance do modelo. Essa abordagem visa garantir que a arquitetura final adotada seja, de fato, a mais adequada ao problema em questão, conforme recomendado na literatura especializada em redes neurais aplicadas à regressão.

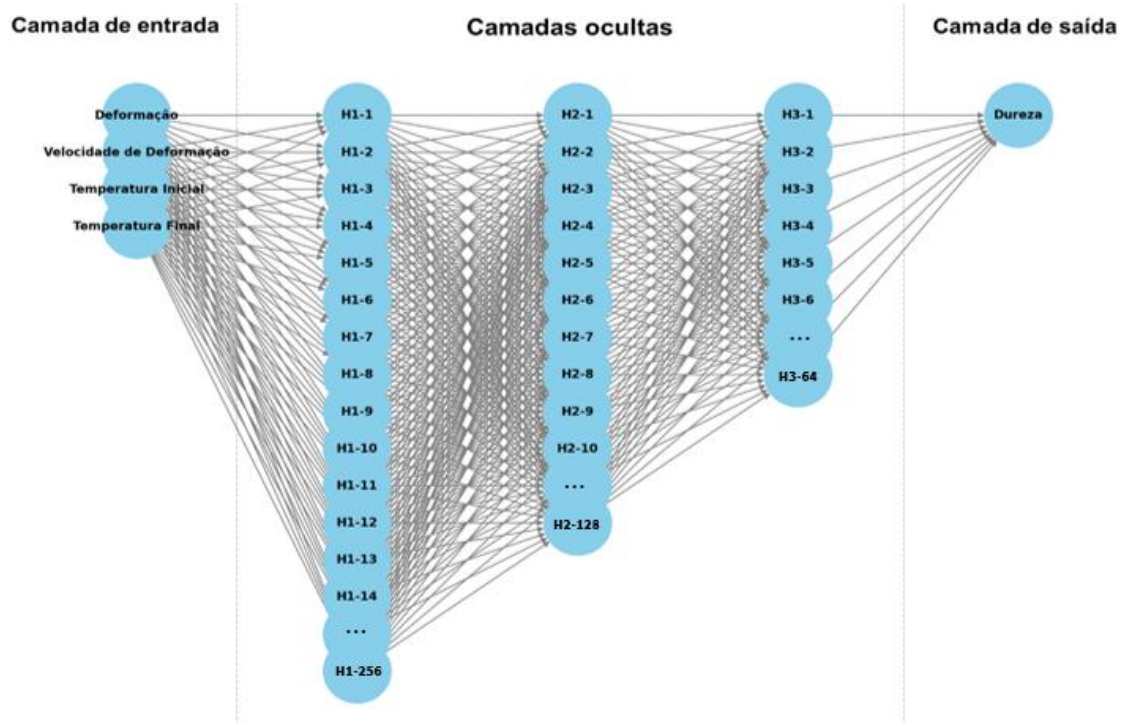


Figura 10 Arquitetura da Rede Neural Artificial Densa proposta.

Para evitar qualquer viés nos resultados e garantir a generalização do modelo, foi adotado o princípio de que os mesmos dados não devem ser utilizados tanto para treinamento quanto para validação. Essa prática ajuda a prevenir o *overfitting*, que ocorre quando o modelo aprende excessivamente os detalhes dos dados de treinamento, comprometendo sua capacidade de generalizar para dados novos e reais. Ao utilizar dados distintos para treinamento e validação, busca-se garantir que as métricas de desempenho reflitam a verdadeira capacidade de predição do modelo (Schmidhuber et al., 2015).

O modelo foi compilado utilizando o otimizador Adam, e a função de perda escolhida foi o erro quadrático médio (*Mean Squared Error*, MSE), enquanto o erro absoluto médio (*Mean Absolute Error*, MAE) foi utilizado como métrica adicional para monitoramento do desempenho.

Durante o treinamento, foi empregada a técnica de parada antecipada (early stopping) com monitoramento da perda no conjunto de validação (val_loss), sendo definidos 20 ciclos (epochs) de tolerância sem melhora como critério para interrupção do treinamento, evitando o sobreajuste. A restauração automática dos melhores pesos obtidos durante o treinamento também foi

ativada. O modelo foi treinado por até 300 épocas, com um *batch size* de 32 amostras, utilizando os dados previamente normalizados. O histórico de treinamento, incluindo a evolução das métricas de desempenho nos conjuntos de treino e validação, foi armazenado para posterior análise.

Após o treinamento da rede neural artificial (RNA), o modelo foi utilizado para realizar previsões de dureza com base nos dados do conjunto de validação. Para isso, as entradas normalizadas foram processadas pela rede, e os valores previstos foram extraídos como uma saída contínua por meio da função .predict() do Keras. Os resultados foram achatados com a função .flatten() para garantir compatibilidade com os vetores reais de saída.

A seguir, foram calculadas as métricas de desempenho da RNA sobre o conjunto de validação. O erro absoluto médio (*Mean Absolute Error* – MAE), o erro quadrático médio (*Mean Squared Error* – MSE) e o coeficiente de determinação (R^2) foram utilizados para quantificar a precisão das previsões. Tais métricas permitiram avaliar, respectivamente, o desvio médio entre valores previstos e reais, a penalização de grandes erros, e a proporção da variância da variável resposta explicada pelo modelo.

Além disso, foi gerado um gráfico com a evolução da função de perda (MSE) ao longo das épocas de treinamento e validação. Esse gráfico teve como objetivo fornecer uma visualização clara do comportamento da rede durante o processo de aprendizado, permitindo identificar a ocorrência de sobreajuste (*overfitting*) ou subajuste (*underfitting*). A comparação entre as curvas de perda nos conjuntos de treinamento e validação forneceu informações valiosas sobre a capacidade de generalização do modelo.

Tabela 9 Modelagem Preditiva com Algoritmos de Redes Neurais Artificiais (RNA)

Etapa	Descrição do Processo	Configurações Implementadas
1. Ambiente	Implementação do modelo utilizando TensorFlow/Keras executado no Google Colab	Framework: TensorFlow 2.x API Keras
2. Arquitetura	Rede neural feedforward sequencial com camadas densas totalmente conectadas	tf.keras.Sequential()
3. Dados	Entrada (4): Deformação (φ), velocidade (φ̇), temperatura inicial (ϑ_0) e final (ϑ_f) Saída (1): Dureza (H)	Pré-processados e normalizados
4. Implementação	• Principal: 256-128-64-1 (ReLU) • Alternativas: 128-64-32 e 64-64 (ReLU/tanh/sigmoid)	Funções de ativação: ReLU, tanh, sigmoid Otimizador: Adam
5. Treinamento	Processo de ajuste dos pesos com monitoramento de métricas de desempenho	Loss: MSE Métricas: MAE, R^2
6. Validação	Avaliação comparativa do desempenho entre diferentes arquiteturas e funções de ativação	Validação cruzada e holdout

Como forma de comparação ao modelo de rede neural artificial (RNA), foram também implementados dois algoritmos de aprendizado supervisionado: o modelo de Máquina de Vetores de Suporte (Support Vector Machine – SVM) e o modelo de Floresta Aleatória (Random Forest – RF), ambos utilizando a biblioteca Scikit-learn.

O modelo SVM foi configurado com um núcleo radial (Radial Basis Function – RBF), que permite capturar relações não lineares entre as variáveis de entrada e a variável de saída. Os parâmetros utilizados foram: penalização C = 100, que controla o *trade-off* entre erro de treinamento e margem de decisão, e γ (gamma) = 0.1, que define a influência de um único ponto de treino. Esses valores foram selecionados com base em testes preliminares com o objetivo de equilibrar a complexidade do modelo e sua capacidade de generalização.

Após o treinamento com os dados normalizados do conjunto de treino, o modelo foi utilizado para gerar previsões sobre o conjunto de validação. O desempenho foi avaliado por meio do erro absoluto médio (MAE), erro quadrático médio (MSE) e coeficiente de determinação (R^2), permitindo comparação direta com os outros modelos desenvolvidos.

O segundo algoritmo testado foi a Floresta Aleatória, um método baseado em ensembles que combina múltiplas árvores de decisão para melhorar a robustez e reduzir o risco de sobreajuste. O modelo foi construído com 100 estimadores (n_estimators = 100) e uma semente fixa (random_state = 42) para garantir a reprodutibilidade dos resultados.

O modelo foi treinado com os mesmos dados normalizados do conjunto de treino, e posteriormente utilizado para realizar previsões sobre o conjunto de validação. As métricas MAE, MSE e R^2 também foram calculadas para esse modelo, possibilitando a comparação direta de desempenho com a rede neural e com o SVM.

3.6 Modelagem com Máquina de Vetores de Suporte (SVM)

A Máquina de Vetores de Suporte (*Support Vector Machine* – SVM) foi utilizada como uma alternativa ao modelo de RNA para a tarefa de regressão da dureza. Para sua implementação, empregou-se a biblioteca Scikit-learn (Pedregosa et al., 2011), utilizando a classe SVR, específica para problemas de regressão. O modelo foi configurado com função de núcleo radial (*Radial Basis Function* – RBF), apropriada para problemas não lineares, dada sua capacidade de projetar os dados para espaços de maior dimensionalidade, onde a separabilidade ou o ajuste podem ser melhor alcançados. A escolha dos hiperparâmetros foi fundamentada em testes preliminares e valores sugeridos na literatura. O parâmetro C = 100 foi adotado para controlar o equilíbrio entre a complexidade do modelo e a penalização de erros. Valores maiores de C tendem a reduzir o erro de treinamento, porém, com risco de sobreajuste. O parâmetro γ (gamma) = 0.1 foi utilizado para controlar a influência de cada ponto de dado sobre a forma da função de decisão. Valores de gamma muito altos tendem a modelar ruído, enquanto valores muito baixos podem subestimar a complexidade do problema.

O modelo SVM foi treinado com o conjunto de dados previamente normalizado (X_train_scaled e y_train) e, após o treinamento, foi utilizado para realizar previsões sobre o conjunto de validação (X_val_scaled). As previsões

foram então avaliadas por meio das métricas erro absoluto médio (MAE), erro quadrático médio (MSE) e coeficiente de determinação (R^2), obtidas a partir da comparação com os valores reais (y_val).

3.7 Modelagem com Floresta Aleatória (RF)

A terceira abordagem de modelagem testada foi a Floresta Aleatória (Random Forest – RF), uma técnica baseada em aprendizado por conjunto (ensemble learning), que agrega múltiplas árvores de decisão para melhorar a capacidade de generalização e reduzir a variância do modelo. O algoritmo foi implementado com a classe RandomForestRegressor da biblioteca Scikit-learn, configurado com 100 estimadores (árvores) e semente aleatória fixa (random_state = 42) para garantir a reprodutibilidade dos resultados. A escolha da Floresta Aleatória deve-se à sua capacidade de lidar com problemas não lineares e com variáveis correlacionadas, além de oferecer maior resistência a sobreajuste quando comparada a modelos baseados em árvores individuais. Além disso, esse modelo fornece, como subproduto, a importância relativa das variáveis de entrada, o que pode contribuir para análises de sensibilidade e tomada de decisão.

Tabela 10 Modelagem Preditiva com Algoritmos de Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF)

Aspecto	**Máquina de Vetores de Suporte (SVM)**	**Floresta Aleatória (RF)**
Biblioteca	Scikit-learn (SVR)	Scikit-learn (RandomForestRegressor)
Tipo de Problema	Regressão	
Configurações	- Kernel: RBF	- Número de estimadores: 100
	- Hiperparâmetros: C=100, gamma=0.1	- random_state=42
Pré-processamento	Dados normalizados (StandardScaler/MinMaxScaler)	
Principais Vantagens	- Eficaz para problemas não-lineares - Projeção para espaços de alta dimensão	- Resistente a sobreajuste - Lida com variáveis correlacionadas - Importância de variáveis
Métricas de Avaliação	MAE, MSE, R^2 (comparação entre y_val e previsões)	
Implementação	Treinamento com X_train_scaled, previsões com X_val_scaled	

O modelo foi treinado com os dados normalizados (X_train_scaled, y_train) e posteriormente utilizado para gerar previsões sobre o conjunto de validação (X_val_scaled). As métricas de desempenho, calculadas com base nos valores reais (y_val).

3.8 Testes de inferência

Para ampliar a avaliação da capacidade preditiva e de generalização dos modelos desenvolvidos, foram realizados testes de inferência utilizando dados que não foram incluídos no conjunto original de treinamento e validação. Essa abordagem tem como objetivo simular condições de aplicação em ambiente real, nas quais 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, permitindo avaliar a aplicabilidade do modelo desenvolvido fora do domínio específico de treinamento. O processo experimental, representado esquematicamente na Fig. 11, consistiu no aquecimento do material até 1200 °C, seguido de sua transferência para uma prensa hidráulica, onde a operação de forjamento foi realizada. Após a extração da peça, o resfriamento ocorreu continuamente ao ar até a temperatura ambiente.

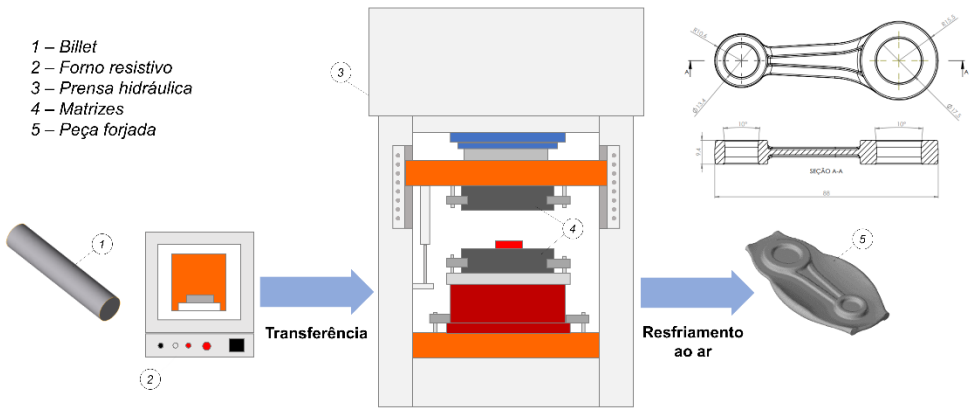


Figura 11 Processo de forjamento de uma biela para avaliação da capacidade preditiva dos modelos de IA.

Informações técnicas detalhadas sobre o processo de forjamento da biela, incluindo parâmetros termomecânicos e operacionais relevantes, são apresentadas na Tabela 11.

Tabela 11 Informações técnicas detalhadas do processo de forjamento das bielas.

Temperatura do material	1000°C
	1100°C
	1200°C
Temperatura das ferramentas	180°C
Lubrificação	Solução a base de grafite
Equipamento de forjamento	Prensa hidráulica ($v = 5{,}3mm/s$)
Resfriamento após o forjamento	Contínuo ao ar

Após o forjamento, as bielas foram seccionadas e o perfil de microdureza foi determinado ao longo da seção longitudinal. Essa metodologia possibilitou uma comparação direta entre as previsões geradas pelos modelos de IA e os valores reais de dureza obtidos experimentalmente, constituindo uma etapa essencial para validar a eficácia e a aplicabilidade prática do modelo.

4 RESULTADOS EXPERIMENTAIS E DISCUSSÃO

Antes de apresentar os resultados numéricos obtidos nos experimentos, é essencial contextualizar a abordagem adotada, destacando os critérios de avaliação e os fundamentos teóricos que sustentam a análise de desempenho dos modelos preditivos. Este capítulo tem como objetivo discutir criticamente os resultados dos Modelos Lineares e em seguida da Rede Neural Artificial (RNA), comparando seu desempenho com outras metodologias de aprendizado supervisionado, como Máquinas de Vetores de Suporte (SVM) e Florestas Aleatórias (RF).

4.1 Análise do banco de dados

O conjunto de dados consistiu em informações de dureza, deformação equivalente (φ), velocidade de deformação ($\dot{\varphi}$), temperatura inicial (ϑ_i) — correspondente à temperatura de aquecimento das cunhas — e temperatura final (ϑ_f), referente à temperatura ao final do forjamento, imediatamente após a abertura da prensa. A relação entre os parâmetros termomecânicos e os valores de dureza é apresentada na Figura 12. Observa-se que a dureza varia de forma não linear com todos os parâmetros analisados, evidenciando a complexidade das interações envolvidas no processo de forjamento a quente.

A Figura 13 apresenta o mapa de calor dos coeficientes de determinação (R^2), destacando a sensibilidade da dureza em relação aos parâmetros termomecânicos do forjamento a quente. Os resultados indicam que a temperatura final de forjamento (ϑ_f) apresenta o maior poder explicativo univariado sobre a dureza ($R^2 \approx 0{,}49$), seguida pela temperatura inicial (ϑ_i) ($\approx 0{,}24$) e pela deformação equivalente ($R^2 \approx 0{,}22$); a velocidade de deformação apresenta a menor associação média ($R^2 \approx 0{,}12$). A triagem univariada confirma esse padrão. Quando consideradas simultaneamente em uma regressão linear, as quatro variáveis explicativas resultam em um ajuste global que explica cerca de 70% da variância da dureza, e os coeficientes padronizados indicam a predominância positiva da temperatura final de forjamento (ϑ_f) ($\approx +0{,}55$) e da

deformação (≈ +0,47), com efeito negativo da velocidade de deformação (≈ −0,22) e influência residual da temperatura inicial (ϑ_i) (≈ +0,04).

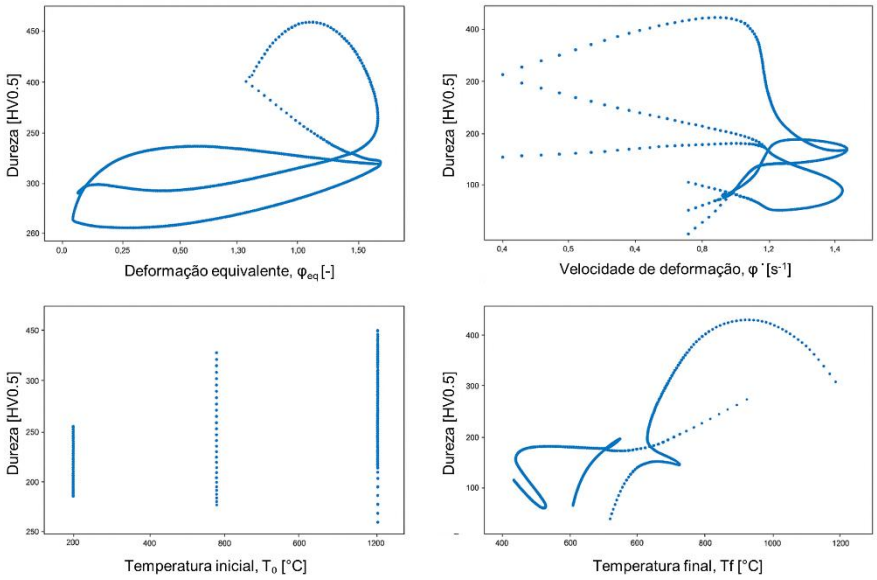


Figura 12 Relação entre os parâmetros termomecânicos e os valores de dureza

A estratificação pela temperatura inicial revela uma dependência do contexto. Em ϑ_i= 1000 °C, o modelo explica 93,8% da variância, e a dureza aumenta principalmente com a deformação (≈ +0,93), enquanto a velocidade de deformação e a temperatura final de forjamento (ϑ_f) atuam no sentido de reduzi-la (≈ −0,76 e −0,32, respectivamente). Em ϑ_i= 1100 °C, por outro lado, a temperatura final de forjamento (ϑ_f) torna-se o principal determinante positivo (≈ +1,16), e a velocidade de deformação também apresenta efeito positivo (≈ +0,43), sugerindo que, dentro da janela térmica intermediária amostrada, as combinações de processo favoreceram um regime no qual valores mais elevados de ϑ_f não degradaram, em média, a dureza; a deformação exibiu efeito médio praticamente nulo (≈ +0,02). Em ϑ_i= 1200 °C, a deformação volta a desempenhar um papel positivo relevante (≈ +0,64), a temperatura final de forjamento (ϑ_f) mantém um impacto positivo moderado (≈ +0,34) e a velocidade de deformação retorna a um efeito negativo (≈ −0,38).

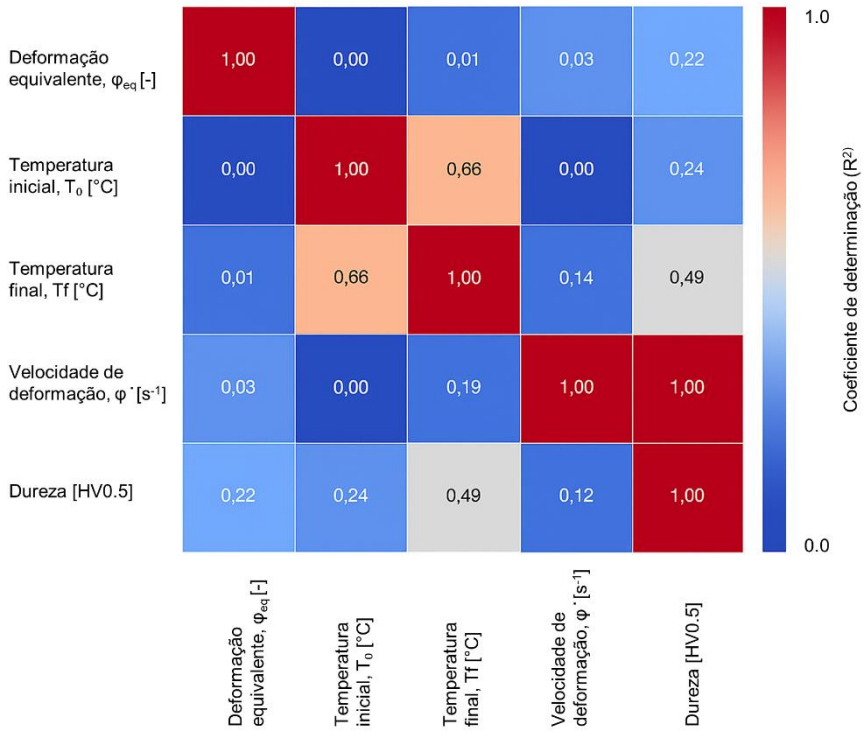


Figura 13 Mapa de calor dos coeficientes de determinação (R^2)

A análise metalúrgica dos resultados apresentados nas Figuras 12 e 13 permite interpretar de forma consistente como os mecanismos microestruturais ativados durante o forjamento a quente governam a evolução da dureza, bem como a forte dependência desses mecanismos em relação à janela termomecânica de processamento.

De forma global, o fato de a temperatura final de forjamento apresentar o maior poder explicativo univariado indica que o estado térmico imediatamente após a deformação é determinante para a dureza final do material. Do ponto de vista metalúrgico, esse comportamento está fortemente associado aos mecanismos de transformação bainítica. Após o forjamento, o material é resfriado lentamente ao ar, promovendo a transformação da microestrutura austenítica em bainita. A temperatura na qual essa transformação ocorre exerce influência direta sobre a cinética de nucleação e crescimento das fases bainíticas, impactando de maneira significativa a resistência mecânica e a dureza dos forjados bainíticos (Rosiak, 2025). Assim, variações na temperatura final de forjamento modificam as condições de transformação, refletindo-se diretamente na dureza final do forjado.

A influência intermediária da temperatura inicial reflete seu papel no condicionamento do estado de austenitização antes da deformação. Temperaturas iniciais mais elevadas favorecem o crescimento de grão austenítico, reduzindo a densidade de contornos disponíveis para nucleação durante a transformação de fase, enquanto temperaturas mais baixas tendem a preservar uma austenita mais refinada. Já a deformação equivalente está associada ao aumento da densidade de discordâncias e à intensificação da recristalização induzida pela deformação, mecanismos clássicos de refino microestrutural que elevam a dureza. A menor correlação univariada da velocidade de deformação sugere que seu efeito é mais indireto e dependente das demais variáveis, atuando principalmente por meio da cinética dos processos termicamente ativados.

Em conjunto, os dados evidenciam que a dureza após o forjamento a quente não é controlada por um único parâmetro isolado, mas pelo balanço dinâmico entre temperatura, deformação e tempo efetivo para os mecanismos de recristalização e transformação de fase. A variação do sinal e da magnitude dos coeficientes conforme a temperatura inicial reforça que os efeitos metalúrgicos são fortemente condicionais, destacando a importância de análises multivariadas e estratificadas para orientar ajustes operacionais robustos e baseados em evidências no processo de forjamento a quente.

4.2 Avaliação Preliminar com Modelos Lineares

Antes de recorrer a abordagens mais complexas como Redes Neurais Artificiais, foi conduzida uma análise com modelos lineares para avaliar se o problema de previsão de dureza poderia ser adequadamente resolvido com técnicas estatísticas mais simples. Esta etapa preliminar é fundamental para estabelecer uma linha de base de desempenho e verificar a existência de relações lineares entre as variáveis independentes e a propriedade mecânica em estudo.

Foram implementados e avaliados quatro modelos distintos de regressão linear. O modelo de Regressão Linear Múltipla tradicional serviu como

referência, enquanto as versões com regularização - *Ridge Regression* (L2), *Lasso Regression* (L1) e *ElasticNet* (combinação L1+L2) - foram testadas para avaliar seu impacto na capacidade preditiva. A avaliação de desempenho considerou três métricas principais: o Erro Absoluto Médio (MAE), que representa a discrepância média entre valores reais e previstos; o Erro Quadrático Médio (MSE), que penaliza mais fortemente os erros maiores; e o Coeficiente de Determinação (R^2), que indica a porcentagem de variabilidade dos dados explicada pelo modelo.

Embora estas abordagens tenham capturado parte significativa da variabilidade dos dados (aproximadamente 72%), a análise crítica destes resultados indicou que as relações entre os parâmetros de processamento e a dureza do material possuem características que transcendem a linearidade simples. Esta constatação foi particularmente evidente quando comparados com os desempenhos subsequentes alcançados por técnicas mais sofisticadas de inteligência artificial.

Tabela 12 Coeficientes das Equações de Regressão

Modelo	Constante	Deformação	Velocidade Deformação	Temperatura Inicial	Temperatura Final
Regressão Linear	322,71	+19,08	-7,31	-0,99	+23,73
Ridge	322,71	+19,07	-7,38	-0,80	+23,50
Lasso	322,71	+19,07	-7,47	-0,35	+23,07
ElasticNet	322,71	+18,53	-7,99	+1,54	+20,44

A análise das equações de regressão (Tabela 12), particularmente do modelo *ElasticNet*, mostrou que a deformação apresenta coeficiente positivo de 18,53, indicando que aumentos nesta variável resultam em maior dureza. Em contraste, a velocidade de deformação mostrou efeito negativo (coeficiente de -7,99), enquanto a temperatura final demonstrou a maior influência positiva (coeficiente de 20,44). Os resultados obtidos, mostrados na Tabela 13, revelaram que todos os modelos lineares testados apresentaram desempenho similar, com valores de R^2 variando entre 0,716 e 0,719. O *ElasticNet* destacou-se ligeiramente com R^2 de 0,719 e MAE de 17,26, seguido pelo *Lasso Regression* com R^2 de 0,717.

Tabela 13 Métricas de Desempenho dos Modelos Lineares

Modelo	MAE (HV)	MSE (HV²)	R²
Regressão Linear	17,46	496,44	0,716
Ridge Regression	17,44	495,86	0,716
Lasso Regression	17,42	494,40	0,717
ElasticNet	17,26	491,73	0,719

A limitação intrínseca dos modelos lineares em representar adequadamente o fenômeno físico-químico em estudo tornou imperativa a exploração de abordagens computacionais mais avançadas. O valor de R^2 obtido, embora estatisticamente relevante, revelou-se insuficiente para os requisitos de precisão exigidos pela aplicação industrial em questão, onde variações mínimas nas propriedades mecânicas podem ter impactos significativos na qualidade do produto final.

Esta fase preliminar cumpriu seu papel fundamental de: (1) estabelecer uma baseline de desempenho, (2) verificar a adequação de soluções mais simples, e (3) fornecer evidências quantitativas da necessidade de métodos mais sofisticados. Os resultados obtidos com os modelos lineares serviram como justificativa técnica robusta para a subsequente investigação com arquiteturas de redes neurais artificiais e outros algoritmos de machine learning não-lineares, conforme detalhado nas seções seguintes deste trabalho.

A transição para modelos mais complexos foi ainda respaldada pela natureza dos dados e pelo conhecimento metalúrgico prévio, que sugerem relações não-lineares entre temperatura, velocidade de deformação e propriedades mecânicas resultantes. Esta decisão metodológica mostrou-se acertada, como comprovado pelos resultados apresentados na Seção 4.2, onde se observou uma melhoria substancial no poder preditivo dos modelos.

4.3 Avaliação do Desempenho da Rede Neural Artificial (RNA)

Os resultados obtidos com diferentes configurações de redes neurais artificiais revelaram variações significativas no desempenho preditivo, conforme evidenciado pelos valores de MAE, MSE e R^2. A Tabela 14 apresenta um

comparativo entre as nove arquiteturas testadas, combinando diferentes funções de ativação (ReLU, Tanh e Sigmoid).

Tabela 14 Desempenho Comparativo das Arquiteturas de RNA

Arquitetura	Função de Ativação	MAE (HV)	MSE (HV²)	R²
256-128-64	ReLU	1,93	13,68	0,992
256-128-64	Tanh	100,65	11877,548	-5,796
256-128-64	Sigmoid	175,49	32544,64	-17,622
128-64-32	ReLU	2,10	13,26	0,992
128-64-32	Tanh	195,05	39793,70	-21,770
128-64-32	Sigmoid	240,79	59728,21	-33,177
64-64	ReLU	3,02	30,44	0,983
64-64	Tanh	93,30	10452,91	-4,981
64-64	Sigmoid	139,46	21196,30	-11,129

As arquiteturas que utilizaram a função de ativação ReLU demonstraram desempenho substancialmente superior às demais. Esses resultados estão resumidos na Tabela 15, que apresenta as três melhores arquiteturas com base no desempenho.

Tabela 15 Top 3 Arquiteturas por Desempenho

Posição	Arquitetura	Ativação	MAE	R²
1	256-128-64	ReLU	1,93	0,992
2	128-64-32	ReLU	2,10	0,992
3	64-64	ReLU	3,02	0,983

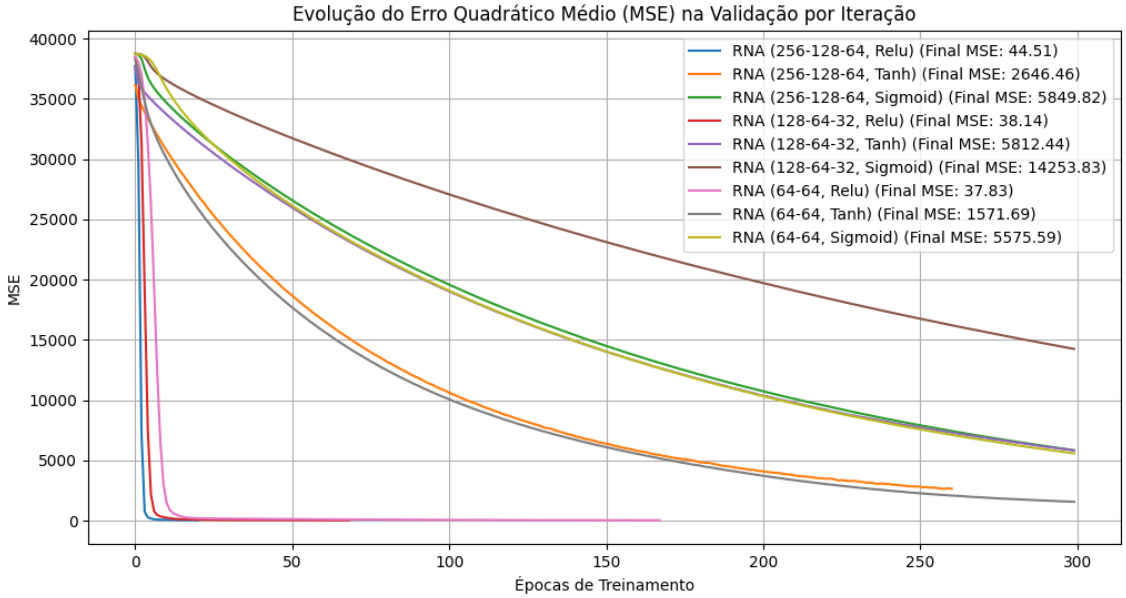


Figura 14 Comparação dos valores de MSE entre as diferentes arquiteturas e funções de ativação.

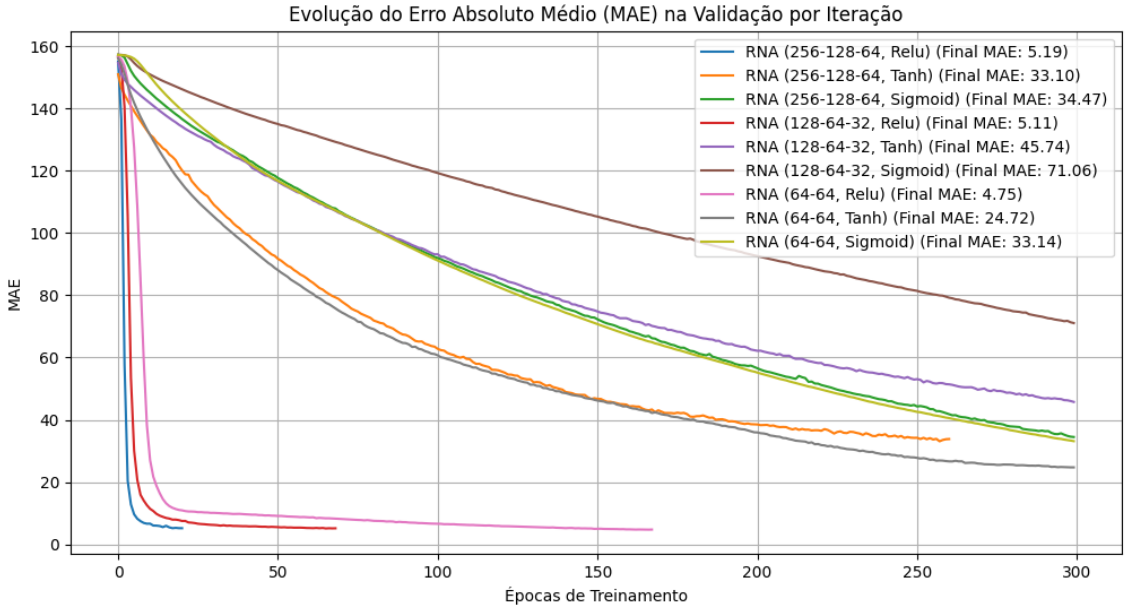


Figura 15 Comparação dos valores de MAE entre as diferentes arquiteturas e funções de ativação.

As Figuras 14 e 15 ilustram visualmente o contraste de desempenho entre as arquiteturas, reforçando a superioridade das configurações com ReLU.

Diante dos resultados obtidos, decidiu-se focar a análise detalhada nas três arquiteturas com melhor desempenho: 256-128-64 (ReLU), 128-64-32 (ReLU) e 64-64 (ReLU). Essas configurações apresentaram os menores valores de erro e os maiores coeficientes de determinação (R^2), conforme evidenciado

nas Tabelas 13 e 14. As demais combinações, que apresentaram desempenho insatisfatório, especialmente aquelas com funções de ativação Tanh e Sigmoid, foram desconsideradas nas discussões subsequentes por não atenderem aos critérios mínimos de precisão preditiva.

Além das comparações gerais, foram elaborados gráficos específicos para as duas arquiteturas selecionadas, com o objetivo de detalhar a avaliação dos erros. A Figura 16, intitulada Evolução dos Erros para a Arquitetura 256-128-64 (ReLU), e a Figura 17, intitulada Evolução dos Erros para a Arquitetura 128-64-32 (ReLU), apresentam visualmente o comportamento dos erros dessas configurações, permitindo uma análise mais aprofundada de seu desempenho. Para fins comparativos, inclui-se também a Figura 18, referente à Arquitetura 64-64 (ReLU), a qual, embora tenha apresentado desempenho inferior, destacou-se em relação às demais combinações com funções de ativação Tanh e Sigmoid.



Figura 16 Evolução dos Erros 256-128-64 (ReLU)



Figura 17 Evolução dos Erros 128-64-32 (ReLU).

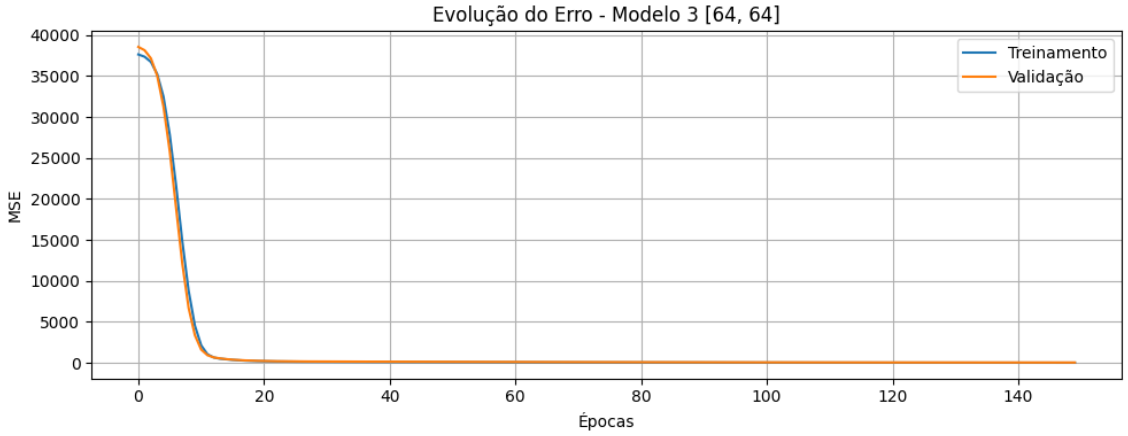


Figura 18 Evolução dos Erros 64-64 (ReLU).

A Figura 19 apresenta o tempo de treinamento, em segundos, para cada uma das arquiteturas de redes neurais artificiais (RNA) analisadas. Observa-se que a arquitetura 64-64 demandou o maior tempo de processamento, com aproximadamente 30 segundos, enquanto as arquiteturas 256-128-64 e 128-64-32 apresentaram tempos significativamente menores, em torno de 12 segundos e 13 segundos, respectivamente. Esse comportamento pode estar relacionado à eficiência computacional das camadas intermediárias e à complexidade do modelo, indicando que arquiteturas mais profundas nem sempre resultam em maior tempo de treinamento.

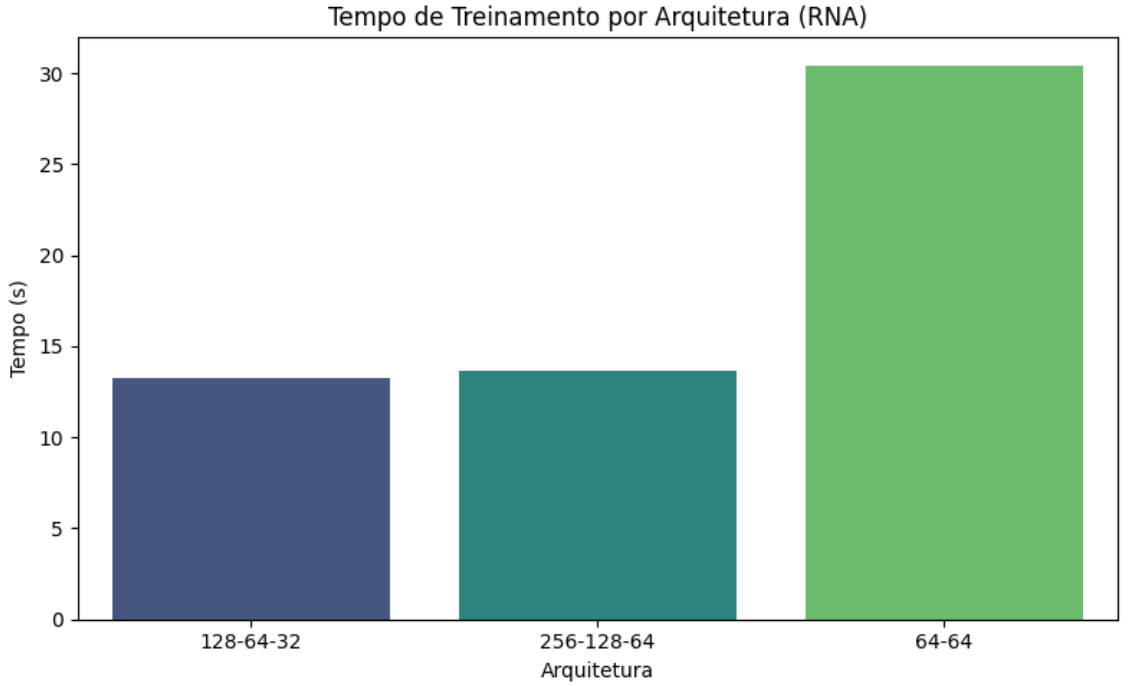


Figura 19 Tempo de treinamento.

A Figura 20 apresenta a comparação dos coeficientes de determinação (R^2) obtidos pelas três arquiteturas de redes neurais artificiais (RNA) com função de ativação ReLU. Observa-se que as arquiteturas 256-128-64 e 128-64-32 apresentaram valores de R^2 próximos de 0,99, indicando excelente capacidade preditiva. Já a arquitetura 64-64 obteve um valor ligeiramente inferior, próximo de 0,98, embora ainda dentro de um intervalo considerado altamente satisfatório. Essa análise reforça a escolha das três arquiteturas como foco da avaliação detalhada, conforme discutido anteriormente.

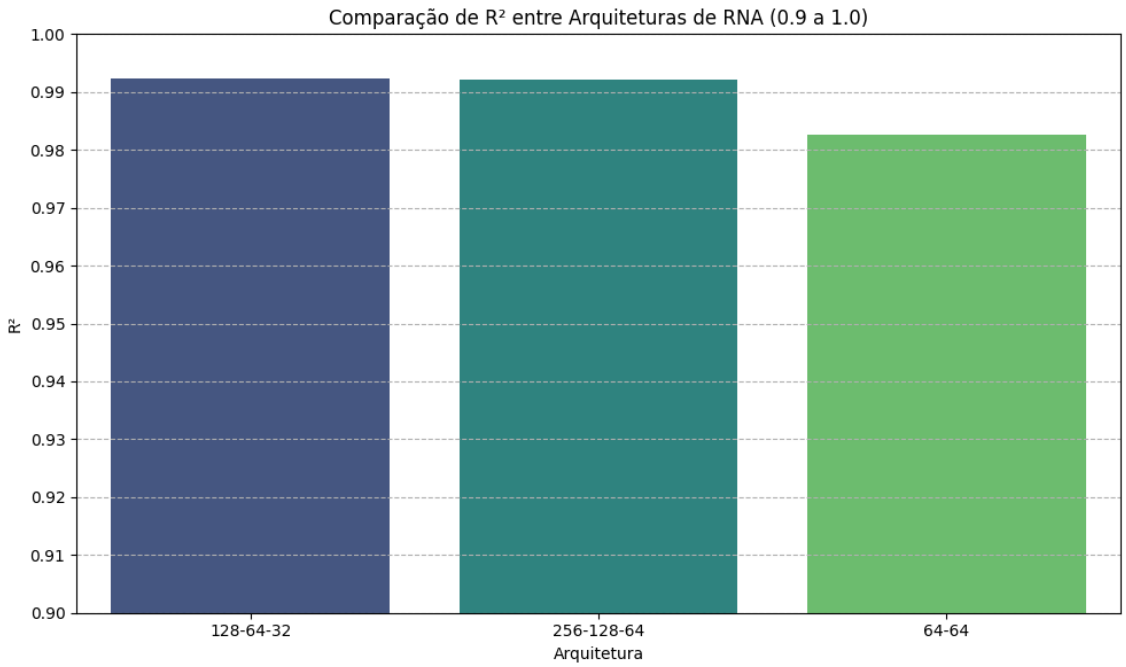


Figura 20 Comparação dos coeficientes de determinação (R^2).

A Figura 21 apresenta uma comparação multivariada entre as arquiteturas 256-128-64, 128-64-32 e 64-64, considerando três métricas de desempenho: Erro Quadrático Médio (MSE), Tempo de Treinamento (s) e Coeficiente de Determinação (R^2). Observa-se que as arquiteturas 256-128-64 e 128-64-32 apresentaram valores semelhantes e baixos de MSE, além de tempos de treinamento reduzidos e R^2 elevados, próximos de 0,99. Em contrapartida, a arquitetura 64-64 apresentou um tempo de treinamento significativamente maior e um leve decréscimo no valor de R^2, embora ainda dentro de um intervalo considerado satisfatório. Essa visualização integrada permite uma análise mais abrangente do equilíbrio entre precisão e custo computacional de cada modelo.

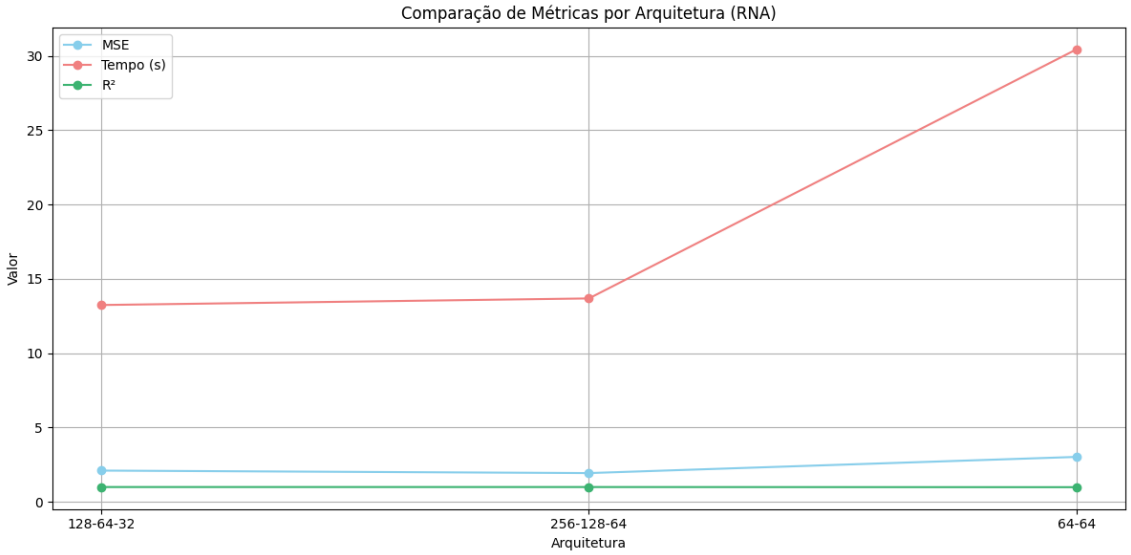


Figura 21 Comparação multivariada entre as arquiteturas 128-64-32, 256-128-64 e 64-64.

O fraco desempenho das funções de ativação Tanh e Sigmoid pode ser atribuído a diversos fatores técnicos inerentes à natureza dessas funções e à configuração do problema em estudo. No caso da função Tanh, que apresentou valores de R^2 negativos em todas as arquiteturas testadas (variando entre -4,981 e -21,770), o principal problema está relacionado ao fenômeno conhecido como *vanishing gradients* (gradientes que desaparecem). Por produzir saídas na faixa entre -1 e 1, essa função tende a gerar gradientes muito pequenos durante o treinamento de redes profundas, dificultando significativamente o processo de aprendizagem, especialmente nas camadas iniciais. Além disso, sua simetria em torno de zero pode não ser a mais adequada para o presente problema de regressão.

Quanto à função Sigmoid, cujos resultados foram ainda mais insatisfatórios (com R^2 variando entre -11,129 e -33,177), os problemas são ainda mais acentuados. Além de também sofrer com o vanishing gradient, a Sigmoid apresenta a desvantagem adicional de produzir saídas apenas positivas (entre 0 e 1), o que pode levar à saturação precoce dos neurônios durante o treinamento. Essa característica é particularmente problemática em problemas de regressão como o deste estudo, nos quais a saída desejada não está normalizada na mesma faixa da função. Outro fator agravante é que a derivada

da Sigmoid atinge seu valor máximo em 0,25, limitando ainda mais o fluxo de gradientes durante o *backpropagation*.

Destaca-se que o desempenho particularmente ruim dessas funções em arquiteturas maiores (como 256-128-64 e 128-64-32) em comparação com a arquitetura menor (64-64) sugere que os problemas de treinamento se tornam mais críticos à medida que a profundidade da rede aumenta. Esse comportamento era esperado, uma vez que redes mais profundas amplificam os efeitos do *vanishing gradient*, especialmente quando utilizam funções como Tanh e Sigmoid.

Em contraste, a função ReLU demonstrou excelente adequação ao problema em estudo, devido às suas características intrínsecas: não linearidade suficiente para capturar relações complexas, ausência de saturação para valores positivos (evitando o *vanishing gradient*) e maior eficiência computacional. Essas propriedades permitiram que as redes neurais com ReLU alcançassem valores de R^2 próximos de 1, indicando excelente capacidade de explicação da variabilidade dos dados.

A decisão de focar apenas nas arquiteturas com ReLU justifica-se não apenas pelos melhores resultados quantitativos, mas também pela estabilidade observada durante o treinamento e pela maior confiabilidade dessas configurações. As variações com Tanh e Sigmoid, por outro lado, apresentaram não apenas baixa precisão, mas também alta variabilidade nos resultados, tornando-as inadequadas para aplicações práticas que demandam consistência e robustez. Essa seleção permite concentrar os esforços de análise nas configurações que efetivamente demonstraram potencial para aplicação industrial, descartando aquelas que não atenderam aos requisitos mínimos de desempenho.

A Figura 22 apresenta um conjunto de gráficos de dispersão que comparam os valores reais com os valores preditos por diferentes modelos de regressão aplicados ao conjunto de dados. Cada subgráfico corresponde a um modelo específico, incluindo Regressão Linear, Ridge, Lasso e diversas configurações de Redes Neurais Artificiais (RNA).

Em todos os gráficos, o eixo x representa os valores reais observados, enquanto o eixo y representa os valores preditos pelos modelos. A linha tracejada vermelha indica a linha de perfeita predição (ou seja, onde os valores

preditos seriam exatamente iguais aos reais). Quanto mais próximos os pontos estiverem dessa linha, melhor o desempenho do modelo.

Observa-se que os modelos baseados em RNA, especialmente aqueles com função de ativação ReLU, apresentam maior concentração de pontos ao longo da linha de referência, indicando maior precisão preditiva. Em contraste, os modelos lineares (Regressão Linear, Ridge e Lasso) demonstram maior dispersão, sugerindo menor capacidade de capturar a complexidade dos dados.

Essa visualização reforça os resultados quantitativos apresentados anteriormente, evidenciando a superioridade das arquiteturas de RNA com ReLU em relação aos demais modelos testados.

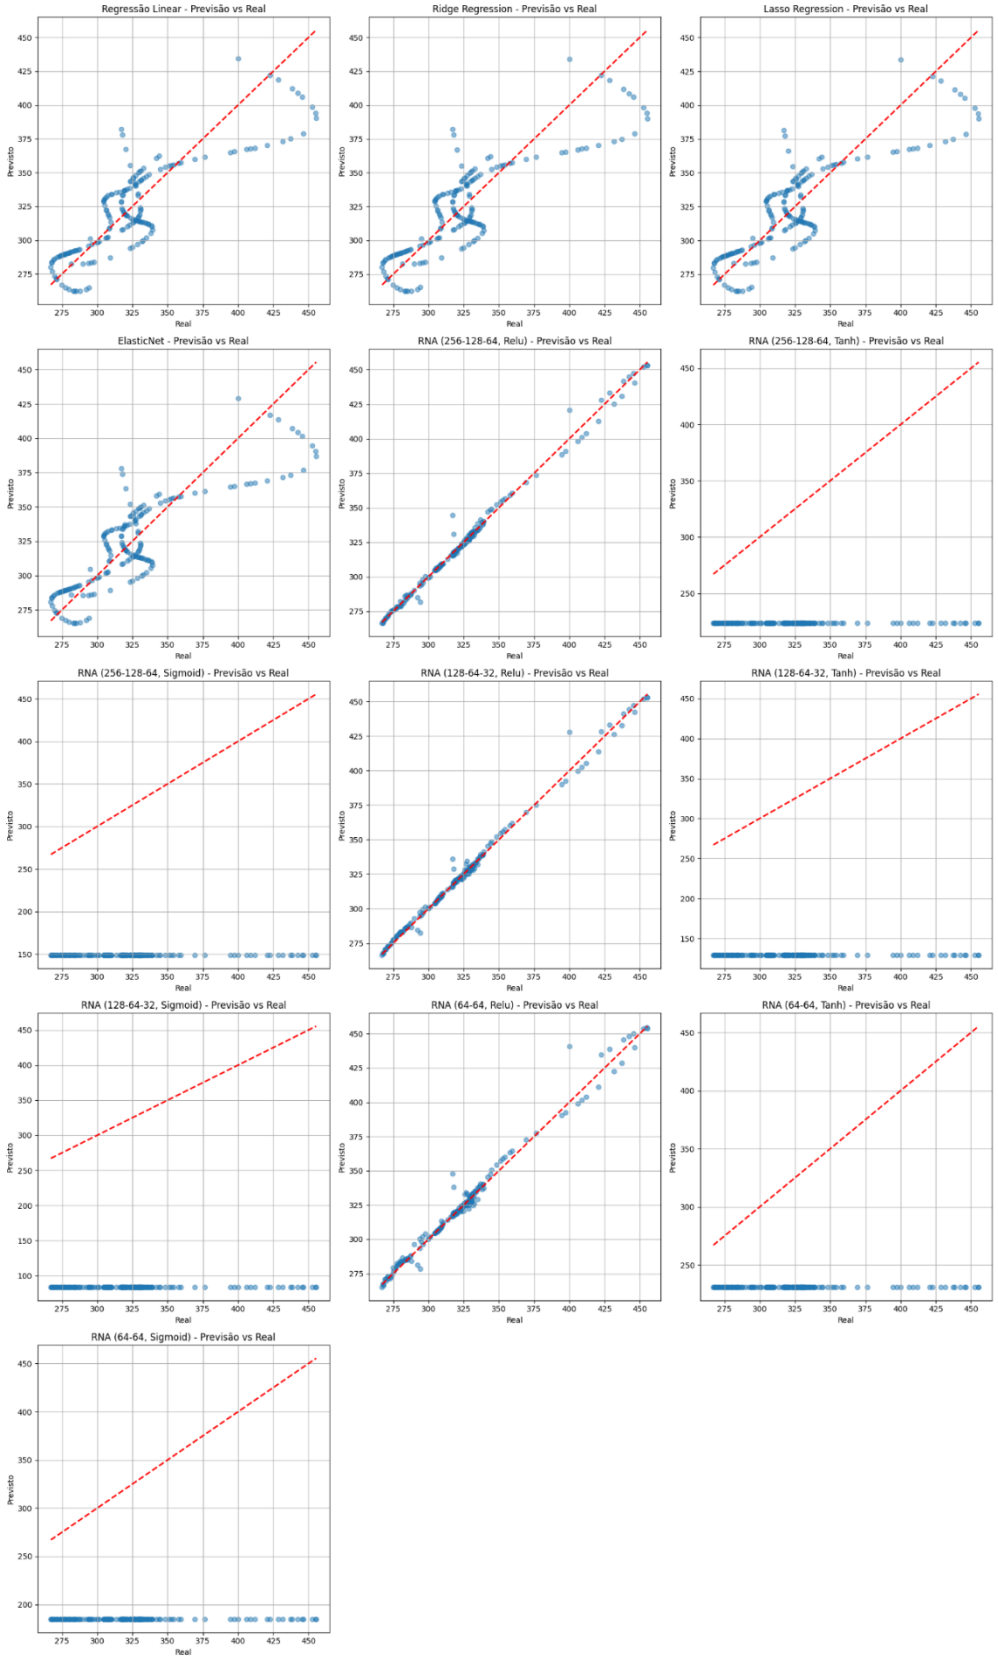


Figura 22 Comparação multivariada entre as arquiteturas 128-64-32, 256-128-64 e 64-64.

A fim de aprofundar a análise, foi realizada uma investigação sobre a distribuição dos erros de previsão (erro = valor_real − valor_previsto) para apenas para as arquiteturas 256-128-64 e 128-64-32 com função de ativação ReLU. A Figura 23 mostra o histograma dessa distribuição, sobreposto por uma curva de densidade (KDE). A visualização permite verificar a simetria da distribuição e sua centralização em torno de zero. Uma distribuição simétrica e centrada próxima de zero é indicativa de ausência de viés sistemático no modelo, ou seja, a RNA não tende a superestimar nem subestimar as previsões de forma consistente.

Ao examinar detalhadamente as tabelas de frequência de erros das duas principais arquiteturas de RNA, observa-se que a configuração 128-64-32 com função de ativação ReLU apresenta vantagens significativas em relação à arquitetura 256-128-64, também utilizando ReLU. A análise da distribuição dos erros revela padrões importantes sobre o comportamento preditivo de cada modelo.

A arquitetura 128-64-32 demonstrou uma concentração mais efetiva dos erros nas faixas de maior precisão, com 92,7% das previsões situando-se entre -5 e +5 HV de diferença em relação aos valores reais. Esse desempenho supera ligeiramente os 91,57% alcançados pela arquitetura 256-128-64 na mesma faixa de tolerância. A diferença de 1,13 ponto percentual, embora aparentemente pequena, torna-se relevante quando considerada a escala industrial de aplicação desses modelos.

Um aspecto particularmente notável diz respeito à distribuição dos erros dentro dessa faixa ótima. A configuração 128-64-32 apresentou 59,55% de seus erros na subfaixa de -5 a 0 HV, contra 38,76% da arquitetura maior, indicando uma precisão ainda mais apurada para uma parcela significativa das previsões. Essa característica é especialmente valiosa em contextos em que subestimativas controladas podem ser preferíveis a superestimativas.

A análise da tendência dos erros revela outro diferencial importante: enquanto a 128-64-32 mantém um equilíbrio razoável entre erros positivos e negativos (59,55% versus 33,15%), a arquitetura 256-128-64 apresenta um viés positivo mais acentuado, com 52,81% de erros positivos contra 38,76% de negativos. Esse desequilíbrio sugere uma tendência sistemática da arquitetura

maior em superestimar os valores de dureza, o que pode ter implicações práticas no processo de tomada de decisão.

No que concerne aos erros mais significativos (*outliers*), ambas as arquiteturas mostraram comportamento similar para valores extremos (acima de 10 HV ou abaixo de -10 HV), porém a 128-64-32 registrou apenas 3,37% de ocorrências nessa categoria, contra 6,74% da 256-128-64. Essa redução pela metade na frequência de erros graves reforça a robustez da arquitetura menor.

A consistência superior da configuração 128-64-32 manifesta-se também na melhor distribuição geral dos erros. O fato de concentrar quase 60% de suas previsões na faixa de -5 a 0 HV, comparado aos cerca de 39% da arquitetura maior, compensa amplamente sua performance ligeiramente inferior na faixa de 0 a +5 HV. Esse padrão sugere um melhor equilíbrio entre viés e variância, resultando em previsões mais confiáveis.

Considerando todos esses aspectos em conjunto: maior precisão global, melhor distribuição dos erros, menor ocorrência de outliers e equilíbrio mais adequado entre viés e variância, conclui-se que a RNA (128-64-32, ReLU) representa a melhor escolha para esta aplicação específica. Seu desempenho superior, combinado com uma provável menor demanda computacional em relação à arquitetura 256-128-64, posiciona-a como a opção mais equilibrada e eficiente para a previsão de dureza em materiais metálicos.

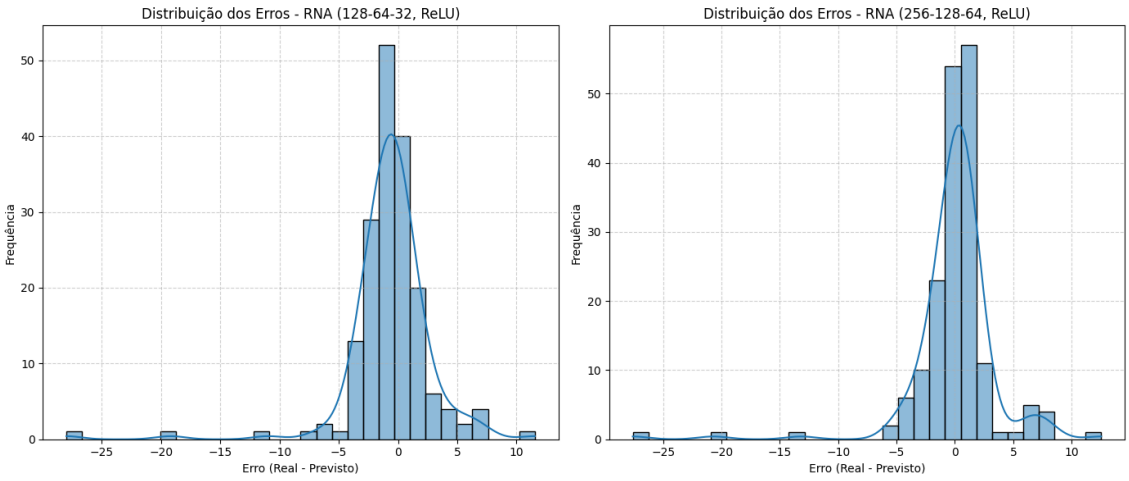


Figura 23 Histograma da distribuição dos erros, sobreposto a uma curva de densidade (KDE).

Para uma avaliação mais precisa do desempenho preditivo, os erros foram classificados em faixas específicas, conforme apresentado na Tabela 16. A RNA (128-64-32, ReLU) demonstrou uma distribuição de erros altamente concentrada, com 59,55% das previsões (106 ocorrências) situadas na faixa de -5 a 0 HV e 33,15% (59 ocorrências) entre 0 e +5 HV, totalizando 92,7% dos casos (165 de 178) com erros contidos dentro de uma margem de ±5 HV. Esse padrão revela não apenas uma alta precisão global, mas também uma tendência equilibrada entre subestimativas e superestimativas controladas.

Por outro lado, a RNA (256-128-64, ReLU) apresentou uma distribuição ligeiramente diferente, com 38,76% dos erros (69 ocorrências) na faixa de -5 a 0 HV e 52,81% (94 ocorrências) entre 0 e +5 HV, somando 91,57% das previsões (163 de 178) na mesma margem de ±5 HV. Embora essa arquitetura também atinja um desempenho elevado, sua maior concentração de erros na faixa positiva (0 a +5 HV) sugere uma tendência discreta à superestimação, em contraste com o comportamento mais equilibrado da configuração 128-64-32.

A comparação direta entre as duas arquiteturas evidencia que, enquanto ambas mantêm mais de 90% dos erros dentro de uma faixa tolerável de ±5 HV, a versão 128-64-32 se destaca pela maior proporção de previsões na faixa de -5 a 0 HV (59.55% contra 38,76%), indicando uma precisão ainda mais refinada para valores subestimados. Essa característica pode ser particularmente vantajosa em contextos industriais onde erros conservadores são preferíveis, assegurando maior segurança nas decisões baseadas nos resultados do modelo.

Além disso, a análise revela que a ocorrência de *outliers* (erros entre ±10 HV) é minimizada em ambas as configurações, com a 128-64-32 registrando apenas 3,37% de casos nessa categoria, contra 6,74% na 256-128-64. Essa diferença, embora modesta, reforça a robustez da arquitetura menor, que não apenas apresenta maior precisão nas faixas centrais, mas também reduz a frequência de erros mais significativos.

Em síntese, os resultados por faixa de erro confirmam a superioridade da RNA (128-64-32, ReLU), que combina alta precisão, distribuição equilibrada de erros e menor incidência de outliers, consolidando-se como a opção mais confiável para aplicações práticas na previsão de dureza de materiais metálicos. A versão 256-128-64, embora competitiva, mostra-se ligeiramente menos

consistente, especialmente no que diz respeito à tendência de superestimação e à frequência de erros extremos.

Tabela 16 Quantidade de valores encontrados por Grandeza de erro.

Grandeza do erro [HV]	RNA (128-64-32, ReLU)		RNA (256-128-64, ReLU)	
	Contagem	Frequência (%)	Contagem	Frequência (%)
-30.00 a < -25.00	1	0,56	1	0,56
-25.00 a < -20.00	0	0,00	1	0,56
-20.00 a < -15.00	1	0,56	0	0,00
-15.00 a < -10.00	1	0,56	1	0,56
-10.00 a < -5.00	3	1,69	1	0,56
-5.00 a < 0.00	106	59,55	69	38,76
0.00 a < 5.00	59	33,15	94	52,81
5.00 a < 10.00	6	3,37	10	5,62
10.00 a < 15.00	1	0,56	1	0,56
Total	178	100	178	100

A escassez de erros nas faixas extremas (< -10 e > 10 HV) e a inexistência de *outliers* significativos reforçam a robustez e confiabilidade do modelo. Casos pontuais com erro superior a 5 HV podem estar associados a variabilidade residual não capturada ou a ruídos nos dados, sendo recomendada análise futura desses pontos para avaliar possíveis melhorias de arquitetura ou de qualidade dos dados.

4.4 Outras modelagens e abordagens

Além da Rede Neural Artificial (RNA), outras abordagens foram exploradas com o objetivo de avaliar diferentes estratégias de modelagem e comparar seus desempenhos na previsão da dureza. A adoção de métodos distintos permite analisar não apenas a precisão das previsões, mas também aspectos como interpretabilidade, custo computacional e robustez frente à variabilidade dos dados. Entre as técnicas selecionadas, destacam-se as Máquinas de Vetores de Suporte (SVM) e a Floresta Aleatória (RF), ambas amplamente utilizadas em problemas de regressão na área metalúrgica. A seguir, são apresentadas as configurações, resultados e análises dessas abordagens, evidenciando suas vantagens e limitações em relação à RNA.

4.4.1 Modelagem com Máquinas de Vetores de Suporte (SVM)

Para fins comparativos com a Rede Neural Artificial (RNA), foi implementado um modelo de regressão utilizando o algoritmo de Máquinas de Vetores de Suporte (*Support Vector Machine* – SVM). A configuração adotada utilizou um núcleo do tipo radial (*Radial Basis Function* – RBF), cuja principal vantagem reside na capacidade de mapear relações não lineares entre as variáveis de entrada e a variável de saída, projetando os dados em um espaço de maior dimensionalidade. Essa abordagem é particularmente eficaz para capturar padrões mais complexos, como aqueles observados no comportamento da dureza em função de parâmetros operacionais de conformação.

Durante o processo de modelagem, os hiperparâmetros do SVM foram definidos como C igual a 100 e γ (gamma) igual a 0,1. O parâmetro C exerce influência direta sobre o equilíbrio entre a minimização do erro de treinamento e a maximização da margem de separação entre os dados, enquanto o parâmetro γ regula a influência de cada amostra de treinamento na construção da função de decisão. A escolha desses valores foi baseada em testes exploratórios preliminares, buscando-se um compromisso adequado entre complexidade do modelo e capacidade de generalização.

O treinamento foi realizado sobre o conjunto de dados normalizado, previamente dividido em subconjuntos de treino e validação. Após o ajuste, o modelo foi aplicado ao conjunto de validação para prever os valores de dureza. As métricas de desempenho indicaram um Erro Absoluto Médio (MAE) de aproximadamente 2,89 HV, um Erro Quadrático Médio (MSE) de 27,29 HV^2 e um coeficiente de determinação (R^2) de 0,984. Tais valores demonstram que o modelo foi capaz de capturar com relativa precisão as relações presentes nos dados, explicando cerca de 98,4% da variabilidade nos valores de dureza.

Embora esses resultados sejam satisfatórios e demonstrem um bom ajuste do modelo, observa-se que o desempenho é inferior ao alcançado pela RNA. O valor mais elevado de MAE indica uma maior média de desvios absolutos entre os valores previstos e os valores reais, enquanto o MSE aponta uma sensibilidade considerável a erros extremos. Isso sugere que, apesar de eficiente, o modelo SVM apresentou maior dispersão nos erros, podendo ter dificuldades em captar nuances específicas dos dados.

Ainda assim, o modelo SVM se mostra competitivo, sobretudo por sua estrutura relativamente simples e seu desempenho robusto mesmo com menos ajustes e menor tempo de treinamento em comparação com redes neurais profundas. Essa característica torna o SVM uma alternativa viável para cenários onde o compromisso entre precisão e eficiência computacional seja desejável, principalmente em aplicações industriais de rotina ou com restrições computacionais.

4.4.2 Modelagem com Floresta Aleatória (RF)

A terceira abordagem empregada para modelagem da dureza baseou-se no algoritmo de Floresta Aleatória (*Random Forest* – RF), uma técnica de aprendizado supervisionado do tipo ensemble, composta por múltiplas árvores de decisão. O modelo foi implementado com 100 estimadores e uma semente aleatória igual a 42, assegurando reprodutibilidade nos experimentos. A RF é reconhecida por sua robustez frente a ruídos nos dados, pela baixa suscetibilidade ao sobre ajuste e pela facilidade de interpretação dos resultados.

Assim como nos modelos anteriores, os dados foram previamente normalizados antes do treinamento. Após o ajuste da floresta, foram realizadas previsões sobre o conjunto de validação, sendo obtidos os seguintes resultados: Erro Absoluto Médio (MAE) de aproximadamente 1,65 HV, Erro Quadrático Médio (MSE) de 34,93 HV^2 e um coeficiente de determinação (R^2) de 0,980. Esses valores indicam que a RF foi capaz de explicar 98% da variabilidade nos valores de dureza, com um erro médio relativamente baixo.

A comparação direta com a RNA revela que, embora a RF tenha apresentado um desempenho sólido, seu ajuste foi inferior, sobretudo em termos de MSE, que foi o maior entre os três modelos testados. Isso pode ser atribuído à natureza das árvores de decisão, que têm dificuldade em extrapolar com precisão para valores fora dos padrões de treinamento, o que pode gerar maior sensibilidade a outliers ou a variações abruptas.

Por outro lado, a performance do modelo em termos de MAE foi superior à do SVM, o que revela uma maior consistência nas previsões ponto a ponto. Além disso, a RF oferece vantagens importantes relacionadas à

interpretabilidade. É possível, por exemplo, extrair a importância relativa de cada variável de entrada para a predição, o que pode ser valioso para entender o impacto individual de parâmetros operacionais sobre a dureza final. Essa característica torna a RF uma ferramenta estratégica em ambientes industriais que demandam não apenas precisão preditiva, mas também transparência na tomada de decisão.

Portanto, embora a RNA tenha se destacado como o modelo de melhor desempenho geral, a Floresta Aleatória demonstrou ser uma alternativa robusta e eficiente. Sua capacidade de operar bem em diferentes condições, aliada à facilidade de interpretação dos resultados, torna esse modelo especialmente útil em aplicações práticas que exigem confiabilidade e rastreabilidade, como a otimização de processos de conformação metálica.

4.5 Análise Comparativa dos Modelos Preditivos

Com o objetivo de avaliar de forma abrangente o desempenho dos modelos desenvolvidos — Rede Neural Artificial (RNA), Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF) — foram analisadas as métricas obtidas na fase de validação, conforme apresentado na Tabela 17 de ranking comparativo. Os resultados demonstraram uma nítida superioridade das arquiteturas de RNA com função de ativação ReLU, em particular a configuração 128-64-32 que alcançou MAE = 2,099 HV, MSE = 13,236 HV² e R^2 = 0,992, seguida de perto pela arquitetura 256-128-64 com MAE = 1,931 HV, MSE = 13,678 HV² e R^2 = 0,992.

A arquitetura RNA (128-64-32, ReLU) obteve a primeira posição no ranking com R^2 de 0,992426, ligeiramente superior ao R^2 de 0,992173 alcançado pela RNA (256-128-64, ReLU), que ficou em segundo lugar. Essa diferença, embora pequena, pode ser explicada por três fatores principais. Em primeiro lugar, a arquitetura 128-64-32 demonstrou melhor capacidade de generalização, possivelmente por encontrar um equilíbrio ideal entre complexidade e capacidade preditiva. Enquanto a arquitetura maior (256-128-64) apresentou um MAE ligeiramente menor (1,930586 contra 2,098541), sua maior complexidade pode ter levado a uma pequena perda de generalização, refletida no R^2. Em

segundo lugar, a estrutura em forma de funil mais acentuada da 128-64-32 (redução de 128 para 64 para 32 neurônios) pode ter criado um processo mais eficiente de extração hierárquica de características. Essa progressão mais gradual parece ter sido mais eficaz para capturar as relações não-lineares específicas deste problema do que a redução mais abrupta da arquitetura 256-128-64. Por fim, a performance superior da 128-64-32 no R^2, mesmo com MAE ligeiramente maior, sugere que esta arquitetura conseguiu distribuir seus erros de forma mais equilibrada ao longo do conjunto de dados. A arquitetura 256-128-64, embora tenha cometido erros absolutos menores em média, pode ter tido um desempenho menos consistente em algumas regiões específicas do espaço de características, resultando em um R^2 um pouco inferior. Esta análise revela que, para este problema específico, o aumento da complexidade da arquitetura além de certos limites não se traduziu necessariamente em melhorias significativas no poder explicativo global do modelo (R^2), embora tenha proporcionado reduções marginais no erro absoluto médio (MAE). O resultado reforça a importância de buscar arquiteturas que equilibrem adequadamente capacidade preditiva e generalização.

A análise quantitativa revelou que a RNA 128-64-32 (ReLU) apresentou o melhor equilíbrio entre precisão e generalização, superando inclusive modelos lineares como ElasticNet (MAE = 17,260 HV, R^2 = 0,719) e Lasso Regression (MAE = 17,419 HV, R^2 = 0,717). Quando comparada com outras técnicas de machine learning, a RNA mostrou desempenho significativamente superior à Floresta Aleatória, que registrou MAE = 1,650 HV e R^2 = 0,980, e à SVM com MAE = 2,890 HV e R^2 = 0,984.

Tabela 17 Comparativo do desempenho dos modelos desenvolvidos.

#	Modelo	Tipo	Arquitetura	Ativação	MAE	MSE	R^2
1	RNA	Rede Neural	256-128-64	ReLU	1,930	13,678	0,992
2	RNA	Rede Neural	128-64-32	ReLU	2,098	13,235	0,992
3	RNA	Rede Neural	64-64	ReLU	3,018	30,436	0,982
4	SVM	Máquina de Vetores	-	-	2,890	27,286	0,984
5	RF	Floresta Aleatória	-	-	1,653	34,929	0,980
6	ElasticNet	Regressão Linear	-	-	17,259	491,729	0,718
7	Lasso Regression	Regressão Linear	-	-	17,419	494,402	0,717
8	Ridge Regression	Regressão Linear	-	-	17,439	495,859	0,716
9	Regressão Linear	Regressão Linear	-	-	17,457	496,444	0,715
10	RNA	Rede Neural	64-64	Tanh	93,302	10452,913	-4,981
11	RNA	Rede Neural	256-128-64	Tanh	100,647	11877,542	-5,796
12	RNA	Rede Neural	64-64	Sigmoid	139,458	21196,295	-11,128
13	RNA	Rede Neural	128-64-32	Tanh	195,054	39793,697	-21,770
14	RNA	Rede Neural	256-128-64	Sigmoid	175,490	32544,637	-17,622
15	RNA	Rede Neural	128-64-32	Sigmoid	240,791	59728,212	-33,177

Os gráficos construídos a partir desses resultados (Figura 24) destacam três aspectos principais: primeiro, a consistência das RNAs com ativação ReLU em todas as métricas avaliadas; segundo, a vantagem marginal da arquitetura 128-64-32 sobre a 256-128-64 no coeficiente R^2 (0.9924 versus 0,9921), apesar de apresentar MAE ligeiramente maior; e terceiro, os problemas de convergência das configurações com funções Tanh e Sigmoid, que resultaram em R^2 negativos (variando entre -4,981 e -33,177), claramente visíveis nas representações gráficas.

Esta análise integrada entre tabelas classificatórias e representações visuais permitiu concluir que, para o problema específico de previsão de dureza em materiais metálicos, as arquiteturas de RNA com ReLU oferecem o melhor compromisso entre desempenho preditivo e robustez computacional, com

destaque para a configuração 256-128-64 que combinou alta precisão (MAE = 1,930 HV) com excelente capacidade explicativa (R^2 = 0,992).

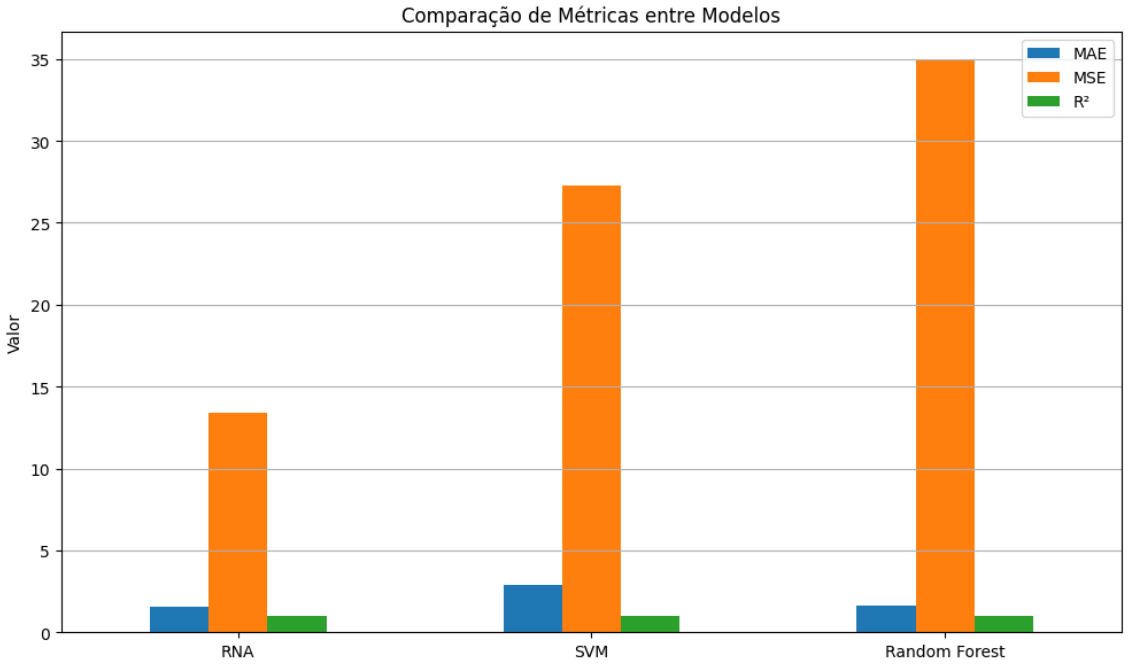


Figura 24 Comparação de resultados entre os modelos.

4.6 Análise da correlação entre valores reais e previstos

Para avaliar a precisão das previsões em relação aos valores reais, foi elaborado um gráfico de dispersão onde se observam os pares de valores reais e previstos para cada modelo (Figura 25). Os pontos correspondentes à RNA se alinharam de maneira mais próxima à linha ideal (y = x), demonstrando maior fidelidade na estimativa da dureza. As distribuições da SVM e da RF também mostraram correlação visual com a linha de referência, embora com maior dispersão, especialmente em amostras com valores extremos de dureza.

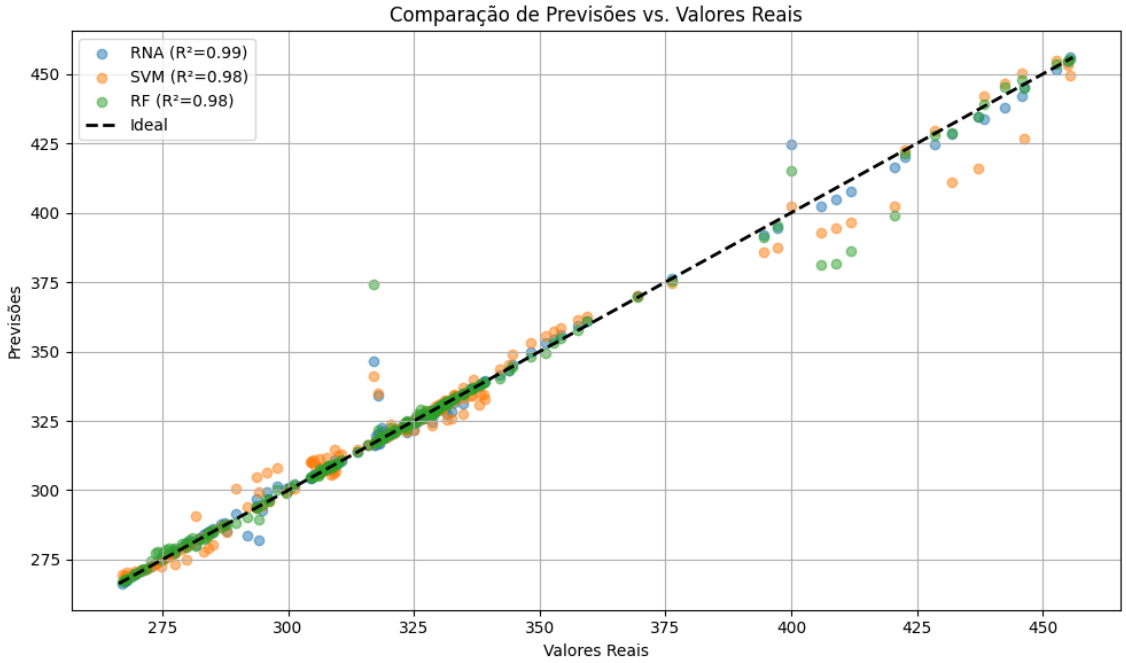


Figura 25 Comparação entre pares de valores reais e previstos para cada modelo.

A análise dos erros absolutos por amostra apresentado na Figura 26 trouxe insights adicionais sobre o comportamento dos modelos. Um gráfico de linha traçando o erro absoluto ao longo das amostras de validação mostrou que a RNA manteve os menores níveis de erro de forma consistente, enquanto SVM e RF apresentaram variações mais pronunciadas.

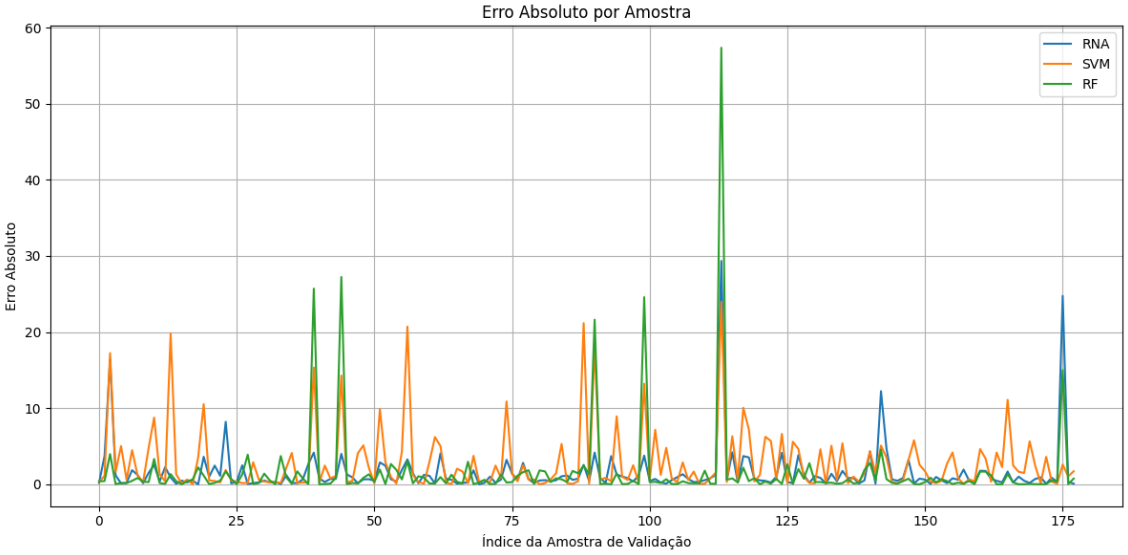


Figura 26 Erro absoluto ao longo das amostras.

Essa avaliação foi reforçada por boxplots (Figura 27) e violin plots (Figura 28), os quais revelaram que os erros da RNA se concentraram em faixas mais

estreitas, com menor presença de outliers, ao passo que os modelos SVM e RF exibiram caudas mais longas e distribuição assimétrica.

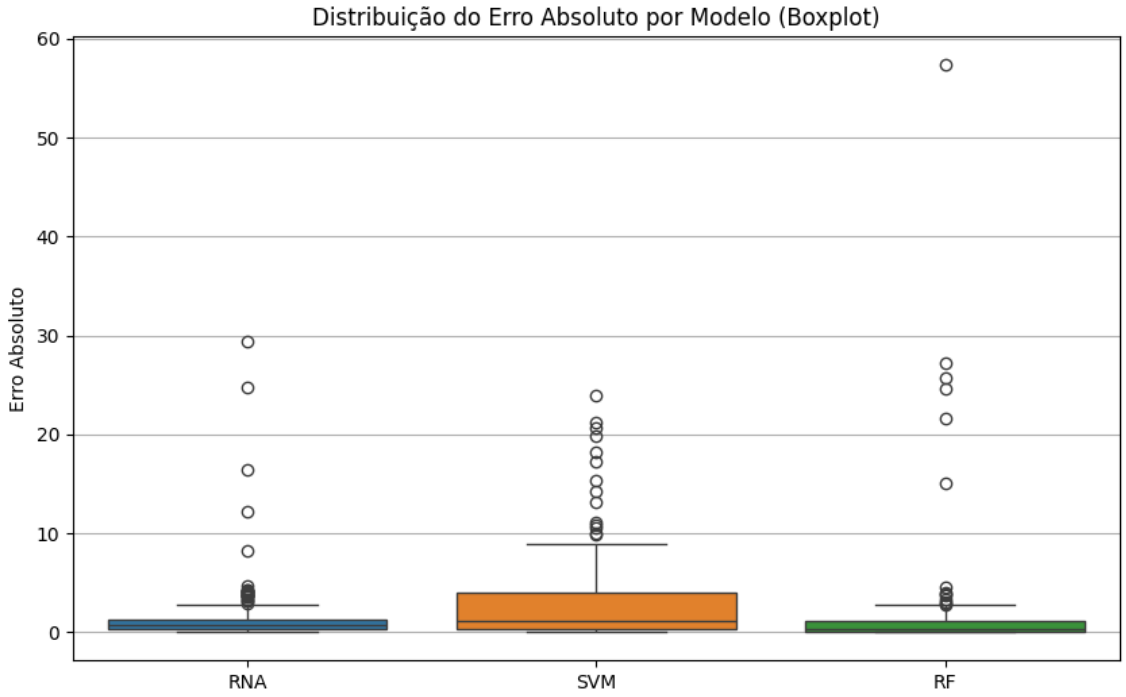


Figura 27 Erro absoluto ao longo das amostras – Boxplots.

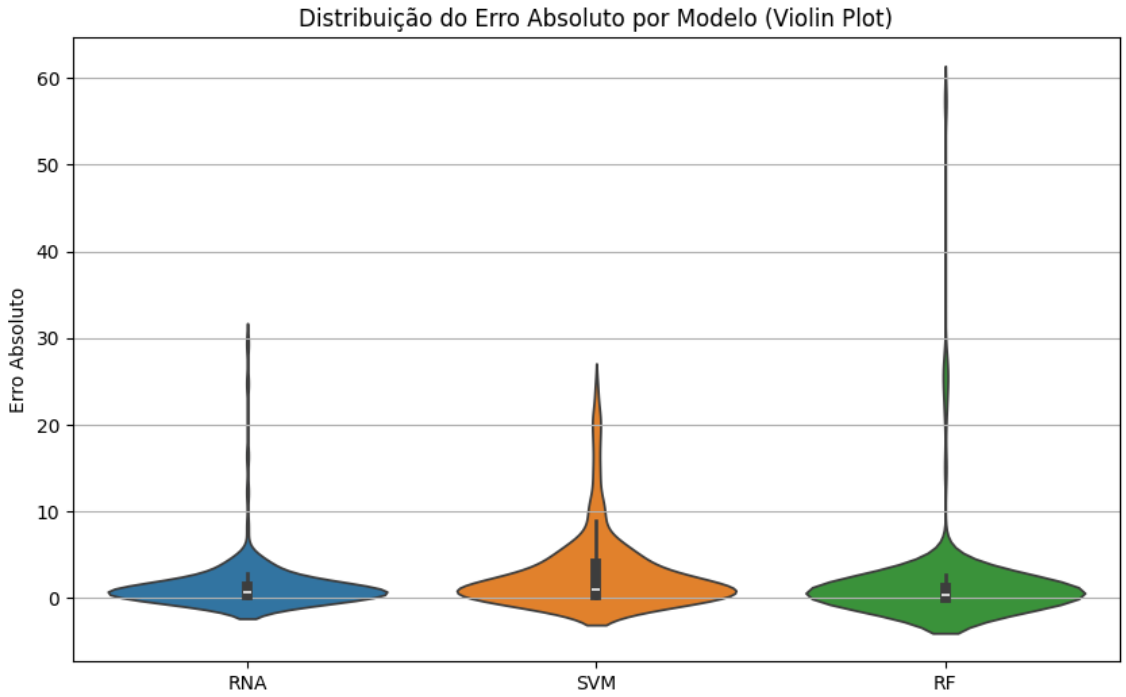


Figura 28 Erro absoluto ao longo das amostras - Violin plots

Adicionalmente, um mapa de calor (heatmap) foi gerado para representar a magnitude do erro absoluto por amostra e por modelo. Essa visualização confirmou que, na maioria das amostras, a RNA apresentou os menores erros, enquanto a SVM mostrou desempenho mais irregular, com picos localizados de erro acentuado conforme Figura 29.

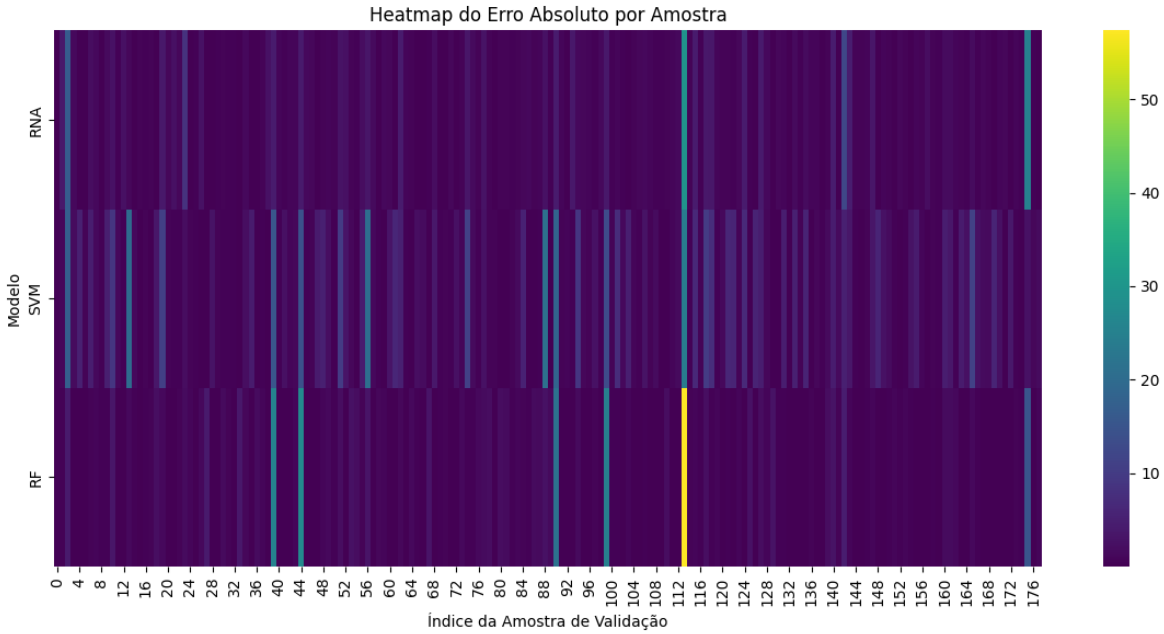


Figura 29 Erro absoluto ao longo das amostras – Heatmap.

A partir dos dados de treinamento da RNA, também foi possível analisar a evolução do erro ao longo das épocas. Os gráficos de MAE e MSE mostraram que a rede neural convergiu rapidamente para valores baixos de erro, tanto no conjunto de treinamento quanto no de validação. Isso indica um bom equilíbrio entre ajuste e generalização, sem indícios de sobre ajuste (*overfitting*).

4.7 Análise dos Testes de inferência

Por fim, foi realizada uma inferência com novos dados experimentais para verificar o desempenho prático dos modelos treinados. Segundo dados contidos na Tabela 18 os resultados de previsão da RNA se mostraram novamente mais próximos dos valores esperados, seguidos pelos da RF e, por último, da SVM. Uma tabela resumo das previsões foi construída com as respectivas variáveis de

entrada e os valores previstos por cada modelo, servindo como validação externa da capacidade de generalização dos algoritmos.

Tabela 18 Resultados após teste de inferência.

Deformação	Velocidade de Deformação	Temp Inicial	Temp Final	Dureza medida (HV0.5)	Previsto RNA	Previsto SVM	Previsto RF
0,70	0,15	1200	420	300,4	299,70	340,28	274,26
0,80	0,20	1100	480	365,4	366,65	363,90	380,86
0,60	0,10	1000	380	347,6	348,06	341,10	283,88

Em conjunto, as análises apresentadas neste capítulo consolidam a RNA como a abordagem preditiva mais robusta e confiável entre os modelos testados, especialmente em tarefas envolvendo a previsão de propriedades mecânicas como a dureza. A combinação de métricas de desempenho, visualizações gráficas e inferência prática na biela forjada corrobora a eficácia da rede neural, destacando seu potencial para aplicações industriais em processos de conformação a quente.

5 CONCLUSÕES

Este trabalho teve como objetivo investigar técnicas de modelagem para a previsão da dureza de componentes forjados a quente. O processo analisado consiste no forjamento a quente do aço comercial Hardox 450®, seguido de resfriamento contínuo ao ar, resultando na formação de uma microestrutura predominantemente bainítica, cujas propriedades mecânicas são altamente sensíveis às condições de processamento. Os parâmetros termomecânicos do processo, tais como deformação, temperaturas e velocidades de deformação, foram empregados como variáveis de entrada nos modelos de predição da dureza dos forjados.

Para a construção de um banco de dados robusto e representativo, foram realizados ensaios de cunha sob diferentes condições de processamento, permitindo a obtenção de cenários termomecânicos diversificados. A partir de uma abordagem numérico-experimental, estabeleceram-se relações quantitativas entre os campos de deformação, históricos térmicos, velocidades de deformação e a dureza final do material.

Inicialmente, avaliou-se a aplicação de modelos de regressão linear para a previsão da dureza dos forjados. Essa abordagem estatística clássica, amplamente empregada devido à sua simplicidade e interpretabilidade, mostrou-se limitada frente à complexidade do problema em estudo. O melhor desempenho entre os modelos lineares avaliados foi obtido com o ElasticNet, que apresentou um coeficiente de determinação (R^2) de 0,719 e um erro absoluto médio (MAE) de 17,26 HV. Do ponto de vista metalúrgico e industrial, tais métricas indicam desempenho insatisfatório, uma vez que um R^2 nessa faixa implica que aproximadamente 30% da variabilidade da dureza permanece não explicada pelo modelo. Ademais, um erro médio superior a 17 HV compromete a confiabilidade da predição para aplicações industriais, nas quais o controle preciso das propriedades mecânicas é essencial. Esses resultados evidenciam que os modelos lineares são incapazes de representar adequadamente as interações altamente não lineares entre os parâmetros termomecânicos do processo e a dureza final do material, o que torna necessária a adoção de técnicas mais avançadas de aprendizado de máquina.

Diante desse cenário, optou-se por investigar abordagens mais avançadas de aprendizado de máquina, com o objetivo de aumentar a acurácia preditiva e a robustez dos modelos. A investigação concentrou-se em três técnicas consolidadas e amplamente utilizadas: Redes Neurais Artificiais (RNA), Máquinas de Vetores de Suporte (SVM) e Floresta Aleatória (Random Forest – RF). O banco de dados experimental, construído a partir de ensaios de cunha, foi dividido em 70% para treinamento e 30% para validação, e o desempenho dos modelos foi avaliado por meio de métricas estatísticas como o coeficiente de determinação (R^2), o erro absoluto médio (MAE) e o erro quadrático médio (MSE).

A etapa de experimentação com as RNAs evidenciou um aspecto crítico com impacto decisivo no sucesso da modelagem: a escolha da função de ativação. As arquiteturas que empregaram as funções tanh e sigmoid apresentaram falha severa de convergência, resultando em valores negativos de R^2. Esse comportamento não indica apenas um ajuste inadequado, mas um desempenho inferior ao de um modelo trivial que simplesmente prevê a média dos dados experimentais. Conforme discutido nos resultados, tal comportamento é atribuído, muito provavelmente, ao fenômeno do vanishing gradient, no qual essas funções saturam e dificultam a propagação do gradiente, inviabilizando o aprendizado eficiente em redes mais profundas. Esse achado evidencia a inadequação dessas funções de ativação para o problema em estudo.

Em contraste absoluto, as arquiteturas de RNA que utilizaram a função de ativação ReLU (Rectified Linear Unit) apresentaram desempenho significativamente superior. A análise comparativa revelou um cenário altamente competitivo entre os modelos de melhor desempenho, exigindo uma avaliação criteriosa e integrada das métricas estatísticas para a seleção do modelo ótimo.

A arquitetura de RNA (256–128–64, ReLU) destacou-se como a solução mais equilibrada. Embora seu coeficiente de determinação (R^2 = 0,992) tenha sido equivalente ao obtido pela arquitetura (128–64–32, ReLU), ela apresentou um erro absoluto médio significativamente menor (MAE = 1,930 HV). A arquitetura (128–64–32, ReLU), por sua vez, alcançou o menor erro quadrático médio (MSE = 13,235 HV^2), porém com um MAE ligeiramente superior (2,098 HV). A Floresta Aleatória apresentou o menor MAE global (1,653 HV), indicando elevada precisão média; contudo, seu R^2 (0,980) e MSE (34,93 HV^2) foram

substancialmente inferiores aos das RNAs com ReLU, evidenciando menor capacidade de ajuste global e maior sensibilidade a erros extremos.

A escolha final pela arquitetura de RNA (256–128–64, ReLU) fundamenta-se no balanço entre as métricas de desempenho. Embora a arquitetura (128–64–32, ReLU) tenha apresentado um R^2 marginalmente superior (diferença da ordem de 0,0003), a arquitetura selecionada proporcionou uma redução aproximada de 8% no MAE (1,930 HV frente a 2,098 HV), refletindo maior precisão média nas previsões. Em aplicações industriais, essa redução do erro médio é considerada mais relevante do que ganhos marginais no coeficiente de determinação. Apesar do menor MAE apresentado pela RF, seu desempenho global inferior (R^2 = 0,980) compromete sua robustez como modelo preditivo. Dessa forma, a RNA (256–128–64, ReLU) representa o melhor compromisso entre ajuste global elevado e precisão média.

A elevada precisão do modelo de RNA foi validada por meio de testes de inferência realizados com dados provenientes do forjamento de bielas. Esses testes confirmaram a robustez e a aplicabilidade prática do modelo desenvolvido, demonstrando que a RNA manteve desempenho superior mesmo quando exposta a cenários distintos daqueles utilizados durante o treinamento.

O modelo proposto consolida-se, assim, como um sensor virtual capaz de complementar ou substituir medições experimentais convencionais, reduzindo custos, eliminando gargalos operacionais e possibilitando o controle do processo em tempo real. Essa capacidade de inferir a dureza com elevada precisão aproxima-se do conceito de gêmeo digital, alinhando-se às demandas de manufatura inteligente e digitalização da Indústria 4.0, com potencial significativo para ampliar a competitividade da indústria metalúrgica.

6 SUGESTÔES PARA TRABALHOS FUTUROS

Os resultados obtidos neste estudo, que culminaram na seleção do modelo de Rede Neural Artificial (RNA) com arquitetura 256-128-64 (ReLU) como a ferramenta preditiva de melhor desempenho, formam uma base sólida para a aplicação de "sensores virtuais" no forjamento de componentes de alto desempenho. O sucesso do modelo em predizer a dureza do aço Hardox450® com alta precisão (R^2 0,9921 e MAE 1,930 HV) valida a metodologia. No entanto, este sucesso também ilumina diversas oportunidades para trabalhos complementares, que podem aprimorar a robustez, a interpretabilidade e a aplicabilidade da solução.

As principais vertentes de pesquisa futura podem ser agrupadas da seguinte forma:

a. Expansão e Otimização do Modelo Preditivo

O modelo atual foi treinado com um *dataset* específico. Para que se torne uma ferramenta industrial verdadeiramente robusta, sua generalização precisa ser testada e aprimorada. Sugere-se a expansão do banco de dados para incluir novas ligas metálicas (como aços inoxidáveis, ligas de titânio ou alumínio) e uma gama mais ampla de condições de processo (diferentes taxas de resfriamento, geometrias de peça, atmosferas controladas). Paralelamente, embora a arquitetura 256-128-64 tenha se mostrado ideal neste estudo, uma otimização de hiperparâmetros mais exaustiva, usando técnicas como *Bayesian Optimization* ou Algoritmos Genéticos, poderia refinar ainda mais a topologia da rede, buscando um balanço ainda melhor entre precisão e custo computacional.

b. Integração com Modelos Físicos e IA Explicável (XAI)

Uma das principais limitações de modelos de RNA é sua natureza de "caixa preta" (*black box*). Duas áreas de pesquisa são cruciais para mitigar isso. A primeira é a aplicação de IA Explicável (XAI), utilizando técnicas como SHAP

ou LIME para investigar *quais* variáveis de entrada (temperatura inicial, deformação, etc.) têm maior impacto nas previsões do modelo 256-128-64. Isso geraria *insights* metalúrgicos valiosos. A segunda, ainda mais avançada, é a exploração de modelos híbridos, especificamente as *Physics-Informed Neural Networks* (PINNs). Esta abordagem permitiria incorporar equações constitutivas da metalurgia ou leis de conservação diretamente na função de perda da rede neural, garantindo que as previsões não sejam apenas estatisticamente corretas, mas também fisicamente plausíveis.

c. Implementação Prática, Gêmeos Digitais e Manutenção

O objetivo final da ferramenta é sua aplicação no "chão de fábrica". Para isso, é necessário estudar a implementação do modelo em tempo real, otimizando-o para execução em *edge computing* (CLPs, *gateways* industriais) e integrando-o a sistemas SCADA/MES para inferência instantânea. Este modelo se tornaria o núcleo de um Gêmeo Digital (*Digital Twin*) do processo de forjamento, permitindo simulações "o que-se" antes da produção. Além disso, um modelo implantado não é estático, é vital pesquisar o monitoramento e manutenção de modelos, implementando sistemas de detecção de *data drift* (deriva de dados) para identificar quando o processo real muda e o modelo precisa ser retreinado (aprendizado contínuo).

d. Generalização da Metodologia e Análise de Viabilidade

A metodologia validada neste trabalho pode ser estendida para além da previsão de dureza. Um caminho natural seria aplicar a mesma abordagem para a manutenção preditiva, treinando modelos para prever o desgaste de matrizes ou falhas em ferramentas com base nos mesmos dados de processo. Da mesma forma, a metodologia pode ser generalizada para outros processos de conformação, como laminação, extrusão ou estampagem.

REFERÊNCIAS BIBLIOGRÁFICAS

AGGARWAL, C. C. Neural Networks and Deep Learning. [S.l.]: Springer, 2018.

ASSIS, C. L. F.; BAZANINI, N. C.; QUEIROZ, M. C. G. P. Efeito do fresamento na microestrutura e na formação do cavaco de aços ferríticos com grãos ultrafinos. [S.l.]: Unesp, 2010.

CALLISTER, W. D.; RETHWISCH, D. G. Materials Science and Engineering: An Introduction. [S.l.]: John Wiley & Sons, 2014.

CAO, Jian et al. Artificial intelligence in metal forming. CIRP Annals, v. 73, n. 2, p. 561-587, 2024.

CHEN, L. et al. Hybrid deep learning model for simultaneous prediction of hardness and grain size in titanium alloys. Materials & Design, 2021.

CHOLLET, F. Deep Learning with Python. [S.l.]: Manning Publications, 2017.

CHOLLET, F.; ALLAIRE, J. J. Deep Learning with R. New York: Manning Publications, 2018.

CUNHA, P. H. C. P. Estudo do aço estrutural microligado S960MC. 2010. Dissertação (Mestrado em Engenharia de Minas, Metalúrgica e de Materiais) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

DANTA, L. Transformação digital e inovação. 2021.

DAVIM, J. P. Metal Cutting and Complex Modeling of Machining Processes. [S.l.]: Springer, 2011.

DOMINGOS, P. A Few Useful Things to Know about Machine Learning. Communications of the ACM, v. 55, n. 10, p. 78-87, 2012.

ESFERA BRASIL (org.). ABDI defende inovação, transformação digital e estímulos à Indústria 4.0. 2023.

FERNANDES, R. A. SmartLVEnergy: um framework para gestão energética inteligente e descentralizada de sistemas legados de baixa tensão. 2024. Dissertação (Mestrado) – Universidade Federal do Pará, Belém, 2024.

GÉRON, A. Hands-On Machine Learning with Scikit-Learn and TensorFlow. Sebastopol: O'Reilly Media, Inc., 2017.

GORNI, A. A.; SILVA, M. B. Artificial neural network model for predicting mechanical properties of hot rolled strip. Materials Research, 2009.

GORNI, Antonio Augusto; SILVA, Marcos Roberto S. da. Previsão de propriedades mecânicas de bobinas laminadas a quente através de redes neurais. Tecnologia em Metalurgia, Materiais e Mineração, v. 5, n. 4, p. 229-234, 2013.

GRAJCAR, A.; KUZIAK, R. Softening kinetics in Nb microalloyed TRIP steels with increased Mn content. Advanced Materials Research, v. 314-316, 2011.

HAWRYLUK, Marek; MRZYGŁÓD, Barbara. A durability analysis of forging tools for different operating conditions with application of a decision support system based on artificial neural networks (ANN). Eksploatacja i Niezawodność, v. 19, n. 3, p. 338-348, 2017.

HUANG, G. B. et al. Trends in extreme learning machines: A review. Neurocomputing, 2018.

INDÚSTRIA 4.0 E DIGITALIZAÇÃO DA ECONOMIA. Brasília: Confederação Nacional da Indústria (CNI), 2018.

JAMES, G. et al. An Introduction to Statistical Learning. New York: Springer, 2013.

KATAYAMA, Tsutao; AKAMATSU, Masami; TANAKA, Yoji. Construction of PC-based expert system for cold forging process design. Journal of Materials Processing Technology, v. 155, p. 1583-1589, 2004.

LI, X. et al. Deep learning architectures for microstructural prediction and property mapping in metallurgy. Computational Materials Science, 2022.

LI, X. et al. Machine Learning for Mechanical Properties Prediction. Materials Today, 2020.

LOPES, V. G. L. Machine Learning Operations, conceitos e ferramentas. 2025. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Norte, Natal, 2025.

MARQUES, A. E. et al. Machine Learning for Predicting Fracture Strain in Sheet Metal Forming. Metals, v. 12, p. 1799, 2022.

MARTINS, N. F. S. Estudo das vantagens da aplicação de metodologias, indústria 4.0, no contexto industrial. 2018.

MENDONÇA, R. S. Desenvolvimento de um roadmap sistemático para a concepção de uma arquitetura de Digital Twin aplicado a sistemas legados. 2024. Dissertação (Mestrado) – Universidade Federal do Amazonas, Manaus, 2024.

NEVES, F. O.; REGONE, W.; BUTTON, S. T. Análise numérica do comportamento termomecânico e microestrutural de um aço microligado ao V-Ti em processamento análogo ao forjamento a quente. 2002.

OHDA, R. K.; PASHA, S. Prediction of the process parameters of metal powder preform forging using artificial neural network. Journal of Materials Processing Technology, 2003.

OLIVEIRA, E. S. de; BACCI, S. C. C. Automação nos Processos Industriais: Processo de Implementação e o Papel do Gestor de Tecnologia da Informação. Revista Prospectus, 2674.

PWC. O futuro da indústria: Quebrando as barreiras e ampliando as fronteiras. 2017.

REIS, M. S. Infraestrutura de dados com capacidade analítica para monitoramento de bombas industriais utilizando IoT. 2024. Dissertação (Mestrado) – Universidade Federal de Minas Gerais, Belo Horizonte, 2024.

RODRIGUES, N. G. Arquitetura e middleware para integração dos níveis de gerenciamento industriais baseado em sistemas ciberfísicos. 2017. Dissertação (Mestrado) – Universidade Federal do Rio Grande, Rio Grande, 2017.

ROSIAK, André. Análise experimental do forjamento a quente de uma biela de alta resistência utilizando um aço baixa liga microligado endurecido por resfriamento contínuo. 2025.

SCHMELING, Murilo. Aplicação de inteligência artificial para a previsão da curva de escoamento a quente de ligas de aço. 2024.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. Neural Networks, v. 61, p. 85–117, 2015.

SILVA, F. T. de S. Inteligência Artificial aplicada no Monitoramento Online de Transformadores de Potência para Suporte à Manutenção Preditiva. [S.d.]. Dissertação (Mestrado) – Universidade de São Paulo, São Paulo, [s.d.].

SILVA, Leonária Araújo et al. Modelagem preditiva de propriedades mecânicas em concretos reforçados com fibra de aço utilizando redes neurais artificiais. Ambiente Construído, v. 22, p. 215-232, 2022.

SILVEIRA, A. C. F. Estudo para aplicação do aço bainítico de resfriamento contínuo DIN 18MNCRSIMO6-4 em forjamento a quente. 2019. Dissertação (Mestrado em Engenharia de Minas, Metalúrgica e de Materiais) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

ULEWICZ, Robert; MAZUR, Magdalena; BOKŮVKA, Otakar. Structure and mechanical properties of fine-grained steels. Periodica Polytechnica Transportation Engineering, v. 41, n. 2, p. 111-115, 2013.

VALENTE, Jonas. Sete em cada dez empresas no Brasil utilizam tecnologias digitais. 2022.

WANG, H. et al. Prediction of Vickers hardness in aluminum alloys using artificial neural networks. Journal of Materials Processing Technology, 2020.

WANG, J.; LI, Y.; ZHAO, R.; GAO, R. Physics guided neural network for machining tool wear prediction. 2020.

YAMAKAMI, W. J. Uma proposta para a flexibilização do forjamento a quente de precisão. 2003. Tese (Doutorado) – Universidade Estadual de Campinas, Campinas, 2003.

ZHANG, J. et al. Influence of neural network architecture on metallurgical property prediction. Metallurgical and Materials Transactions B, 2019.

ZONTA, T. Predictive Maintenance & Schedule (PdMS): um novo processo de fabricação que integra manutenção preditiva e programação de produção. 2022. Dissertação (Mestrado) – Universidade do Vale do Rio dos Sinos, São Leopoldo, 2022.

GLOSSÁRIO

Adam (otimizador) – Algoritmo de otimização para redes neurais que combina momento e estimativa adaptativa de variância, utilizado no treinamento das RNAs do estudo.

API (Application Programming Interface) – Interface que permite a integração entre sistemas industriais como SCADA, MES e CLPs.

Autoencoder – Rede neural utilizada para redução de dimensionalidade e extração de características latentes.

Backpropagation – Algoritmo responsável pelo cálculo dos gradientes e ajuste dos pesos nas redes neurais.

Batch size – Número de amostras processadas antes da atualização dos pesos durante o treinamento.

Big Data – Processo de coleta e análise de grandes volumes de dados industriais para fins de otimização.

Bootstrap – Método de amostragem com reposição utilizado em modelos como Random Forest.

C (SVM) – Hiperparâmetro que controla a penalização de erros no treinamento do SVM.

CLP / PLC – Controlador lógico programável usado para automação e aquisição de dados industriais.

CNN – Arquitetura de rede neural utilizada para visão computacional e análise de sinais complexos.

Computação de borda (Edge Computing) – Processamento local próximo ao equipamento para reduzir latência e dependência da nuvem.

Cross-validation – Método para avaliar a capacidade de generalização de modelos de aprendizado de máquina.

Curva KDE – Técnica de estimativa de densidade utilizada para visualizar a distribuição dos erros.

Data drift – Mudança nas distribuições de dados ao longo do tempo, exigindo retreinamento do modelo.

Data lake – Repositório para armazenamento de grandes volumes de dados brutos.

Dataset – Conjunto de dados usado para treinar, validar e testar modelos preditivos.

Digital Twin – Representação virtual de processos físicos, atualizada em tempo real.

Dropout – Técnica de regularização que desativa aleatoriamente neurônios durante o treinamento.

Early stopping – Mecanismo de parada antecipada do treinamento para evitar overfitting.

Ensemble learning – Combinação de múltiplos modelos para aumentar a robustez preditiva.

Epoch – Uma iteração completa sobre o conjunto de treinamento.

Escalonamento / Normalização – Padronização de variáveis para reduzir viés numérico.

Explainable AI (XAI) – Conjunto de técnicas que tornam o comportamento dos modelos de IA interpretável.

FCNN – Rede neural totalmente conectada aplicada ao modelo de regressão de dureza.

Feature selection – Processo de seleção das variáveis mais relevantes para o modelo.

Feedforward – Arquitetura onde os dados fluem somente no sentido entrada-saída.

Função de ativação (ReLU, Tanh, Sigmoid) – Funções que introduzem não linearidade no modelo; ReLU apresentou melhor desempenho.

Gamma (γ, SVM) – Define a influência dos pontos de treinamento no kernel RBF.

Gateway industrial – Dispositivo que conecta redes e protocolos industriais a sistemas modernos de IA.

GPU / TPU – Aceleradores utilizados no treinamento de redes neurais profundas.

Heatmap – Visualização gráfica que representa a intensidade de erros ou correlações.

Hiperparâmetros – Parâmetros definidos antes do treinamento que influenciam o comportamento do modelo.

Inferência – Processo de utilização de um modelo treinado para realizar previsões.

Interoperabilidade – Capacidade de sistemas distintos operarem de forma integrada.

IoT (Internet of Things) – Rede de dispositivos conectados que coletam e trocam dados automaticamente.

Keras – Biblioteca de alto nível para construção e treinamento de redes neurais.

Kernel (SVM) – Função que projeta dados para espaços de maior dimensionalidade.

Lasso / Ridge / ElasticNet – Técnicas de regressão com regularização L1, L2 e ambas.

Learning rate – Taxa que define o tamanho do passo na atualização dos pesos no treinamento.

LIME / SHAP – Métodos de interpretabilidade utilizados para explicar modelos complexos.

MAE – Erro absoluto médio entre valores reais e previstos.

MES – Sistema de execução da manufatura que integra processos produtivos.

MinMaxScaler – Técnica de normalização que ajusta os dados para a faixa [0,1].

Model deployment – Processo de disponibilização do modelo em ambiente produtivo.

Model retraining – Retreinamento periódico para manter a precisão do modelo frente a mudanças nos dados.

MSE – Erro quadrático médio; penaliza mais fortemente grandes desvios.

PCA – Técnica de redução de dimensionalidade através de componentes principais.

PINN – Redes neurais guiadas por conhecimento físico.

Pruning – Redução da complexidade do modelo por remoção de pesos irrelevantes.

Python – Linguagem utilizada no desenvolvimento dos modelos do estudo.

Quantization – Redução da precisão numérica para acelerar a execução de modelos.

Random Forest – Ensemble de múltiplas árvores de decisão que melhora a generalização.

ReLU – Função de ativação que evita o problema de vanishing gradient.

R^2 – Métrica que indica a proporção da variância explicada pelo modelo preditivo.

SCADA – Sistema supervisório utilizado para monitoramento e controle industrial.

Sensor virtual – Modelo preditivo que estima propriedades difíceis ou caras de medir fisicamente.

Sigmoid – Função de ativação que pode sofrer saturação e dificultar o aprendizado.

SVM – Técnica de aprendizado supervisionado baseada em margens de separação.

TensorFlow – Framework utilizado para construção e treinamento das RNAs.

Tanh – Função de ativação que retorna valores entre -1 e 1, sujeita a vanishing gradient.

Train/Validation split – Separação dos dados em conjuntos de treinamento e validação.

Underfitting – Quando o modelo é simples demais e não aprende o padrão dos dados.

Vanishing gradient – Problema que ocorre quando os gradientes se tornam muito pequenos durante o treinamento.

Violin plot – Gráfico que combina boxplot e curva de densidade para visualizar distribuições.

ANEXO I – BANCO DE DADOS

Teste cunha [#]	Deformação [φ]	Temperatura inicial [T_0]	Temperatura final [Tf]	Velocidade de deformação [φ']	Dureza [HV]
1	0,180006	1000	403,8695	1,113691	294,2
2	0,18357	1000	404,1789	1,139391	293,1
3	0,187601	1000	404,4954	1,1628	292,0
4	0,19209	1000	404,8182	1,184075	290,9
5	0,197031	1000	405,1469	1,203364	289,9
6	0,202418	1000	405,4808	1,220812	288,9
7	0,208242	1000	405,8193	1,236554	287,9
8	0,214498	1000	406,1618	1,250721	286,9
9	0,221178	1000	406,5077	1,263437	285,9
10	0,228276	1000	406,8565	1,274821	285,0
11	0,235785	1000	407,2076	1,284985	284,1
12	0,243697	1000	407,5605	1,294038	283,2
13	0,252006	1000	407,9146	1,30208	282,3
14	0,260705	1000	408,2695	1,309208	281,5
15	0,269788	1000	408,6246	1,315514	280,6
16	0,279246	1000	408,9794	1,321083	279,8
17	0,289074	1000	409,3335	1,325998	279,1
18	0,299265	1000	409,6863	1,330335	278,3
19	0,30981	1000	410,0374	1,334168	277,6
20	0,320705	1000	410,3863	1,337563	276,9
21	0,331941	1000	410,7327	1,340584	276,2
22	0,343513	1000	411,076	1,343291	275,5
23	0,355412	1000	411,4159	1,34574	274,9
24	0,367632	1000	411,7519	1,347983	274,3
25	0,380167	1000	412,0837	1,350066	273,7
26	0,393009	1000	412,4109	1,352036	273,1
27	0,406152	1000	412,733	1,353931	272,6
28	0,419588	1000	413,0498	1,355791	272,1
29	0,433311	1000	413,3609	1,357649	271,6
30	0,447313	1000	413,666	1,359537	271,1
31	0,461589	1000	413,9646	1,361482	270,7
32	0,47613	1000	414,2566	1,363511	270,3
33	0,490931	1000	414,5415	1,365645	269,9
34	0,505984	1000	414,8192	1,367904	269,5
35	0,521282	1000	415,0894	1,370306	269,2
36	0,536819	1000	415,3517	1,372867	268,9
37	0,552588	1000	415,6059	1,375597	268,6
38	0,568581	1000	415,8517	1,378509	268,3
39	0,584792	1000	416,089	1,381609	268,1
40	0,601214	1000	416,3176	1,384905	267,9

41	0,61784	1000	416,5371	1,388401	267,7
42	0,634663	1000	416,7474	1,392099	267,5
43	0,651676	1000	416,9484	1,396001	267,4
44	0,668873	1000	417,1398	1,400105	267,3
45	0,686246	1000	417,3215	1,40441	267,2
46	0,703789	1000	417,4933	1,408911	267,1
47	0,721495	1000	417,6551	1,413604	267,1
48	0,739357	1000	417,8068	1,418483	267,1
49	0,757367	1000	417,9483	1,423539	267,1
50	0,77552	1000	418,0794	1,428766	267,1
51	0,793807	1000	418,2	1,434152	267,1
52	0,812223	1000	418,3102	1,439688	267,2
53	0,830761	1000	418,4097	1,445362	267,3
54	0,849413	1000	418,4987	1,451162	267,4
55	0,868172	1000	418,5769	1,457076	267,6
56	0,887033	1000	418,6444	1,463091	267,7
57	0,905987	1000	418,7011	1,469192	267,9
58	0,925028	1000	418,7471	1,475365	268,1
59	0,94415	1000	418,7823	1,481596	268,3
60	0,963344	1000	418,8068	1,487869	268,6
61	0,982605	1000	418,8206	1,494169	268,9
62	1,001926	1000	418,8237	1,50048	269,2
63	1,021299	1000	418,8162	1,506787	269,5
64	1,040717	1000	418,7981	1,513074	269,8
65	1,060175	1000	418,7694	1,519326	270,2
66	1,079664	1000	418,7304	1,525525	270,5
67	1,099178	1000	418,681	1,531658	270,9
68	1,118711	1000	418,6214	1,537707	271,3
69	1,138255	1000	418,5517	1,543657	271,8
70	1,157803	1000	418,472	1,549494	272,2
71	1,177349	1000	418,3824	1,555202	272,7
72	1,196885	1000	418,2832	1,560767	273,2
73	1,216405	1000	418,1744	1,566173	273,7
74	1,235902	1000	418,0562	1,571409	274,2
75	1,255369	1000	417,9288	1,576459	274,7
76	1,2748	1000	417,7925	1,581311	275,2
77	1,294186	1000	417,6473	1,585952	275,8
78	1,313522	1000	417,4936	1,59037	276,4
79	1,332801	1000	417,3315	1,594555	277,0
80	1,352015	1000	417,1613	1,598494	277,6
81	1,371157	1000	416,9833	1,602178	278,2
82	1,390222	1000	416,7976	1,605597	278,9
83	1,409202	1000	416,6045	1,608743	279,5
84	1,42809	1000	416,4044	1,611607	280,2
85	1,446879	1000	416,1976	1,614181	280,8

86	1,465563	1000	415,9842	1,616459	281,5
87	1,484134	1000	415,7647	1,618435	282,2
88	1,502586	1000	415,5393	1,620104	282,9
89	1,520912	1000	415,3084	1,62146	283,7
90	1,539105	1000	415,0723	1,622501	284,4
91	1,557158	1000	414,8313	1,623223	285,1
92	1,575064	1000	414,5859	1,623624	285,9
93	1,592817	1000	414,3364	1,623703	286,6
94	1,610409	1000	414,0831	1,623459	287,4
95	1,627834	1000	413,8265	1,622893	288,2
96	1,645085	1000	413,5669	1,622006	289,0
97	1,662155	1000	413,3049	1,6208	289,8
98	1,679037	1000	413,0407	1,619277	290,5
99	1,695724	1000	412,7747	1,617441	291,3
100	1,71221	1000	412,5076	1,615296	292,2
101	1,728487	1000	412,2396	1,612847	293,0
102	1,744549	1000	411,9713	1,610101	293,8
103	1,760389	1000	411,703	1,607063	294,6
104	1,776001	1000	411,4353	1,603741	295,4
105	1,791376	1000	411,1687	1,600144	296,2
106	1,806509	1000	410,9036	1,596279	297,1
107	1,821393	1000	410,6406	1,592157	297,9
108	1,836021	1000	410,3801	1,587787	298,7
109	1,850385	1000	410,1226	1,583181	299,6
110	1,86448	1000	409,8688	1,578349	300,4
111	1,878298	1000	409,619	1,573303	301,2
112	1,891832	1000	409,3739	1,568057	302,0
113	1,905076	1000	409,134	1,562623	302,9
114	1,918023	1000	408,8998	1,557014	303,7
115	1,930666	1000	408,6719	1,551246	304,5
116	1,942999	1000	408,4509	1,545331	305,3
117	1,955014	1000	408,2374	1,539285	306,1
118	1,966704	1000	408,0319	1,533123	307,0
119	1,978064	1000	407,835	1,52686	307,8
120	1,989085	1000	407,6473	1,520512	308,6
121	1,999762	1000	407,4695	1,514096	309,4
122	2,010087	1000	407,3022	1,507626	310,1
123	2,020054	1000	407,1459	1,501119	310,9
124	2,029656	1000	407,0012	1,494591	311,7
125	2,038886	1000	406,869	1,488059	312,5
126	2,047738	1000	406,7496	1,481539	313,2
127	2,056204	1000	406,6439	1,475046	314,0
128	2,064278	1000	406,5524	1,468597	314,7
129	2,071953	1000	406,4759	1,462207	315,4
130	2,079223	1000	406,4149	1,455891	316,2

131	2,08608	1000	406,3702	1,449665	316,9
132	2,092517	1000	406,3423	1,443543	317,6
133	2,098529	1000	406,3321	1,437539	318,2
134	2,104108	1000	406,3402	1,431667	318,9
135	2,109248	1000	406,3672	1,425939	319,6
136	2,113942	1000	406,4139	1,420368	320,2
137	2,118183	1000	406,4809	1,414965	320,8
138	2,121964	1000	406,5691	1,409741	321,5
139	2,125279	1000	406,679	1,404705	322,1
140	2,128121	1000	406,8113	1,399866	322,6
141	2,130483	1000	406,9669	1,395231	323,2
142	2,132358	1000	407,1465	1,390807	323,8
143	2,133741	1000	407,3506	1,386598	324,3
144	2,134624	1000	407,5802	1,382609	324,8
145	2,135	1000	407,8358	1,378841	325,3
146	2,134863	1000	408,1184	1,375295	325,8
147	2,134206	1000	408,4285	1,371971	326,2
148	2,133022	1000	408,7669	1,368865	326,7
149	2,131305	1000	409,1344	1,365972	327,1
150	2,129048	1000	409,5317	1,363288	327,5
151	2,126245	1000	409,9596	1,360802	327,9
152	2,122888	1000	410,4188	1,358504	328,2
153	2,118972	1000	410,9101	1,356382	328,6
154	2,114489	1000	411,4343	1,35442	328,9
155	2,109433	1000	411,992	1,352601	329,2
156	2,103797	1000	412,5841	1,350903	329,4
157	2,097575	1000	413,2113	1,349306	329,7
158	2,090759	1000	413,8744	1,347781	329,9
159	2,083344	1000	414,5741	1,346302	330,1
160	2,075323	1000	415,3112	1,344836	330,3
161	2,066689	1000	416,0865	1,343348	330,4
162	2,057435	1000	416,9008	1,341801	330,5
163	2,047556	1000	417,7548	1,340153	330,6
164	2,037044	1000	418,6492	1,338359	330,7
165	2,025892	1000	419,5849	1,33637	330,8
166	2,014095	1000	420,5626	1,334135	330,8
167	2,001646	1000	421,5831	1,331596	330,8
168	1,988538	1000	422,6471	1,328693	330,7
169	1,974764	1000	423,7555	1,325363	330,7
170	1,960319	1000	424,9089	1,321536	330,6
171	1,945195	1000	426,1082	1,317138	330,4
172	1,929386	1000	427,354	1,312093	330,3
173	1,912886	1000	428,6473	1,306318	330,1
174	1,895688	1000	429,9886	1,299724	329,9
175	1,877785	1000	431,3788	1,292221	329,7

176	1,859171	1000	432,8187	1,28371	329,4
177	1,83984	1000	434,3089	1,274088	329,1
178	1,819785	1000	435,8503	1,263247	328,8
179	1,799	1000	437,4436	1,251073	328,5
180	1,777478	1000	439,0895	1,237447	328,1
181	1,755213	1000	440,7887	1,222242	327,7
182	1,732198	1000	442,5421	1,205327	327,2
183	1,708427	1000	444,3503	1,186565	326,7
184	1,683893	1000	446,2141	1,16581	326,2
185	1,65859	1000	448,1341	1,142912	325,7
186	1,632513	1000	450,1112	1,117713	325,2
187	1,605653	1000	452,146	1,090049	324,6
188	1,578005	1000	454,2392	1,059747	323,9
189	1,549563	1000	456,3916	1,02663	323,3
190	1,52032	1000	458,6038	0,990511	322,6
191	1,49027	1000	460,8765	0,951195	321,9
192	1,459407	1000	463,2105	0,908482	321,2
193	1,427723	1000	465,6065	0,862162	320,4
194	1,395214	1000	468,065	0,812017	319,6
195	1,361872	1000	470,5867	0,757821	318,7
196	1,327691	1000	473,1724	0,69934	317,9
197	1,292665	1000	475,8227	0,636331	317,0
198	0,180006	1100	430,1122177	1,113691	268,6
199	0,18357	1100	429,8722471	1,139391	270,3
200	0,187601	1100	429,7056028	1,1628	272,1
201	0,19209	1100	429,60757	1,184075	273,9
202	0,197031	1100	429,5735973	1,203364	275,7
203	0,202418	1100	429,5992937	1,220812	277,6
204	0,208242	1100	429,6804247	1,236554	279,6
205	0,214498	1100	429,81291	1,250721	281,6
206	0,221178	1100	429,9928195	1,263437	283,6
207	0,228276	1100	430,2163706	1,274821	285,6
208	0,235785	1100	430,4799249	1,284985	287,7
209	0,243697	1100	430,7799852	1,294038	289,7
210	0,252006	1100	431,1131923	1,30208	291,7
211	0,260705	1100	431,4763224	1,309208	293,8
212	0,269788	1100	431,8662833	1,315514	295,8
213	0,279246	1100	432,2801122	1,321083	297,8
214	0,289074	1100	432,7149726	1,325998	299,8
215	0,299265	1100	433,1681508	1,330335	301,8
216	0,30981	1100	433,6370541	1,334168	303,7
217	0,320705	1100	434,119207	1,337563	305,6
218	0,331941	1100	434,6122488	1,340584	307,5
219	0,343513	1100	435,113931	1,343291	309,3
220	0,355412	1100	435,6221141	1,34574	311,1

221	0,367632	1100	436,1347653	1,347983	312,8
222	0,380167	1100	436,6499556	1,350066	314,5
223	0,393009	1100	437,1658574	1,352036	316,2
224	0,406152	1100	437,6807415	1,353931	317,8
225	0,419588	1100	438,1929747	1,355791	319,3
226	0,433311	1100	438,7010176	1,357649	320,8
227	0,447313	1100	439,2034214	1,359537	322,2
228	0,461589	1100	439,6988259	1,361482	323,6
229	0,47613	1100	440,185957	1,363511	324,9
230	0,490931	1100	440,6636241	1,365645	326,2
231	0,505984	1100	441,1307179	1,367904	327,4
232	0,521282	1100	441,5862079	1,370306	328,5
233	0,536819	1100	442,0291401	1,372867	329,6
234	0,552588	1100	442,4586346	1,375597	330,6
235	0,568581	1100	442,8738839	1,378509	331,6
236	0,584792	1100	443,2741496	1,381609	332,5
237	0,601214	1100	443,6587614	1,384905	333,3
238	0,61784	1100	444,0271141	1,388401	334,1
239	0,634663	1100	444,3786657	1,392099	334,8
240	0,651676	1100	444,7129354	1,396001	335,5
241	0,668873	1100	445,0295015	1,400105	336,1
242	0,686246	1100	445,3279992	1,40441	336,7
243	0,703789	1100	445,6081187	1,408911	337,2
244	0,721495	1100	445,8696033	1,413604	337,6
245	0,739357	1100	446,1122474	1,418483	338,0
246	0,757367	1100	446,3358944	1,423539	338,3
247	0,77552	1100	446,5404353	1,428766	338,6
248	0,793807	1100	446,7258063	1,434152	338,8
249	0,812223	1100	446,8919872	1,439688	339,0
250	0,830761	1100	447,0389997	1,445362	339,2
251	0,849413	1100	447,1669056	1,451162	339,3
252	0,868172	1100	447,2758051	1,457076	339,3
253	0,887033	1100	447,365835	1,463091	339,3
254	0,905987	1100	447,437167	1,469192	339,3
255	0,925028	1100	447,4900065	1,475365	339,2
256	0,94415	1100	447,5245903	1,481596	339,1
257	0,963344	1100	447,5411857	1,487869	338,9
258	0,982605	1100	447,5400886	1,494169	338,8
259	1,001926	1100	447,5216222	1,50048	338,5
260	1,021299	1100	447,4861353	1,506787	338,3
261	1,040717	1100	447,4340009	1,513074	338,0
262	1,060175	1100	447,3656152	1,519326	337,7
263	1,079664	1100	447,2813956	1,525525	337,4
264	1,099178	1100	447,18178	1,531658	337,0
265	1,118711	1100	447,0672248	1,537707	336,6

266	1,138255	1100	446,9382044	1,543657	336,2
267	1,157803	1100	446,7952091	1,549494	335,8
268	1,177349	1100	446,6387448	1,555202	335,4
269	1,196885	1100	446,4693309	1,560767	334,9
270	1,216405	1100	446,2875001	1,566173	334,5
271	1,235902	1100	446,0937964	1,571409	334,0
272	1,255369	1100	445,8887745	1,576459	333,5
273	1,2748	1100	445,6729988	1,581311	333,0
274	1,294186	1100	445,447042	1,585952	332,5
275	1,313522	1100	445,2114846	1,59037	332,0
276	1,332801	1100	444,9669135	1,594555	331,4
277	1,352015	1100	444,7139213	1,598494	330,9
278	1,371157	1100	444,4531054	1,602178	330,4
279	1,390222	1100	444,1850671	1,605597	329,8
280	1,409202	1100	443,9104108	1,608743	329,3
281	1,42809	1100	443,629743	1,611607	328,8
282	1,446879	1100	443,3436719	1,614181	328,3
283	1,465563	1100	443,0528065	1,616459	327,7
284	1,484134	1100	442,7577557	1,618435	327,2
285	1,502586	1100	442,4591278	1,620104	326,7
286	1,520912	1100	442,1575301	1,62146	326,2
287	1,539105	1100	441,8535678	1,622501	325,7
288	1,557158	1100	441,5478437	1,623223	325,2
289	1,575064	1100	441,2409579	1,623624	324,7
290	1,592817	1100	440,9335067	1,623703	324,3
291	1,610409	1100	440,6260826	1,623459	323,8
292	1,627834	1100	440,3192736	1,622893	323,4
293	1,645085	1100	440,013663	1,622006	322,9
294	1,662155	1100	439,7098288	1,6208	322,5
295	1,679037	1100	439,4083435	1,619277	322,1
296	1,695724	1100	439,1097737	1,617441	321,7
297	1,71221	1100	438,8146797	1,615296	321,3
298	1,728487	1100	438,5236157	1,612847	321,0
299	1,744549	1100	438,2371288	1,610101	320,6
300	1,760389	1100	437,9557597	1,607063	320,3
301	1,776001	1100	437,6800418	1,603741	320,0
302	1,791376	1100	437,4105014	1,600144	319,7
303	1,806509	1100	437,1476577	1,596279	319,4
304	1,821393	1100	436,8920226	1,592157	319,1
305	1,836021	1100	436,6441003	1,587787	318,9
306	1,850385	1100	436,4043882	1,583181	318,7
307	1,86448	1100	436,1733761	1,578349	318,5
308	1,878298	1100	435,9515465	1,573303	318,3
309	1,891832	1100	435,7393749	1,568057	318,1
310	1,905076	1100	435,5373297	1,562623	317,9

311	1,918023	1100	435,3458724	1,557014	317,8
312	1,930666	1100	435,165458	1,551246	317,6
313	1,942999	1100	434,9965347	1,545331	317,5
314	1,955014	1100	434,8395448	1,539285	317,4
315	1,966704	1100	434,6949246	1,533123	317,4
316	1,978064	1100	434,5631047	1,52686	317,3
317	1,989085	1100	434,4445104	1,520512	317,2
318	1,999762	1100	434,3395624	1,514096	317,2
319	2,010087	1100	434,2486767	1,507626	317,2
320	2,020054	1100	434,1722652	1,501119	317,2
321	2,029656	1100	434,1107366	1,494591	317,2
322	2,038886	1100	434,064496	1,488059	317,2
323	2,047738	1100	434,0339466	1,481539	317,2
324	2,056204	1100	434,0194893	1,475046	317,3
325	2,064278	1100	434,0215238	1,468597	317,3
326	2,071953	1100	434,040449	1,462207	317,4
327	2,079223	1100	434,0766638	1,455891	317,5
328	2,08608	1100	434,1305679	1,449665	317,6
329	2,092517	1100	434,2025623	1,443543	317,7
330	2,098529	1100	434,2930502	1,437539	317,8
331	2,104108	1100	434,4024376	1,431667	317,9
332	2,109248	1100	434,5311345	1,425939	318,1
333	2,113942	1100	434,6795554	1,420368	318,2
334	2,118183	1100	434,8481204	1,414965	318,4
335	2,121964	1100	435,037256	1,409741	318,5
336	2,125279	1100	435,2473961	1,404705	318,7
337	2,128121	1100	435,478983	1,399866	318,9
338	2,130483	1100	435,7324685	1,395231	319,1
339	2,132358	1100	436,0083148	1,390807	319,3
340	2,133741	1100	436,3069954	1,386598	319,5
341	2,134624	1100	436,6289968	1,382609	319,7
342	2,135	1100	436,974819	1,378841	319,9
343	2,134863	1100	437,3449773	1,375295	320,2
344	2,134206	1100	437,7400028	1,371971	320,4
345	2,133022	1100	438,1604442	1,368865	320,7
346	2,131305	1100	438,606869	1,365972	320,9
347	2,129048	1100	439,0798644	1,363288	321,2
348	2,126245	1100	439,5800391	1,360802	321,5
349	2,122888	1100	440,1080246	1,358504	321,8
350	2,118972	1100	440,6644762	1,356382	322,2
351	2,114489	1100	441,250075	1,35442	322,5
352	2,109433	1100	441,8655289	1,352601	322,9
353	2,103797	1100	442,5115743	1,350903	323,3
354	2,097575	1100	443,1889777	1,349306	323,7
355	2,090759	1100	443,898537	1,347781	324,1

356	2,083344	1100	444,6410835	1,346302	324,5
357	2,075323	1100	445,417483	1,344836	325,0
358	2,066689	1100	446,2286379	1,343348	325,5
359	2,057435	1100	447,0754887	1,341801	326,1
360	2,047556	1100	447,9590156	1,340153	326,7
361	2,037044	1100	448,8802406	1,338359	327,3
362	2,025892	1100	449,8402288	1,33637	327,9
363	2,014095	1100	450,8400906	1,334135	328,6
364	2,001646	1100	451,8809835	1,331596	329,4
365	1,988538	1100	452,9641138	1,328693	330,2
366	1,974764	1100	454,0907386	1,325363	331,1
367	1,960319	1100	455,2621677	1,321536	332,0
368	1,945195	1100	456,4797657	1,317138	333,0
369	1,929386	1100	457,744954	1,312093	334,0
370	1,912886	1100	459,0592125	1,306318	335,1
371	1,895688	1100	460,4240821	1,299724	336,4
372	1,877785	1100	461,8411667	1,292221	337,7
373	1,859171	1100	463,312135	1,28371	339,0
374	1,83984	1100	464,8387231	1,274088	340,5
375	1,819785	1100	466,4227364	1,263247	342,1
376	1,799	1100	468,0660522	1,251073	343,8
377	1,777478	1100	469,7706213	1,237447	345,6
378	1,755213	1100	471,538471	1,222242	347,6
379	1,732198	1100	473,371707	1,205327	349,7
380	1,708427	1100	475,2725158	1,186565	351,9
381	1,683893	1100	477,2431673	1,16581	354,2
382	1,65859	1100	479,2860169	1,142912	356,8
383	1,632513	1100	481,4035082	1,117713	359,5
384	1,605653	1100	483,5981754	1,090049	362,4
385	1,578005	1100	485,8726459	1,059747	365,4
386	1,549563	1100	488,2296426	1,02663	368,7
387	1,52032	1100	490,6719867	0,990511	372,2
388	1,49027	1100	493,2026002	0,951195	375,9
389	1,459407	1100	495,8245088	0,908482	379,8
390	1,427723	1100	498,5408441	0,862162	384,0
391	1,395214	1100	501,3548466	0,812017	388,5
392	1,361872	1100	504,2698685	0,757821	393,2
393	1,327691	1100	507,2893763	0,69934	398,2
394	1,292665	1100	510,4169538	0,636331	403,5
395	0,180006	1200	444,5417	1,113691	249,7
396	0,18357	1200	445,3229	1,139391	256,4
397	0,187601	1200	446,1106	1,1628	262,5
398	0,19209	1200	446,9033	1,184075	268,1
399	0,197031	1200	447,6994	1,203364	273,2
400	0,202418	1200	448,4976	1,220812	277,8

401	0,208242	1200	449,2964	1,236554	282,0
402	0,214498	1200	450,0945	1,250721	285,8
403	0,221178	1200	450,8907	1,263437	289,2
404	0,228276	1200	451,6837	1,274821	292,3
405	0,235785	1200	452,4724	1,284985	295,0
406	0,243697	1200	453,2557	1,294038	297,4
407	0,252006	1200	454,0326	1,30208	299,5
408	0,260705	1200	454,8019	1,309208	301,4
409	0,269788	1200	455,5628	1,315514	303,0
410	0,279246	1200	456,3143	1,321083	304,4
411	0,289074	1200	457,0557	1,325998	305,6
412	0,299265	1200	457,786	1,330335	306,6
413	0,30981	1200	458,5045	1,334168	307,4
414	0,320705	1200	459,2104	1,337563	308,0
415	0,331941	1200	459,9031	1,340584	308,6
416	0,343513	1200	460,582	1,343291	309,0
417	0,355412	1200	461,2464	1,34574	309,2
418	0,367632	1200	461,8957	1,347983	309,4
419	0,380167	1200	462,5295	1,350066	309,5
420	0,393009	1200	463,1472	1,352036	309,5
421	0,406152	1200	463,7484	1,353931	309,4
422	0,419588	1200	464,3326	1,355791	309,3
423	0,433311	1200	464,8996	1,357649	309,1
424	0,447313	1200	465,4489	1,359537	308,9
425	0,461589	1200	465,9802	1,361482	308,7
426	0,47613	1200	466,4933	1,363511	308,4
427	0,490931	1200	466,9879	1,365645	308,1
428	0,505984	1200	467,4637	1,367904	307,8
429	0,521282	1200	467,9207	1,370306	307,5
430	0,536819	1200	468,3586	1,372867	307,2
431	0,552588	1200	468,7773	1,375597	306,8
432	0,568581	1200	469,1767	1,378509	306,5
433	0,584792	1200	469,5567	1,381609	306,2
434	0,601214	1200	469,9172	1,384905	306,0
435	0,61784	1200	470,2583	1,388401	305,7
436	0,634663	1200	470,58	1,392099	305,5
437	0,651676	1200	470,8822	1,396001	305,2
438	0,668873	1200	471,165	1,400105	305,1
439	0,686246	1200	471,4285	1,40441	304,9
440	0,703789	1200	471,6728	1,408911	304,8
441	0,721495	1200	471,8979	1,413604	304,7
442	0,739357	1200	472,1041	1,418483	304,6
443	0,757367	1200	472,2914	1,423539	304,5
444	0,77552	1200	472,46	1,428766	304,5
445	0,793807	1200	472,6101	1,434152	304,6

446	0,812223	1200	472,742	1,439688	304,6
447	0,830761	1200	472,8557	1,445362	304,7
448	0,849413	1200	472,9517	1,451162	304,8
449	0,868172	1200	473,0301	1,457076	305,0
450	0,887033	1200	473,0911	1,463091	305,2
451	0,905987	1200	473,1352	1,469192	305,4
452	0,925028	1200	473,1625	1,475365	305,7
453	0,94415	1200	473,1734	1,481596	305,9
454	0,963344	1200	473,1681	1,487869	306,2
455	0,982605	1200	473,1472	1,494169	306,6
456	1,001926	1200	473,1108	1,50048	306,9
457	1,021299	1200	473,0594	1,506787	307,3
458	1,040717	1200	472,9932	1,513074	307,7
459	1,060175	1200	472,9128	1,519326	308,1
460	1,079664	1200	472,8184	1,525525	308,6
461	1,099178	1200	472,7106	1,531658	309,0
462	1,118711	1200	472,5896	1,537707	309,5
463	1,138255	1200	472,4559	1,543657	310,0
464	1,157803	1200	472,31	1,549494	310,5
465	1,177349	1200	472,1522	1,555202	311,0
466	1,196885	1200	471,983	1,560767	311,5
467	1,216405	1200	471,8028	1,566173	312,1
468	1,235902	1200	471,6121	1,571409	312,6
469	1,255369	1200	471,4114	1,576459	313,1
470	1,2748	1200	471,2011	1,581311	313,7
471	1,294186	1200	470,9817	1,585952	314,2
472	1,313522	1200	470,7536	1,59037	314,8
473	1,332801	1200	470,5174	1,594555	315,3
474	1,352015	1200	470,2734	1,598494	315,9
475	1,371157	1200	470,0223	1,602178	316,4
476	1,390222	1200	469,7644	1,605597	317,0
477	1,409202	1200	469,5004	1,608743	317,5
478	1,42809	1200	469,2306	1,611607	318,0
479	1,446879	1200	468,9555	1,614181	318,6
480	1,465563	1200	468,6758	1,616459	319,1
481	1,484134	1200	468,3918	1,618435	319,6
482	1,502586	1200	468,1041	1,620104	320,1
483	1,520912	1200	467,8132	1,62146	320,6
484	1,539105	1200	467,5196	1,622501	321,1
485	1,557158	1200	467,2238	1,623223	321,6
486	1,575064	1200	466,9263	1,623624	322,1
487	1,592817	1200	466,6277	1,623703	322,5
488	1,610409	1200	466,3284	1,623459	323,0
489	1,627834	1200	466,0289	1,622893	323,4
490	1,645085	1200	465,7298	1,622006	323,9

491	1,662155	1200	465,4316	1,6208	324,3
492	1,679037	1200	465,1348	1,619277	324,8
493	1,695724	1200	464,8399	1,617441	325,2
494	1,71221	1200	464,5475	1,615296	325,6
495	1,728487	1200	464,258	1,612847	326,0
496	1,744549	1200	463,9719	1,610101	326,4
497	1,760389	1200	463,6898	1,607063	326,9
498	1,776001	1200	463,4122	1,603741	327,3
499	1,791376	1200	463,1396	1,600144	327,7
500	1,806509	1200	462,8725	1,596279	328,1
501	1,821393	1200	462,6115	1,592157	328,5
502	1,836021	1200	462,3569	1,587787	329,0
503	1,850385	1200	462,1095	1,583181	329,4
504	1,86448	1200	461,8696	1,578349	329,9
505	1,878298	1200	461,6378	1,573303	330,3
506	1,891832	1200	461,4145	1,568057	330,8
507	1,905076	1200	461,2004	1,562623	331,3
508	1,918023	1200	460,9959	1,557014	331,8
509	1,930666	1200	460,8015	1,551246	332,4
510	1,942999	1200	460,6177	1,545331	332,9
511	1,955014	1200	460,4451	1,539285	333,5
512	1,966704	1200	460,2842	1,533123	334,1
513	1,978064	1200	460,1354	1,52686	334,8
514	1,989085	1200	459,9993	1,520512	335,5
515	1,999762	1200	459,8764	1,514096	336,2
516	2,010087	1200	459,7672	1,507626	336,9
517	2,020054	1200	459,6722	1,501119	337,7
518	2,029656	1200	459,592	1,494591	338,5
519	2,038886	1200	459,527	1,488059	339,4
520	2,047738	1200	459,4778	1,481539	340,3
521	2,056204	1200	459,4449	1,475046	341,3
522	2,064278	1200	459,4287	1,468597	342,4
523	2,071953	1200	459,43	1,462207	343,4
524	2,079223	1200	459,4491	1,455891	344,6
525	2,08608	1200	459,4865	1,449665	345,8
526	2,092517	1200	459,5429	1,443543	347,0
527	2,098529	1200	459,6188	1,437539	348,3
528	2,104108	1200	459,7146	1,431667	349,7
529	2,109248	1200	459,831	1,425939	351,2
530	2,113942	1200	459,9684	1,420368	352,7
531	2,118183	1200	460,1275	1,414965	354,3
532	2,121964	1200	460,3087	1,409741	355,9
533	2,125279	1200	460,5127	1,404705	357,6
534	2,128121	1200	460,7399	1,399866	359,4
535	2,130483	1200	460,9911	1,395231	361,3

536	2,132358	1200	461,2666	1,390807	363,2
537	2,133741	1200	461,5672	1,386598	365,2
538	2,134624	1200	461,8934	1,382609	367,3
539	2,135	1200	462,2458	1,378841	369,5
540	2,134863	1200	462,625	1,375295	371,7
541	2,134206	1200	463,0317	1,371971	374,0
542	2,133022	1200	463,4663	1,368865	376,3
543	2,131305	1200	463,9296	1,365972	378,7
544	2,129048	1200	464,4223	1,363288	381,2
545	2,126245	1200	464,9448	1,360802	383,8
546	2,122888	1200	465,498	1,358504	386,4
547	2,118972	1200	466,0824	1,356382	389,0
548	2,114489	1200	466,6988	1,35442	391,8
549	2,109433	1200	467,3478	1,352601	394,5
550	2,103797	1200	468,0302	1,350903	397,3
551	2,097575	1200	468,7466	1,349306	400,2
552	2,090759	1200	469,4978	1,347781	403,0
553	2,083344	1200	470,2846	1,346302	405,9
554	2,075323	1200	471,1076	1,344836	408,8
555	2,066689	1200	471,9677	1,343348	411,8
556	2,057435	1200	472,8656	1,341801	414,7
557	2,047556	1200	473,8022	1,340153	417,6
558	2,037044	1200	474,7783	1,338359	420,5
559	2,025892	1200	475,7947	1,33637	423,4
560	2,014095	1200	476,8522	1,334135	426,3
561	2,001646	1200	477,9518	1,331596	429,1
562	1,988538	1200	479,0943	1,328693	431,8
563	1,974764	1200	480,2807	1,325363	434,5
564	1,960319	1200	481,5119	1,321536	437,1
565	1,945195	1200	482,7888	1,317138	439,6
566	1,929386	1200	484,1125	1,312093	442,0
567	1,912886	1200	485,4839	1,306318	444,2
568	1,895688	1200	486,9041	1,299724	446,3
569	1,877785	1200	488,3741	1,292221	448,2
570	1,859171	1200	489,8949	1,28371	450,0
571	1,83984	1200	491,4678	1,274088	451,6
572	1,819785	1200	493,0938	1,263247	452,9
573	1,799	1200	494,7741	1,251073	454,0
574	1,777478	1200	496,5098	1,237447	454,8
575	1,755213	1200	498,3022	1,222242	455,3
576	1,732198	1200	500,1525	1,205327	455,5
577	1,708427	1200	502,062	1,186565	455,4
578	1,683893	1200	504,0321	1,16581	454,9
579	1,65859	1200	506,0639	1,142912	454,0
580	1,632513	1200	508,159	1,117713	452,6

581	1,605653	1200	510,3187	1,090049	450,8
582	1,578005	1200	512,5445	1,059747	448,5
583	1,549563	1200	514,8378	1,02663	445,7
584	1,52032	1200	517,2001	0,990511	442,4
585	1,49027	1200	519,6331	0,951195	438,4
586	1,459407	1200	522,1382	0,908482	433,8
587	1,427723	1200	524,7172	0,862162	428,5
588	1,395214	1200	527,3717	0,812017	422,6
589	1,361872	1200	530,1033	0,757821	415,8
590	1,327691	1200	532,914	0,69934	408,3
591	1,292665	1200	535,8054	0,636331	399,9

ANEXO II – ALGORITMOS

1. Importação das Bibliotecas

```
import pandas as pd

import numpy as np

import matplotlib.pyplot as plt

import seaborn as sns


from sklearn.model_selection import train_test_split

from sklearn.preprocessing import StandardScaler

from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score


from tensorflow import keras

from tensorflow.keras import layers

from tensorflow.keras.callbacks import EarlyStopping


from sklearn.svm import SVR

from sklearn.ensemble import RandomForestRegressor
```

2. Preparação dos Dados

```
# Carregar dados

data = pd.read_excel('banco de dados.xlsx', sheet_name='1000')


# Selecionar colunas relevantes

data = data[['Deformação', 'Velocidade de deformação', 'Temperatura inicial', 'Temperatura final', 'Dureza']]

data.columns = ['deformacao', 'velocidade_deformacao', 'temp_inicial', 'temp_final', 'dureza']


# Verificar dados faltantes
```

```
print("Valores faltantes por coluna:")
print(data.isnull().sum())

# Estatísticas descritivas
print("\nEstatísticas descritivas:")
print(data.describe())

3. Divisão e Normalização dos Dados
X = data[['deformacao', 'velocidade_deformacao', 'temp_inicial', 'temp_final']]
y = data['dureza']

X_train, X_val, y_train, y_val = train_test_split(X, y, test_size=0.3, random_state=42)

scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_val_scaled = scaler.transform(X_val)

print(f"\nAmostras de Treinamento: {X_train.shape[0]} | Validação: {X_val.shape[0]}")


4. Modelo de Rede Neural Artificial (RNA)
model = keras.Sequential([
    layers.Dense(16, activation='relu', input_shape=[X_train.shape[1]]),
    layers.Dense(12, activation='relu'),
    layers.Dense(8, activation='relu'),
    layers.Dense(1)
])

model.compile(optimizer='adam', loss='mse', metrics=['mae', 'mse'])
```

```
early_stopping = EarlyStopping(monitor='val_loss', patience=20, restore_best_weights=True)

# Treinamento
history = model.fit(
    X_train_scaled, y_train,
    validation_data=(X_val_scaled, y_val),
    epochs=300,
    batch_size=32,
    callbacks=[early_stopping],
    verbose=1
)

5. Avaliação do Modelo RNA
y_train_pred = model.predict(X_train_scaled).flatten()
y_val_pred = model.predict(X_val_scaled).flatten()

train_mse = mean_squared_error(y_train, y_train_pred)
train_mae = mean_absolute_error(y_train, y_train_pred)
train_r2 = r2_score(y_train, y_train_pred)

val_mse = mean_squared_error(y_val, y_val_pred)
val_mae = mean_absolute_error(y_val, y_val_pred)
val_r2 = r2_score(y_val, y_val_pred)

print("\nMétricas da RNA:")
print(f"Treino -> MSE: {train_mse:.4f}, MAE: {train_mae:.4f}, R²: {train_r2:.3f}")
print(f"Validação -> MSE: {val_mse:.4f}, MAE: {val_mae:.4f}, R²: {val_r2:.3f}")

# 6. Gráficos do Treinamento (RNA)
```

```
plt.figure(figsize=(12, 5))
plt.plot(history.history['loss'], label='Treinamento')
plt.plot(history.history['val_loss'], label='Validação')
plt.xlabel('Épocas')
plt.ylabel('Erro Quadrático Médio (MSE)')
plt.title('Evolução do MSE durante o Treinamento da RNA')
plt.legend()
plt.grid(True)
plt.show()

7. Treinamento e Avaliação do Modelo SVM
svm_model = SVR(kernel='rbf', C=100, gamma=0.1)
svm_model.fit(X_train_scaled, y_train)

y_pred_svm = svm_model.predict(X_val_scaled)

mae_svm = mean_absolute_error(y_val, y_pred_svm)
mse_svm = mean_squared_error(y_val, y_pred_svm)
r2_svm = r2_score(y_val, y_pred_svm)

print(f"\nMétricas da SVM -> MAE: {mae_svm:.4f}, MSE: {mse_svm:.4f}, R²: {r2_svm:.3f}")

8. Treinamento e Avaliação do Modelo Random Forest
rf_model = RandomForestRegressor(n_estimators=100, random_state=42)
rf_model.fit(X_train_scaled, y_train)

y_pred_rf = rf_model.predict(X_val_scaled)

mae_rf = mean_absolute_error(y_val, y_pred_rf)
mse_rf = mean_squared_error(y_val, y_pred_rf)
```

```
r2_rf = r2_score(y_val, y_pred_rf)

print(f"\nMétricas da RF -> MAE: {mae_rf:.4f}, MSE: {mse_rf:.4f}, R²: {r2_rf:.3f}")

9. Comparação Gráfica: Previsões vs Valores Reais
plt.figure(figsize=(15, 5))

# RNA
plt.subplot(1, 3, 1)
plt.scatter(y_val, y_val_pred, alpha=0.6)
plt.plot([y.min(), y.max()], [y.min(), y.max()], 'r--')
plt.xlabel('Dureza Real (HV)')
plt.ylabel('Dureza Prevista (HV)')
plt.title('RNA')

# SVM
plt.subplot(1, 3, 2)
plt.scatter(y_val, y_pred_svm, alpha=0.6)
plt.plot([y.min(), y.max()], [y.min(), y.max()], 'r--')
plt.xlabel('Dureza Real (HV)')
plt.ylabel('Dureza Prevista (HV)')
plt.title('SVM')

# RF
plt.subplot(1, 3, 3)
plt.scatter(y_val, y_pred_rf, alpha=0.6)
plt.plot([y.min(), y.max()], [y.min(), y.max()], 'r--')
plt.xlabel('Dureza Real (HV)')
plt.ylabel('Dureza Prevista (HV)')
plt.title('Random Forest')
```

```
plt.tight_layout()
plt.show()

10. Distribuição dos Erros (RNA)
errors = y_val - y_val_pred
plt.figure(figsize=(10, 5))
sns.histplot(errors, kde=True)
plt.xlabel('Erro de Predição (HV)')
plt.ylabel('Frequência')
plt.title('Distribuição dos Erros de Predição - RNA')
plt.grid(True)
plt.show()

11. Importância das Variáveis (RNA via Permutation)
def permutation_importance(model, X, y, metric, n_repeats=10):
    baseline = metric(y, model.predict(X).flatten())
    imp = []
    for col in range(X.shape[1]):
        X_permuted = X.copy()
        perm_scores = []
        for _ in range(n_repeats):
            X_permuted[:, col] = np.random.permutation(X_permuted[:, col])
            perm_scores.append(metric(y, model.predict(X_permuted).flatten()))
        imp.append(baseline - np.mean(perm_scores))
    return np.array(imp)

importance = permutation_importance(model, X_val_scaled, y_val, r2_score)

plt.figure(figsize=(10, 6))
```

```
plt.barh(X.columns, importance)
plt.xlabel('Importância (redução no R²)')
plt.title('Importância das Variáveis - RNA')
plt.grid(True)
plt.show()
```