

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
Escola de Engenharia

Departamento de Metalurgia

APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA A PREVISÃO DA CURVA
DE ESCOAMENTO A QUENTE DE LIGAS DE AÇO

Murilo Schmeling

Trabalho de Diplomação

Orientador: Professor Dr. Lirio Schaeffer
Coorientador: Professor Dr. Roderval Marcelino

Porto Alegre
2024

CIP - Catalogação na Publicação

Schmeling, Murilo
APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA A
PREVISÃO DA CURVA DE ESCOAMENTO A QUENTE DE LIGAS DE
AÇO / Murilo Schmeling. -- 2024.
65 f.
Orientador: Lirio Schaeffer.

Coorientador: Roderval Marcelino.

Trabalho de conclusão de curso (Graduação) --
Universidade Federal do Rio Grande do Sul, Escola de
Engenharia, Curso de Engenharia Metalúrgica, Porto
Alegre, BR-RS, 2024.

1. Rede Neurais Artificiais. 2. Tensão de
Escoamento a quente. 3. Previsão da curva de
escoamento a quente a partir da composição química. 4.
Conformação Mecânica. I. Schaeffer, Lirio, orient.
II. Marcelino, Roderval, coorient. III. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os dados fornecidos pelo(a) autor(a).

AGRADECIMENTOS

Antes de tudo, gostaria de agradecer à vida, este fenômeno extraordinário que transcende a mera coincidência ou casualidade.

Gostaria de agradecer ao universo, mais precisamente aos átomos, que uma vez foram parte de estrelas distantes e agora fazem parte de mim. Eles representam a incrível jornada da matéria através do tempo e do espaço, culminando nesta consciência que vos escreve.

Para os agradecimentos as pessoas a quem amo, antes gostaria de agradecer a causalidade, pois diante da vastidão do tempo, e da imensidão do espaço, das múltiplas realidades possíveis e de todas as pequenas contribuições que fazem do agora, o agora, é um prazer para mim dividir este tempo com estas pessoas.

Aos meus pais, Valter Schmeling e Eliane Braga Schmeling, por todo carinho e ensinamentos que sempre tiveram e sempre terão comigo, por sempre me ensinarem o caminho do bem e me incentivarem a sonhar alto.

Para minha irmã Sofia Schmeling, pelo cuidado, amizade e as boas risadas.

Para meu amor, Bárbara Bervian Viegas, por todo companheirismo e paciência, te amo mais que ontem e menos que amanhã.

Para toda minha família. Em especial minhas falecidas “Tia Bete” e “Vó Jandira” que partiram durante minha jornada, levo vocês para sempre!

Ao meu orientador, Prof^o. Dr. Ing. Lirio Schaeffer, e ao meu coorientador Prof^o. Dr. Roderval Marcelino pela grande oportunidade, auxílio e confiança.

Ao MSc. Eng^o. André Rosiak pela imensurável ajuda.

A todos os colegas e amigos da metal que fiz durante essa caminhada.

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

A todos os amigos, colegas e professores que auxiliaram nestes anos de graduação.

SUMÁRIO

LISTA DE FIGURAS	VI
LISTA DE TABELAS	VII
LISTA DE ABREVIATURAS E SÍMBOLOS	IX
RESUMO	X
ABSTRACT	XI
1.0 INTRODUÇÃO	1
2.0 REVISÃO DA LITERATURA	2
<u>2.1 Processos de Fabricação por Conformação Mecânica</u>	2
<u>2.1.1 Tensão</u>	4
<u>2.1.2 Deformação</u>	5
<u>2.1.3 Velocidade de Deformação</u>	6
<u>2.2 Curvas de Escoamento</u>	7
<u>2.3 Método de obtenção da curva de escoamento</u>	8
<u>2.3.1 Ensaio de Tração</u>	9
<u>2.3.2 Ensaio de Compressão</u>	10
<u>2.3.3 Método de obtenção da curva de escoamento a quente</u>	12
<u>2.3.4 Custos do ensaio de tração a quente</u>	14
<u>2.4 Influência dos elementos de liga na tensão de escoamento</u>	15
<u>2.4.1 Carbono</u>	16
<u>2.4.2 Silício</u>	17
<u>2.4.3 Manganês</u>	18
<u>2.4.4 Fósforo</u>	18
<u>2.4.5 Enxofre</u>	19
<u>2.4.6 Alumínio</u>	19
<u>2.4.7 Cromo</u>	20
<u>2.4.8 Níquel</u>	21
<u>2.4.9 Molibdênio</u>	21
<u>2.4.10 Titânio</u>	22
<u>2.4.11 Vanádio</u>	22

2.4.12	<u>Nitrogênio</u>	23
2.4.13	<u>Cobre</u>	23
2.4.14	<u>Nióbio</u>	24
2.5	<u>Redes Neurais Artificiais</u>	24
2.5.1	<u>Fundamento e Funcionamento das RNA's</u>	25
2.5.2	<u>Aplicações de RNA's na Conformação Mecânica</u>	27
3.0	MATERIAIS E MÉTODOS	30
3.1	<u>Determinação de Parâmetros para a RNA</u>	32
3.2	<u>Coleta e preparação dos dados</u>	33
3.3	<u>Projeto e calibração da RNA</u>	37
4.0	RESULTADOS E DISCUSSÃO	40
4.1	<u>Avaliação da influência uniforme de cada elemento</u>	40
4.2	<u>Avaliação do desempenho da RNA</u>	42
5.0	CONCLUSÕES	49
6.0	SUGESTÕES PARA TRABALHOS FUTUROS	50
7.0	REFERÊNCIAS BIBLIOGRÁFICAS	51

LISTA DE FIGURAS

Figura 2.1	Classificação dos processos de conformação mecânica quanto ao tipo de esforço aplicado.....	3
Figura 2.2	Tensões principais σ_x , σ_y e σ_z	4
Figura 2.3	Curvas de escoamento do aço AISI 1045 em (A) = 750°C, (B) 850°C e (c) = 950°C.	8
Figura 2.4	Representação esquemática de corpo de prova submetido a carga de tração, compressão e cisalhamento.....	9
Figura 2.5	Curvas de escoamento de uma liga de alumínio Ti-45Al-8Nb em (a) 1273K, (b) 1373K e (c) 1473K....	10
Figura 2.6	Representação do ensaio de compressão de uma amostra que tem dimensões iniciais D_0 e h_c e dimensões pós ensaio D_f e h_f ..	11
Figura 2.7	Máquina de teste servo-hidráulica com forno e instrumentada para teste em alta temperatura....	13
Figura 2.8	Curva de Escoamento do aço ASTM 1045.....	14
Figura 2.9	Curva de Dureza Brinell, tensão máxima e tensão de escoamento em relação ao teor de carbono no aço.....	17
Figura 2.10	Influência da concentração de Silício na resistência a tração do aço ligado 30CrMo5-2.....	18
Figura 2.11	Influência da concentração de Alumínio na tensão de escoamento do aço ligado 24CrMo4.....	20
Figura 2.12	Influência da concentração de Cromo na tensão de escoamento do aço ligado 30CrMo5-2.....	21
Figura 2.13	Influência da concentração de Vanádio na resistência a tração do aço ligado 42CrMo4.....	23
Figura 2.14	Representação esquemática das camadas de uma RNA.....	26
Figura 2.15	Representação de uma rede neural com dados de entrada e pesos.....	26
Figura 2.16	Diagrama para determinação do Método de Conformação.....	27
Figura 2.17	Ilustração simplificada da estrutura do sistema de assistência a produção.....	28

Figura 2.18	Comparação entre os resultados de previsão de elementos finitos e RNA de ângulos de retorno elástico.....	28
Figura 3.1	Fluxograma da Criação da Rede Neural.....	31
Figura 3.2	Representação Esquemática da interação entre os elementos químicos do aço e obtenção da tensão de escoamento a quente.....	33
Figura 3.3	Tabela de aços coletados.....	34
Figura 3.4	Banco de dados do software, mostrando as diferentes temperaturas, velocidades de deformação e deformação.....	36
Figura 3.5	Tabela dos dados coletados do software.....	37
Figura 4.1	Frequência de cada elemento de liga na base de 102 materiais.....	40
Figura 4.2	Análise da influência da composição dos elementos de liga na tensão de escoamento. Os valores de k_f registrados correspondem a tensão de escoamento requerida para gerar uma deformação $\varphi=1,5$ em uma velocidade de deformação $\dot{\varphi}=1s^{-1}$ e a uma temperatura $\vartheta=1000^{\circ}C$	41
Figura 4.3	Arquitetura da Rede Neural Artificial Densa proposta.....	43
Figura 4.4	Evolução do Erro Absoluto Médio em função do número de iterações para o treinamento com (a) 70 e (b) 100 materiais.....	44
Figura 4.5	Evolução do Erro Quadrático Médio em função do número de iterações para o treinamento com (a) 70 e (b) 100 materiais.....	44
Figura 4.6	Predição da tensão de escoamento em função do respectivo valor original.....	46
Figura 4.7	Curva de escoamento real do aço X15Cr13 ($1250^{\circ}C$, $0,1s^{-1}$) e sua aproximação usando os valores previstos pela RNA.....	48

LISTA DE TABELAS

Tabela 2.1	Preço para realização de diferentes tipos de Ensaio.	15
Tabela 2.2	Tempo médio para realização de diferentes tipos de Ensaio..	15
Tabela 3.1	Elementos químicos registrados... ..	34
Tabela 3.2	Faixas de temperatura registradas.....	34
Tabela 3.3	Valores de velocidade de Deformação.....	35
Tabela 3.4	Valores de Deformação.....	35

LISTA DE ABREVIATURAS E SÍMBOLOS

h	Altura final	mm
h_0	Altura inicial	mm
A	Área	mm ²
A_0	Área Inicial	mm ²
l	Comprimento final	mm
l_0	Comprimento inicial	mm
F	Força	kN
b	Largura final	mm
b_0	Largura inicial	mm
R_m	Resistência máxima	N/mm ²
T	Temperatura	°C
t	Tempo	s
V_f	Velocidade da ferramenta	mm/s
ε	Tensão de engenharia	N/mm ²
σ_{eq}	Tensão equivalente	N/mm ²
σ_x	Tensão no eixo x	N/mm ²
σ_y	Tensão no eixo y	N/mm ²
σ_z	Tensão no eixo z	N/mm ²
σ_1	Tensão principal máxima	N/mm ²
σ_3	Tensão principal mínima	N/mm ²
Δl	Variação do comprimento	mm
$\dot{\varphi}$	Velocidade de deformação	s ⁻¹
φh	Deformação em altura	-
φl	Deformação em comprimento	-
φb	Deformação em largura	-
σ	Tensão	N/mm ²
k_f	Tensão de escoamento	N/mm ²
k_{f0}	Tensão de escoamento inicial	N/mm ²

RESUMO

O objetivo deste trabalho é avaliar a possibilidade e a precisão de usar uma rede neural artificial (RNA) para prever o comportamento a quente da tensão de escoamento de diferentes tipos de aço. A tensão de escoamento é uma propriedade mecânica importante dos aços, pois determina o início da deformação permanente do material. Para projetos mecânicos, é fundamental conhecer o comportamento da tensão de escoamento dos aços em diferentes condições, como temperatura e velocidade de deformação. O trabalho foi realizado em três etapas. Na primeira etapa, foi feita a coleta de dados de tensão de escoamento para diferentes aços. Na segunda etapa, uma RNA foi treinada a partir destes dados. Na terceira etapa, a confiabilidade do resultado e a eficácia da RNA foram testadas ao submeter a ela as propriedades mecânicas de materiais que não foram usados no treinamento da mesma, para então comparar a capacidade e precisão da previsão da RNA com o valor real de ensaio.

Palavras Chave: Tensão de Escoamento, RNA, Composição química,

ABSTRACT

The objective of this study is to evaluate the possibility and accuracy of using an artificial neural network (ANN) to predict the hot yield behavior of different steel types. Yield strength is an important mechanical property of steels, as it determines the material's ability to withstand loads without permanent deformation. For mechanical designs, it is essential to know the yield strength behavior of steels under different conditions, such as temperature and deformation speed. The study will be conducted in three stages. In the first stage, yield strength data for different steels will be collected. In the second stage, an ANN will be trained using this data. In the third stage, the reliability of the results and the effectiveness of the ANN will be tested by submitting the mechanical properties of materials not used in the training to the ANN, and then comparing the ANN's prediction capability and accuracy with the actual test values.

Keywords: Yield Strength, ANN, Chemical Composition

1.0 INTRODUÇÃO

A curva de escoamento de um material é uma informação valiosíssima para qualquer projeto mecânico, e esta, por sua vez é fundamental na conformação mecânica, pois fornece informações sobre o comportamento do material sob tensão, além disso, a partir da curva de escoamento pode-se observar a máxima tensão que o material aguenta até começar a deformar plasticamente. Compreender a curva de escoamento de um material é essencial para definir limites de carga impostas sobre o mesmo quando usado em qualquer projeto mecânico.

Tradicionalmente, as curvas de escoamento são obtidas a partir de testes experimentais, realizados a quente ou a frio, chamadas de deformação a quente e deformação a frio, respectivamente. Quando realizados a quente, é crucial manter a temperatura constante durante o ensaio, bem como a velocidade de deformação permanecer constante, para garantir a precisão dos resultados. Este tipo de ensaio requer equipamentos especiais e caros, tornando o processo caro e complexo.

Diante destes desafios, as RNA'S surgem como uma alternativa promissora, pois são capazes de resolver problemas complexos e não lineares, bem como identificar padrões em grandes conjuntos de dados. A RNA pode ser treinada para simular e prever o comportamento dos materiais sob diferentes condições, oferecendo uma solução mais financeiramente acessível, em contrapartida aos testes experimentais. (Vallim et al., [s.d.]

O objetivo geral deste trabalho é utilizar RNA's para prever a curva de escoamento de aços no trabalho a quente. Dentro deste objetivo geral, tem-se os objetivos específicos:

- Avaliar desempenho da RNA na previsão da curva de escoamento do material.
- Verificar quais propriedades químicas ou composição de elementos que tem mais influência na variabilidade dos resultados de tensão de escoamento.

2.0 REVISÃO DA LITERATURA

Este capítulo é dedicado a apresentar os conceitos chave que fundamentam a realização deste trabalho.

Aqui serão descritos os princípios teóricos essenciais para entender a relevância da curva de escoamento a quente em um material, bem como as técnicas primárias empregadas para sua obtenção.

Também será descrito como funcionam as RNA's, e como é possível aplica-las ao uso dentro da conformação mecânica.

2.1 Processos de fabricação por Conformação Mecânica

A área da engenharia denominada em termos gerais “conformação mecânica” tem por objetivo a análise dos processos de fabricação de peças por meio de deformação plástica.

Esses processos envolvem métodos de manufatura onde a forma dos metais é permanentemente modificada, utilizando tensões externas que excedem a tensão de escoamento do material, mas são inferiores à sua tensão de fratura. Nesse processo, não apenas a forma do material é alterada, mas também suas características mecânicas. (Helman & Cetlin, 2005).

Esses métodos podem ser categorizados de diversas maneiras, sendo as classificações mais comuns baseadas na temperatura do processo e no tipo de tensão empregada.

Os métodos de conformação mecânica são geralmente divididos em trabalho a quente, morno e frio. No trabalho a quente, a deformação ocorre em condições onde temperatura e velocidade de deformação permitem que recuperação e recristalização aconteçam simultaneamente à deformação. Já o trabalho a frio se dá em circunstâncias onde esses processos de recuperação e recristalização são ineficazes. No trabalho morno, ocorre a recuperação, mas não a formação de novos grãos, ou seja, não há recristalização. (Brito Mira & Moreno, [s.d.]

Nos processos a frio, ocorre o fenômeno do encruamento, que é o endurecimento do material junto com a deformação plástica do mesmo, e isto aumenta sua resistência mecânica. A vantagem dos processos a frio é a produção de peças com melhor acabamento superficial.

Durante o trabalho a quente, acompanhado pelos processos de recuperação e recristalização, a alta temperatura auxilia na difusão de átomos e na eliminação de discordâncias, fazendo com que o endurecimento por deformação não ocorra pela formação de novos grãos, livres de deformação, este processo permite então alcançar níveis mais altos de deformação. A vantagem dos processos a quente é que a energia necessária para a deformação é muito menor que no trabalho a frio. (FROTA JR, 2009).

Outra categorização que é feita nos processos de conformação mecânica é devido ao tipo de esforço aplicado, sendo que mais de um pode ser usado para produzir determinada estrutura. Na Figura 2.1 abaixo, é mostrado uma ilustração esquemática dos diferentes tipos de esforços.

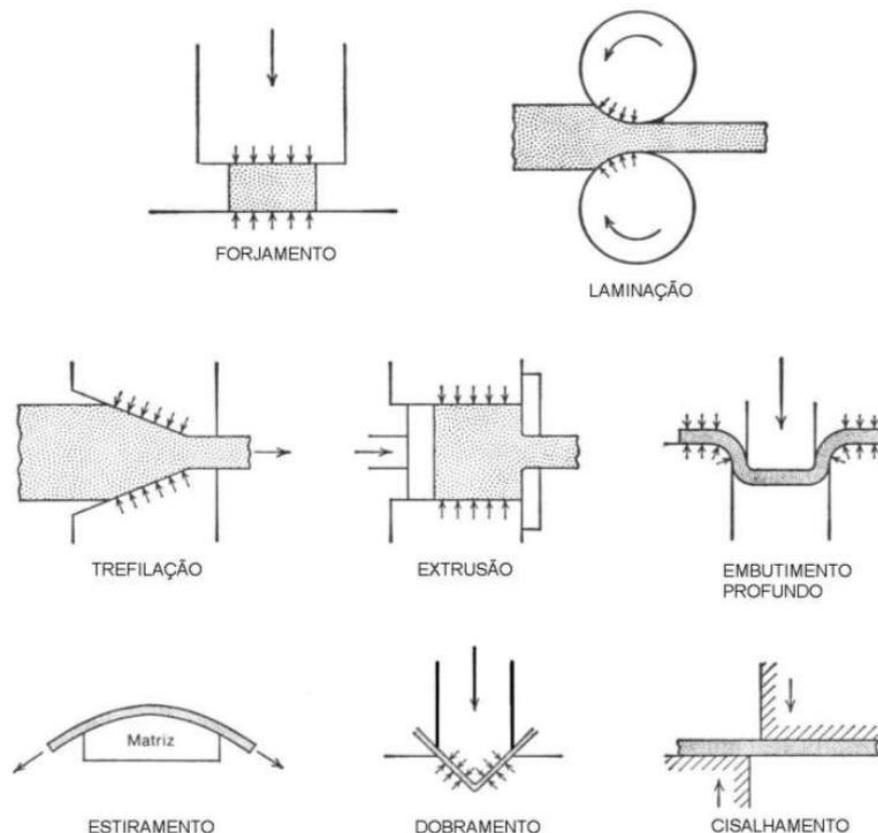


Figura 2.1: Classificação dos processos de conformação mecânica quanto ao tipo de esforço aplicado.

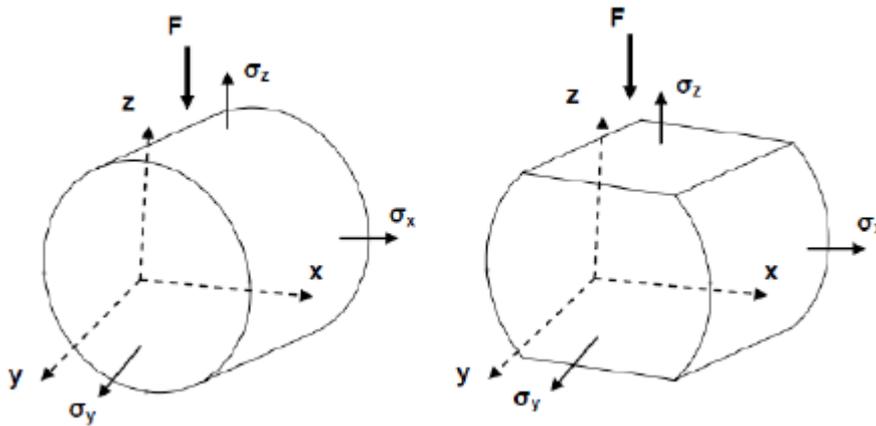
Fonte: (Fábio Martins, [s.d.]

2.1.1 Tensão

A tensão (σ) é definida como a razão entre a força aplicada (F) e a área da seção (A) onde a força está sendo aplicada, conforme mostra a Equação 1:

$$\sigma = \frac{F}{A} \quad \text{(Equação 1)}$$

Quando um corpo está sujeito a uma força, ele experimenta tensões tanto na sua superfície quanto internamente. Pode-se definir três tensões principais que um corpo experimenta em qualquer trabalho mecânico, são estas, tensão ao longo da largura (σ_x), a tensão ao longo do comprimento (σ_y) e a tensão ao longo da altura (σ_z), que estão representadas esquematicamente na figura 2.2.



Figurar 2.2: Tensões principais σ_x , σ_y e σ_z

Fonte: (SCHAEFFER, 2006.)

Quando um corpo está sujeito a diferentes combinações de tensões, este pode sofrer escoamento ou não. Em um estado onde múltiplas tensões estão presentes, o escoamento do material é influenciado pela interação dessas tensões.

A tensão equivalente (σ_{eq}), que representa a soma de todas as tensões em um corpo durante o processo de forjamento, serve como um indicativo deste fenômeno. Portanto, para avaliar a possibilidade de escoamento do material, utiliza-se a determinação da tensão

equivalente (σ_{eq}) conforme proposto na Teoria de Escoamento de Von Mises, apresentada na Equação 2:

$$\sigma_{eq} \cong \frac{1}{\sqrt{2}} \sqrt{(\sigma_y - \sigma_x)^2 + (\sigma_z - \sigma_x)^2 + (\sigma_z - \sigma_y)^2} \quad (\text{Equação 2})$$

Quando esta tensão equivalente (σ_{eq}) ultrapassa um valor específico do material, começa o efeito do escoamento do mesmo, este valor específico é conhecido como limite de escoamento do material, definido como o estado de tensões que, quando superado, inicia-se a deformação plástica no material. (Altan et al., 2005)

2.1.2 Deformação

No campo da conformação mecânica, a análise da deformação pode ser abordada de duas maneiras distintas. Na mecânica tradicional, geralmente emprega-se o conceito de Deformação Relativa, que incorpora a área da seção transversal inicial nos cálculos. No entanto, nos estudos específicos de conformação mecânica, é mais adequado utilizar a Deformação Verdadeira para analisar a deformação em uma área específica de um componente. A Deformação Verdadeira leva em conta as mudanças instantâneas de tamanho, seja por compressão ou tração, que alteram as dimensões do objeto. Para calcular essas deformações verdadeiras, são aplicadas as seguintes equações:

$$\text{Deformação em largura} \quad \varphi_b = \ln \frac{b}{b_0} \quad (\text{Equação 3})$$

$$\text{Deformação em comprimento} \quad \varphi_l = \ln \frac{l}{l_0} \quad (\text{Equação 4})$$

$$\text{Deformação em altura} \quad \varphi_h = \ln \frac{h}{h_0} \quad (\text{Equação 5})$$

Estas são as 3 deformações principais, em relação a um sistema cartesiano (x, y, z), como mostrado na Figura 2.2.

Através destas três deformações, calcula-se a deformação equivalente, que é a soma de todas as deformações que o material sofre em um processo de conformação, através da equação 6: (SCHAEFFER, 2006)

$$\varphi_{eq} = \sqrt{\frac{2}{3} \cdot (\varphi_b^2 + \varphi_l^2 + \varphi_h^2)}. \quad (\text{Equação 6})$$

Qualquer corpo submetido a deformação plástica segue a lei da constância de volume, portanto, o volume final do material após o processo de conformação tem de ser igual ao volume inicial. Desta forma, ao realizar uma alteração em uma direção de deformação, as outras duas serão modificadas para que o volume do material continue o mesmo, com isso, verifica-se a equação 7, que mostra que o somatório das 3 deformações principais é igual a zero. (*Estampagem*, [s.d.]

$$\varphi_b + \varphi_l + \varphi_h = 0 \quad (\text{Equação 7})$$

2.1.3 Velocidade de Deformação

A velocidade de deformação na conformação mecânica é definida como a velocidade na qual o material é deformado durante um processo de conformação, em termos técnicos, é uma taxa de como varia a deformação com o tempo, conforme a equação 8.

$$\dot{\varphi} = \frac{d\varphi}{dt} \quad (\text{Equação 8})$$

A velocidade com qual o material é deformado varia através de três aspectos, a magnitude dessa deformação, a direção da deformação e a velocidade da ferramenta usada no processo de deformação, sendo esta última determinada pela variação instantânea da altura do corpo ao longo do tempo, conforme a equação 9.

$$\dot{\varphi} = \frac{vf}{h} \quad (\text{Equação 9})$$

Existe uma relação direta entre a tensão de escoamento do material e sua velocidade de deformação; um aumento na velocidade de deformação geralmente resulta em um aumento na tensão de escoamento. No entanto, uma maior velocidade da ferramenta tende a reduzir as perdas térmicas do processo. Isso pode levar a um aumento na temperatura do material, uma consequência da conversão da energia de deformação plástica em calor. (Rosiak, [s.d.]

2.2 Curva de Escoamento

As curvas de escoamento são fundamentais para compreender o comportamento mecânico dos materiais durante a deformação em processos de conformação mecânica, pois são elas que determinam os valores que serão aplicados nos cálculos da força e do trabalho no processo de conformação. (Carlos et al., 2018)

Quando um metal é submetido a tensões que alcançam um valor específico, conhecido como tensão de escoamento ou resistência ao escoamento (kf), inicia-se o processo de escoamento ou deformação plástica do material. a magnitude desta tensão é afetada por uma série de fatores, incluindo a deformação (φ), a velocidade de deformação ($\dot{\varphi}$), a temperatura (T), bem como aspectos intrínsecos do material, como sua composição química e microestrutura.

A curva de escoamento é a forma gráfica de representar essa tensão de escoamento a partir desses fatores, conforme mostra a equação 10 (SCHAEFFER, 2006):

$$Kf = (\varphi, \dot{\varphi}, T, \text{material}) \quad (\text{Equação 10})$$

Para deformação a frio, a relação entre a tensão de escoamento (kf) e a deformação real (φ) pode ser expressa através da Equação 11:

$$kf = C \cdot \varphi^n \quad (\text{Equação 11})$$

Para deformação a quente, ou seja, acima da temperatura de recristalização, a dependência da tensão de escoamento (kf) em relação à taxa de deformação ($\dot{\varphi}$) aumenta significativamente. Isso é evidenciado na Figura 2.3, que exhibe as curvas de escoamento para o aço AISI 1045 sob condições de deformação a quente, destacando o impacto da velocidade de deformação.

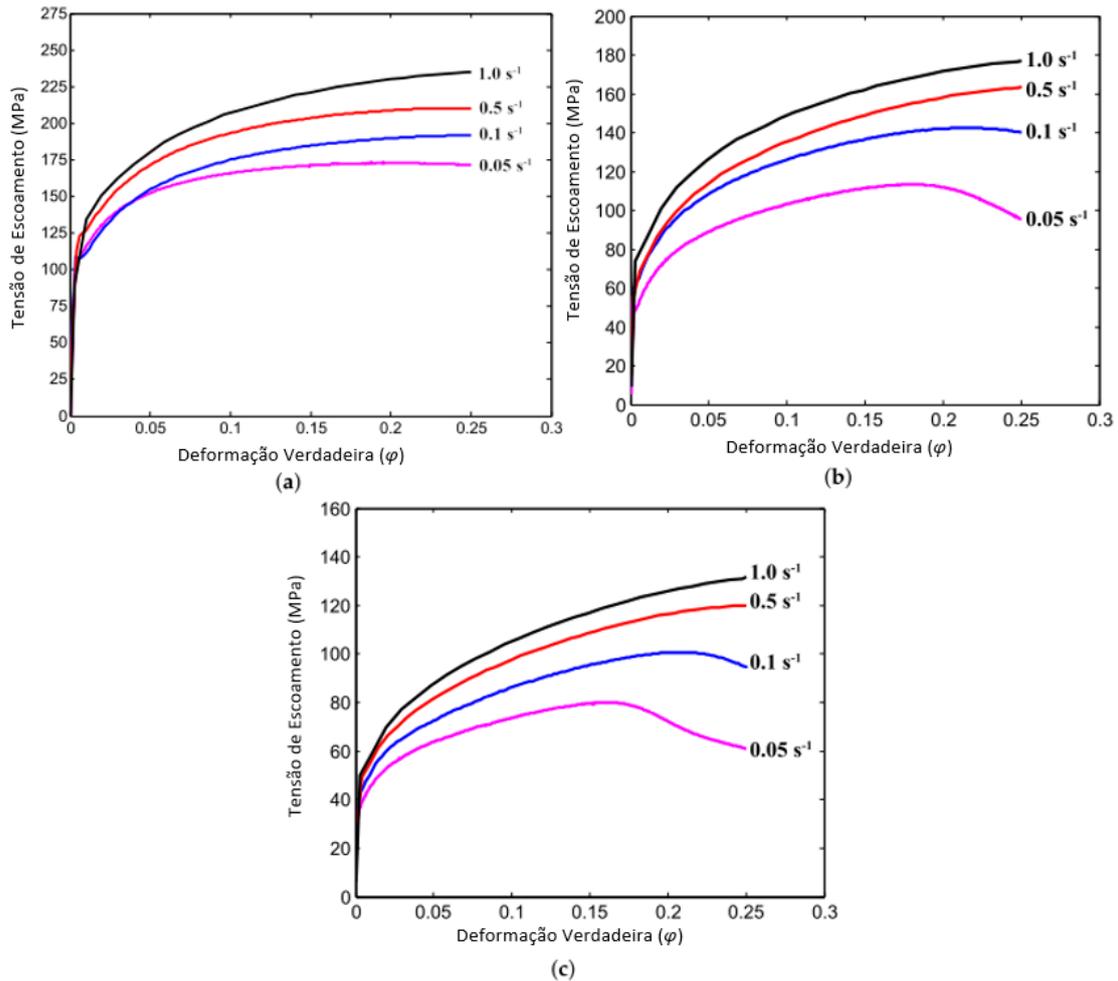


Figura 2.3: Curvas de escoamento do aço AISI 1045 em (A) = 750°C, (B) 850°C E (c) = 950°C
 Fonte: (Murugesan et al., 2020)

2.3 Método de obtenção da curva de escoamento

A determinação das curvas de escoamento para um material é crucial nos processos de conformação mecânica. Quando uma carga é aplicada de forma estática ou varia lentamente ao longo do tempo, distribuindo-se uniformemente sobre uma superfície de um componente, é possível analisar o comportamento mecânico do material por meio de testes de tensão-deformação. Os testes mais comumente empregados são o de tração, de compressão e de torção. (Boeira Ercolani & Rodrigo Kehl, [s.d.]

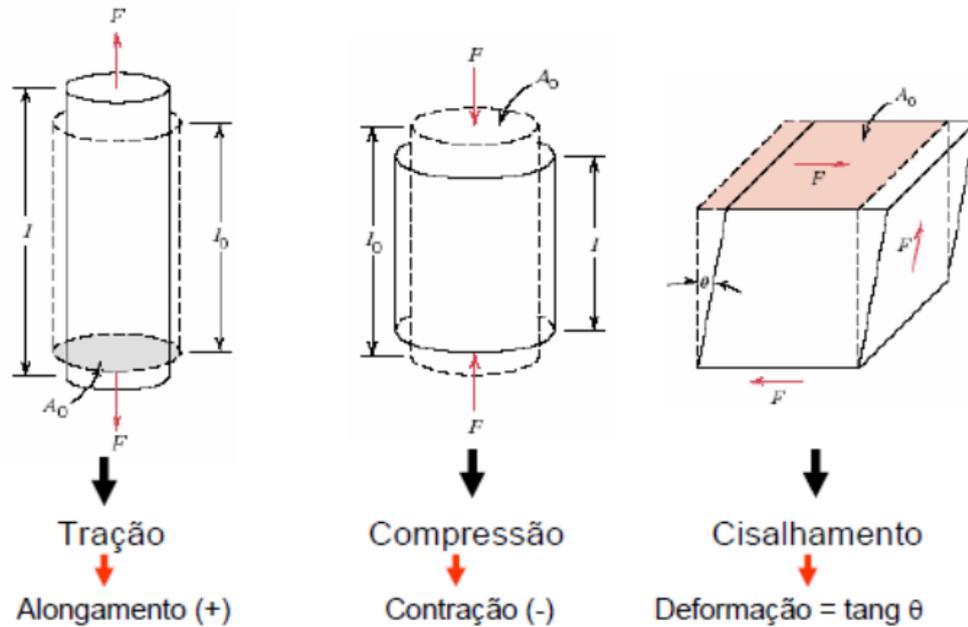


Figura 2.4: Representação esquemática de corpo de prova submetido a carga de tração, compressão e cisalhamento.

Fonte: (william, [s.d.]

2.3.1 Ensaio de Tração

O teste mais comum para avaliar as propriedades de tensão do material é o ensaio de tração. Neste teste, aplica-se uma força de tração progressiva sobre um corpo de prova padronizado, mantendo uma velocidade constante até que ocorra o rompimento do corpo de prova. O teste monitora a variação do comprimento da amostra em função da carga aplicada e os dados são apresentados em um gráfico que relaciona estes dois parâmetros.

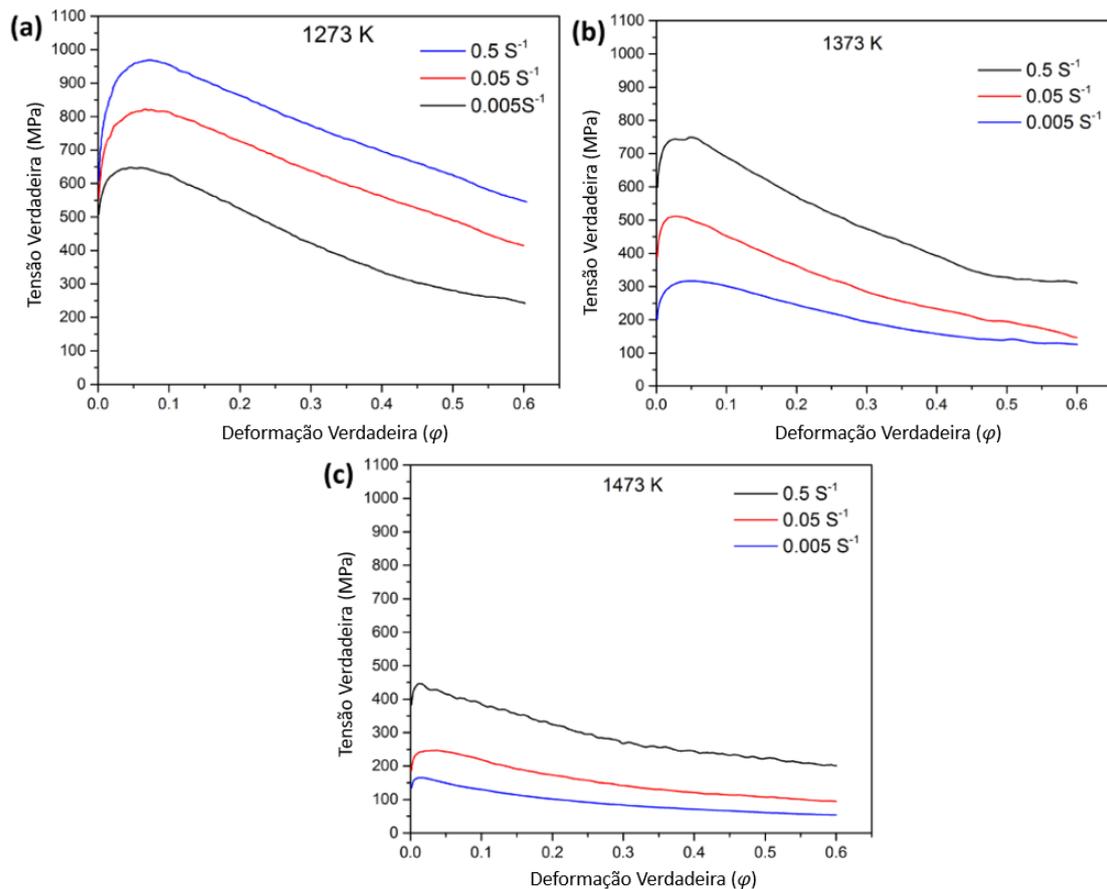


Figura 2.5: Curvas de escoamento de uma liga de alumínio Ti-45Al-8Nb em (a) 1273K, (b) 1373K e (c) 1473K.

Fonte: (Singh et al., 2019)

O teste de tração é um método eficaz para analisar várias características mecânicas dos materiais, essenciais para o desenvolvimento de projetos e para assegurar a qualidade das matérias-primas. Este teste permite determinar várias propriedades, incluindo a resistência máxima à tração, o ponto de escoamento, a elasticidade, a resiliência, a tenacidade, a ductilidade, o coeficiente de endurecimento por deformação e o coeficiente de resistência. (BRITO, 1998).

Na figura 2.5, observa-se a curva de escoamento de uma liga de alumínio em 3 diferentes temperaturas, e 3 diferentes velocidades de deformação.

2.3.2 Ensaio de Compressão

O teste de compressão consiste em submeter uma amostra a uma força compressiva unidirecional.

Ao contrário do teste de tração, o teste de compressão é utilizado para avaliar o comportamento do material sob deformações maiores, beneficiando-se da simplicidade geométrica da amostra. Neste ensaio, conforme mostra a figura 2.6, a amostra é comprimida entre duas placas paralelas, e se avalia tanto a força aplicada quanto a redução na altura da amostra.

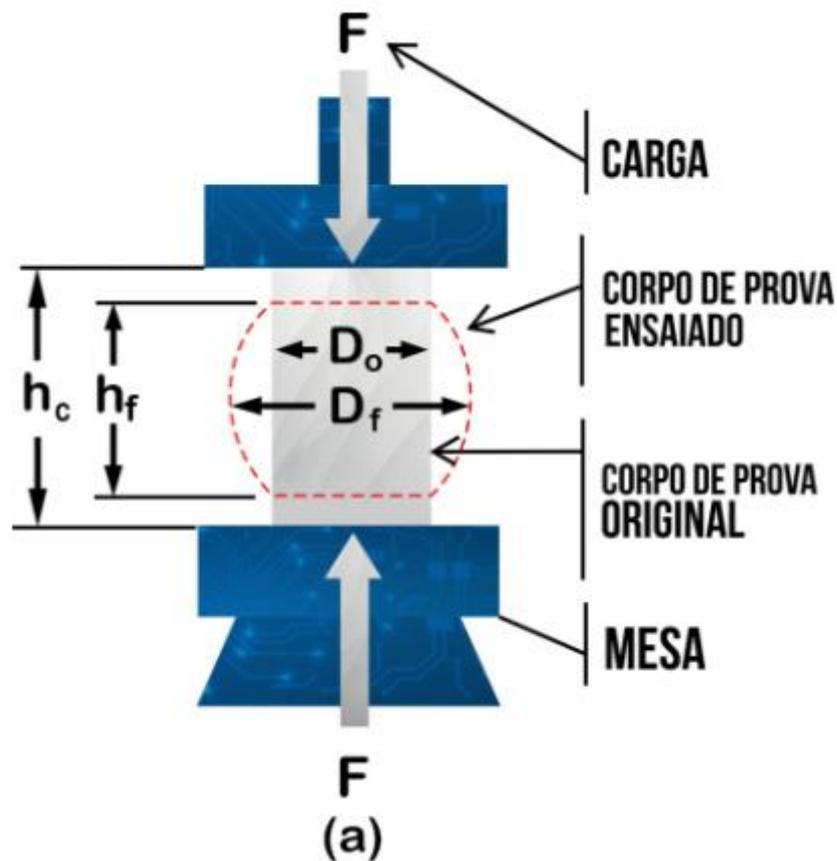


Figura 2.6: Representação do ensaio de compressão de uma amostra que tem dimensões iniciais D_0 e h_c e dimensões pós ensaio D_f e h_f .

Fonte: <https://biopdi.com.br/artigos/ensaio-de-compressao/>

O teste de compressão pode apresentar alguns fenômenos indesejáveis. O atrito entre a amostra e as placas da matriz pode causar uma deformação não uniforme, resultando em variações na seção transversal da amostra ao longo de sua altura. Além disso, a proporção inicial entre a altura e a largura da amostra, expressa pela relação h_c/D_0 , se for excessiva, pode levar à instabilidade. Estes problemas, se não forem devidamente gerenciados, podem dificultar a obtenção de uma curva precisa de tensão-deformação do material. (RODRIGUES, 2010).

2.3.3 Método de obtenção da curva de escoamento a quente

Obter informações confiáveis sobre as características de trabalho a quente de materiais metálicos é fundamental para o desenvolvimento bem-sucedido de técnicas de fabricação. Determinar a temperatura e a velocidade de deformação é vital para criar produtos forjados de alta qualidade com formas complexas.

O passo inicial e fundamental é estabelecer as condições apropriadas para o trabalho a quente. Gráficos que ilustram a relação entre a tensão de escoamento e a deformação do material em diversas temperaturas e velocidades de deformação, como exemplificado na figura 2.3, são cruciais para definir os parâmetros de processamento necessários para fabricar produtos de alto padrão.

A maneira de obtenção dessa curva é medir a resistência ao escoamento do material em diferentes temperaturas e com diferentes velocidades de deformação. Uma gama de equipamentos é utilizada para aplicar forças às amostras nos testes, variando de dispositivos simples a sistemas avançados controlados por computador. Os métodos de teste mais frequentemente empregados são os ensaios de tração a quente.

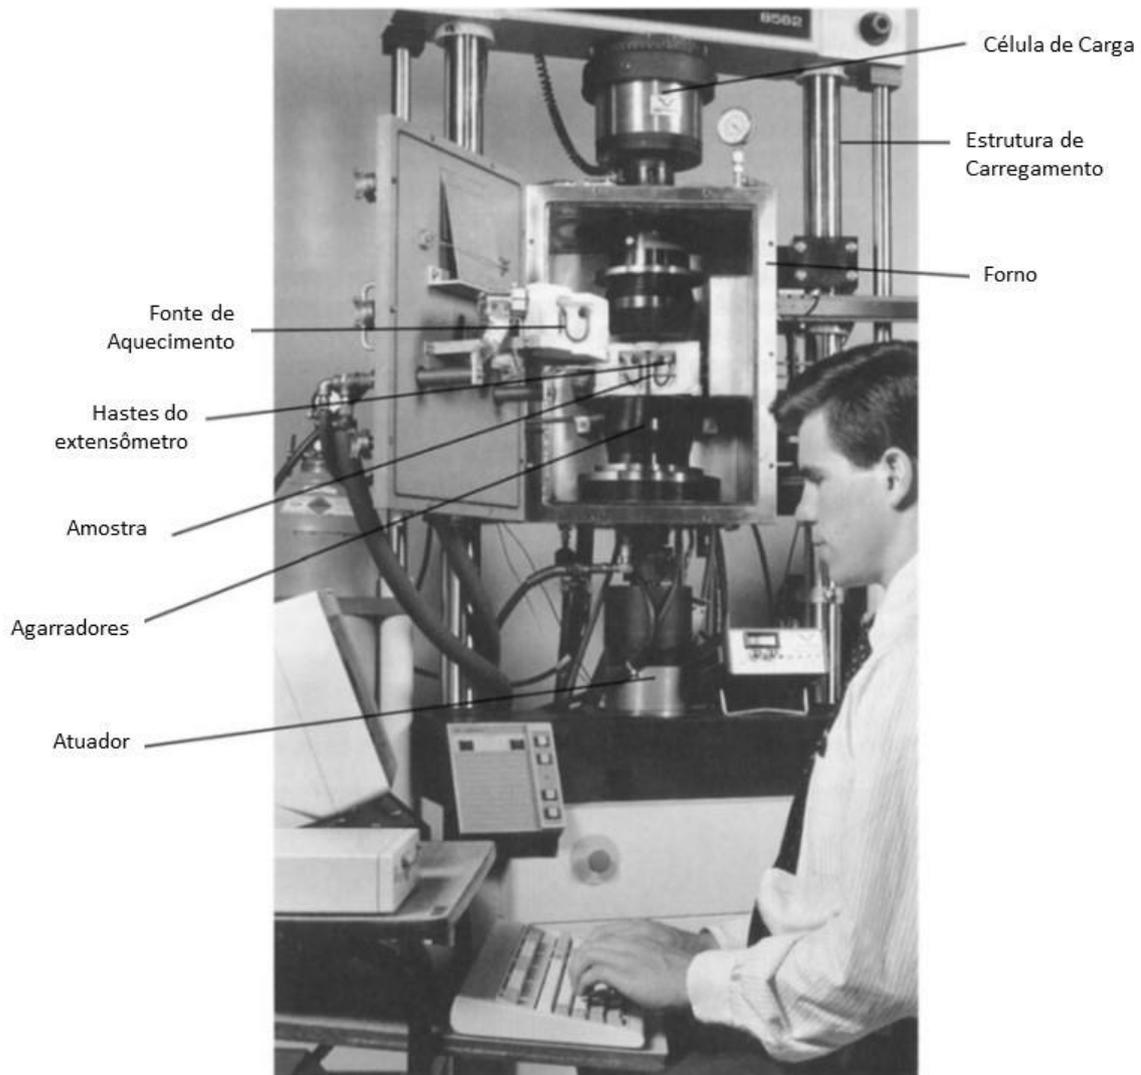


Figura 2.7: Máquina de teste servo-hidráulica com forno e instrumentada para teste em alta temperatura.

Fonte: (Dieter et al., 2003)

O método de aquecimento para testes de tensão em alta temperatura varia conforme a aplicação. As técnicas mais comuns são o aquecimento por resistência direta e aquecimento por resistência indireta ou indução. Na figura 2.7, tem-se uma máquina para ensaio de tração a quente, com um forno acoplado em volta da amostra para realizar ensaio em diferentes temperaturas. Algumas máquinas de teste universais podem incluir uma câmara especial para testes em vácuo ou atmosfera controlada.

A temperatura das amostras é monitorada e controlada por termopares, que podem estar presos à superfície da amostra ou localizados muito próximos a ela. A medição e controle precisos são cruciais para obter dados confiáveis. A ocorrência de aquecimento por deformação

também é uma consideração importante, especialmente em altas taxas de deformação, pois pode elevar significativamente a temperatura da amostra. (Dieter et al., 2003)

2.3.4 Custos do ensaio de tração a quente

O ensaio de tração a quente, além de ter diferentes variáveis que precisam ser precisamente controladas, também demanda tempo e investimento para ser realizado. Na figura 2.8 estão plotados dados de tensão de escoamento versus deformação de um aço ASTM 1045 a 800°C.

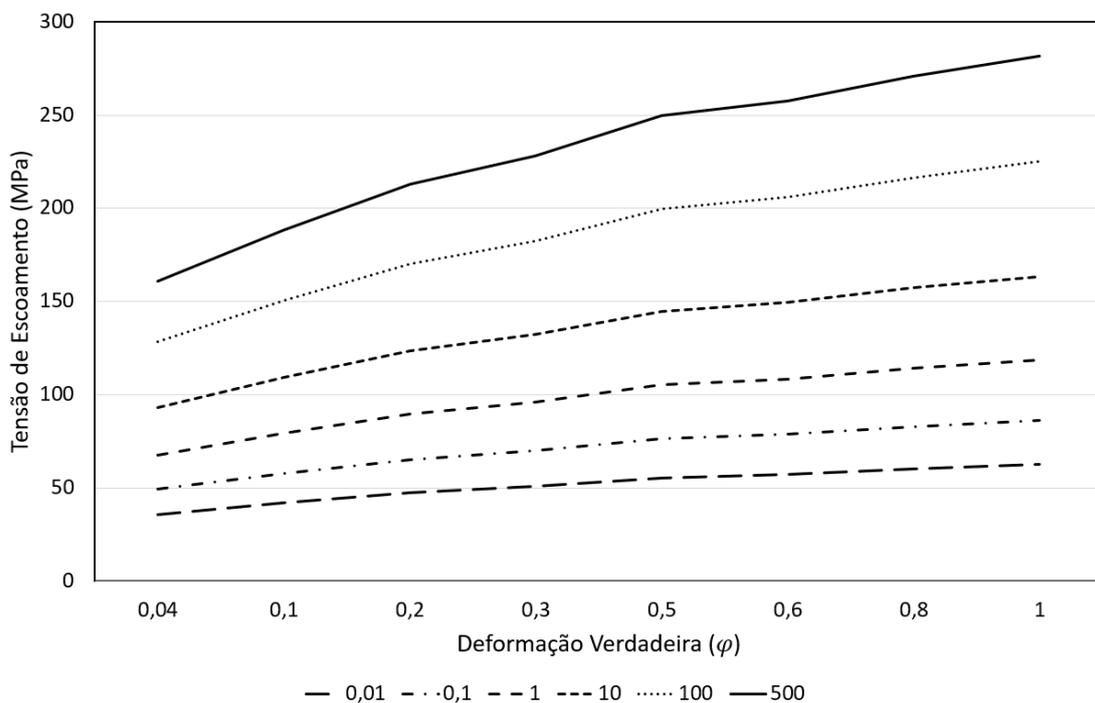


Figura 2.8: Curva de Escoamento do aço ASTM 1045

Fonte: QForm UK 10.2.1

Micas Simulations Ltd.

<http://qform3d.co.uk>

Para obter cada curva, é necessário realizar um ensaio prático no material, mantendo a temperatura fixa e variando a velocidade de deformação para cada corpo de prova, ou seja, para este material nesta temperatura, foram realizados seis ensaios com seis diferentes corpos de prova.

As tabelas 2.1 e 2.2 mostram o preço e o tempo médio para realização de cada ensaios do Laboratório de Ensaios Mecânicos (LEM) do Departamento de Engenharia de Materiais (DEMA) da UNICAMP.

Tipo de ensaio	Preço por corpo-de-prova	
	Para Empresas	Para ensino e pesquisa
<i>Tração</i>	R\$ 140,00	R\$ 70,00
<i>Flexão</i>	R\$ 90,00	R\$ 45,00
<i>Compressão</i>	R\$ 90,00	R\$ 45,00
<i>Compressão a quente</i>	R\$ 170,00	R\$ 85,00
<i>Tração a quente</i>	R\$ 550,00	R\$ 225,00
<i>Tenacidade à fratura</i>	R\$ 550,00	R\$ 225,00
<i>Dinâmicos (1 hora)</i>	R\$ 170,00	R\$ 85,00

Tabela 2.1: Preço para realização de diferentes tipos de Ensaio.

Fonte: <https://www.fem.unicamp.br/~emu/LEM.htm>

Tipo de ensaio	Tempo
<i>Tração</i>	15 minutos
<i>Flexão</i>	10 minutos
<i>Compressão</i>	10 minutos
<i>Compressão a quente</i>	20 minutos
<i>Tração a quente</i>	1 hora
<i>Tenacidade à fratura</i>	2,5 horas
<i>Dinâmicos</i>	Varia conforme frequência e número de ciclos

Tabela 2.2: Tempo médio para realização de diferentes tipos de Ensaio.

Fonte: <https://www.fem.unicamp.br/~emu/LEM.htm>

Portanto, um ensaio em apenas uma temperatura, como mostrado na figura 2.8, custaria em torno de R\$ 3.300,00 para uma empresa e R\$ 1.650,00 para setores de ensino e pesquisa, excluindo gastos com logística e confecção dos corpos de prova.

Como a aplicação para trabalho a quente dos aços abrange variadas taxas de temperatura, esse valor tem relação direta com quantas faixas se pretende realizar o ensaio, em três faixas, 3 vezes o valor total, por exemplo.

Além de ter um custo elevado para construção de gráficos de tensão de escoamento a quente pois demanda mais ensaios, o equipamento utilizado para tração a quente é extremamente mais caro que equipamentos para tração a frio, pois é necessário controlar temperatura e velocidade de deformação.

2.4 Influência dos elementos de liga na tensão de escoamento

As propriedades mecânicas do aço, como resistência à tração, dureza, entre outras, podem ser alteradas através da adição de quantidades reduzidas de um ou mais elementos químicos ao aço carbono convencional.

Propõem-se a adição de diferentes elementos de liga ao aço carbono comum para alcançar um ou mais dos seguintes efeitos. (Costa e Silva, 2008; AMS Internacional, 1990).

- Aumentar a dureza e a resistência mecânica do aço;
- Conferir resistência à corrosão;
- Aumentar a resistência à temperatura;
- Aumentar a resistência ao desgaste;

As propriedades que mais se buscam alterar em um aço são sua ductilidade, resistência mecânica, dureza e resistência a corrosão. (AMS Internacional, 1990).

Na sequência, será discorrido sobre os efeitos resultantes da incorporação de diversos elementos de liga ao aço carbono.

2.4.1 Carbono

O carbono quando combinado com ferro puro forma o aço carbono (< 2,11%) ou o ferro fundido (> 2,11%), ambos considerados ligas metálicas de carbono e ferro, com diferença em sua composição química e propriedades mecânicas. (Chiaverini, 2005; AMS Internacional, 1990).

Na figura 2.9, apresenta-se de maneira aproximada as variações na dureza, observa-se que à medida que o teor de carbono se eleva, há um aumento progressivo na dureza, bem como nas tensões de tração e escoamento.

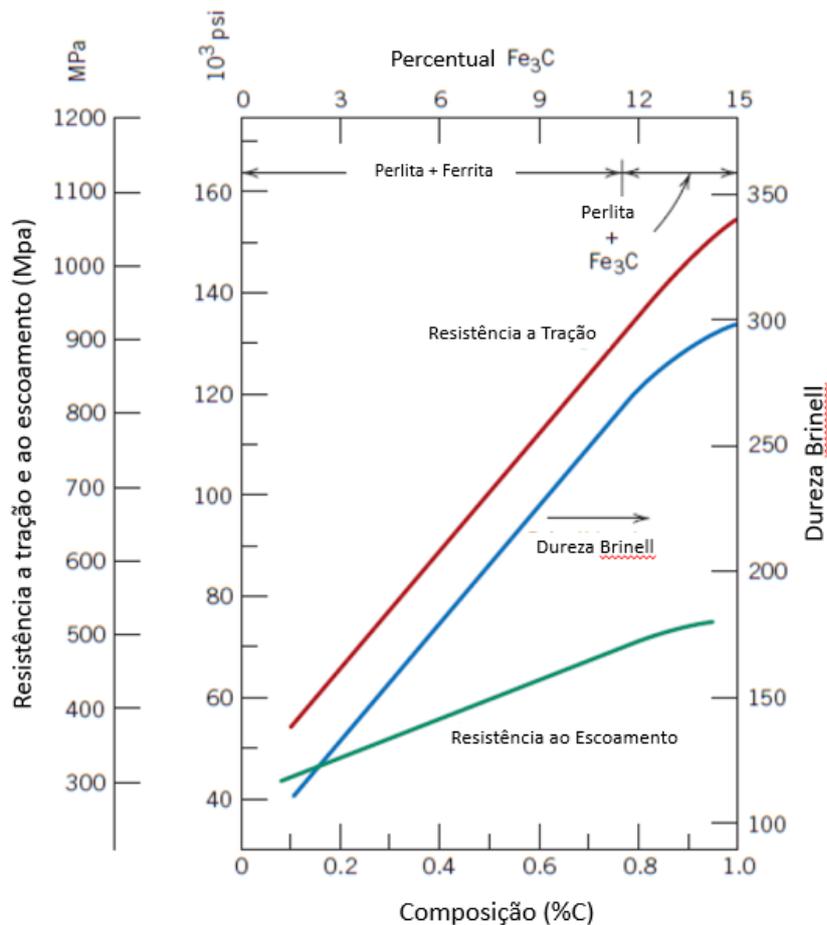


Figura 2.9: Curva de Dureza Brinell, tensão máxima e tensão de escoamento em relação ao teor de carbono no aço

Fonte: (Calister 2002).

2.4.2 Silício

O silício é comumente encontrado nos aços estruturais em teores de 0,15% a 0,40%; é um dos principais desoxidantes utilizado no fabrico de aço, pois apresenta, em sua maioria, maior tamanho de grão, aumentando à resistência a fluência, o que melhora o desempenho dos aços para serviços em alta temperatura. (Costa e Silva, 2008).

O silício é menos eficaz do que o manganês no que se refere ao aumento da resistência e dureza dos aços laminados. (AMS Internacional, 1990)

Na figura 2.10, observa-se que um aumento de 0,15% a 1,1% no percentual de silício variou a resistência mecânica do aço apenas em aproximadamente 70 MPa.

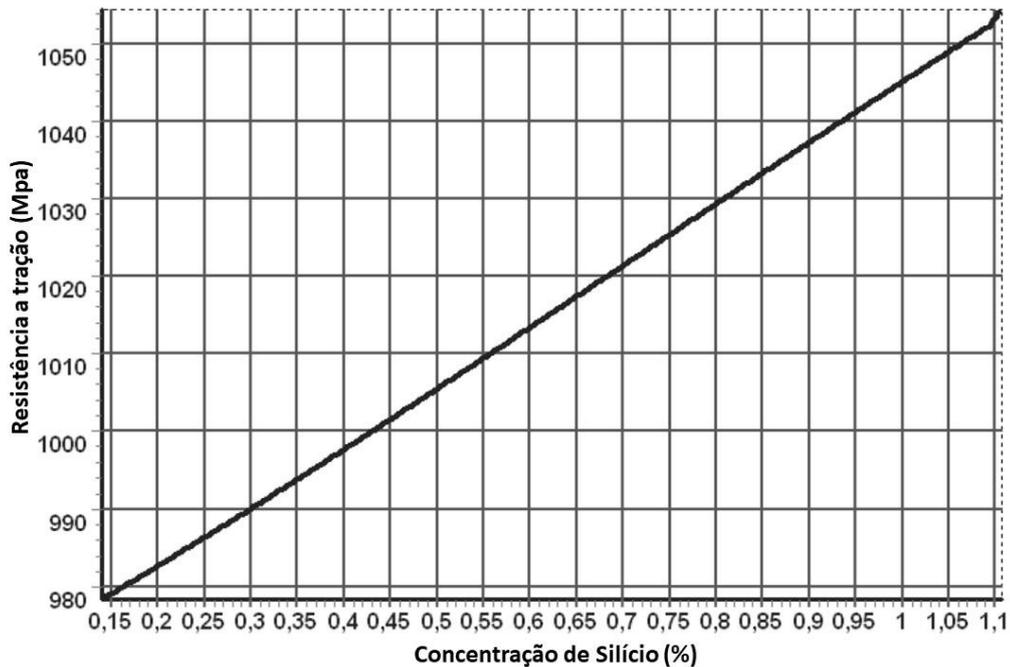


Figura 2.10: Influência da concentração de Silício na resistência a tração do aço ligado 30CrMo5-2.

Fonte: (Dobrzański & Honysz, [s.d.]

2.4.3 Manganês

Os percentuais comumente encontrados de manganês nos aços variam entre 0,40% e 1,60%, porém existem aços especiais com composição de 10 a 15% de manganês.

Devido à maior afinidade do enxofre pelo manganês comparado ao ferro, a presença deste elemento melhora a forjabilidade do aço, pois resulta principalmente na formação de MnS, substituindo o FeS.

Além disso, a presença de manganês aumenta a temperabilidade, a resistência ao impacto e o limite elástico. Entretanto, reduz a ductilidade, e sabe-se que aços com altos teores de manganês são mais propensos a rachaduras durante o processo de têmpera. (AMS Internacional, 1990; Golpaert,1974)

2.4.4 Fósforo

Apesar do fósforo ter algumas vantagens, seus efeitos negativos são mais relevantes, tornando-o frequentemente visto como uma impureza.

Em aços de baixo carbono, os impactos prejudiciais do fósforo são reduzidos, resultando em um incremento da dureza do aço, sua resistência ao desgaste e à corrosão, melhorando assim a resistência à tração. (Costa e Silva, 2008).

Em aços com menos de 0.10% de carbono, o fósforo melhora a usinabilidade, e este efeito é intensificado quando há uma alta concentração de enxofre. Nos aços ligados, a presença de fósforo é aceitável em uma faixa de 0,025% a 0,04%, sendo este o limite máximo. (AMS Internacional, 1990)

2.4.5 Enxofre

Se o aço contiver enxofre em quantidades que o classifiquem como um elemento de liga, é provável que cause o fenômeno conhecido como fragilização a quente. Isso ocorre porque o enxofre forma sulfeto de ferro (FeS), reduzindo o ponto de fusão para cerca de 1000 °C. Para conseguir uma conformação a quente eficiente, adiciona-se manganês à liga. O enxofre tem maior afinidade pelo manganês do que pelo ferro, formando preferencialmente sulfeto de manganês (MnS), que tem um ponto de fusão de 1600 °C. Isso resolve o problema de fragilidade por calor e, como o MnS se forma em partículas minúsculas, melhora a forjabilidade. (Ramos Almeida, 1989; AMS Internacional, 1990)

Devido à alta afinidade do enxofre pelo manganês, na presença de Mn, tende-se a formar sulfeto de manganês (MnS). Este composto possui um ponto de solidificação mais alto que o do aço, solidificando-se primeiro e acumulando-se preferencialmente no centro da peça, tornando essa área frágil e repleta de impurezas. Se submetida a tensões, como as tensões residuais de soldagem, pode ocorrer fratura por decoesão lamelar. Para evitar esse problema, utiliza-se aços com baixo teor de enxofre, limitando a no máximo 0,015% de Enxofre. (AMS Internacional, 1990)

2.4.6 Alumínio

O alumínio é um metal caracterizado por sua leveza e maleabilidade, mas também é notável por sua resistência à corrosão. Essa resistência deve-se à formação rápida de uma fina camada de óxido quando exposto ao ar, conferindo-lhe uma longa durabilidade. (Costa e Silva, 2008).

Na fabricação de aços, o alumínio é considerado um excelente desoxidante. Ele reage com o nitrogênio, formando nitretos, que ajudam a limitar o crescimento de grão. Como resultado, os aços desoxidados com alumínio exibem uma granulação mais fina e uma temperatura de transição mais baixa.

O papel do Alumínio como um agente de fortalecimento de solução sólida é parecido com o do Silício, conhecido por seu forte efeito de endurecimento em soluções sólidas de ferro, mas até pouco tempo atrás, o alumínio não era comumente visto como um elemento de fortalecimento nesse contexto. Embora o Al atue como uma solução sólida substitucional no ferro puro, níveis de até 2% em peso de Al apresentam uma ligeira diminuição na resistência do aço, como observados na figura 2.11. (Palizdar, 2011)

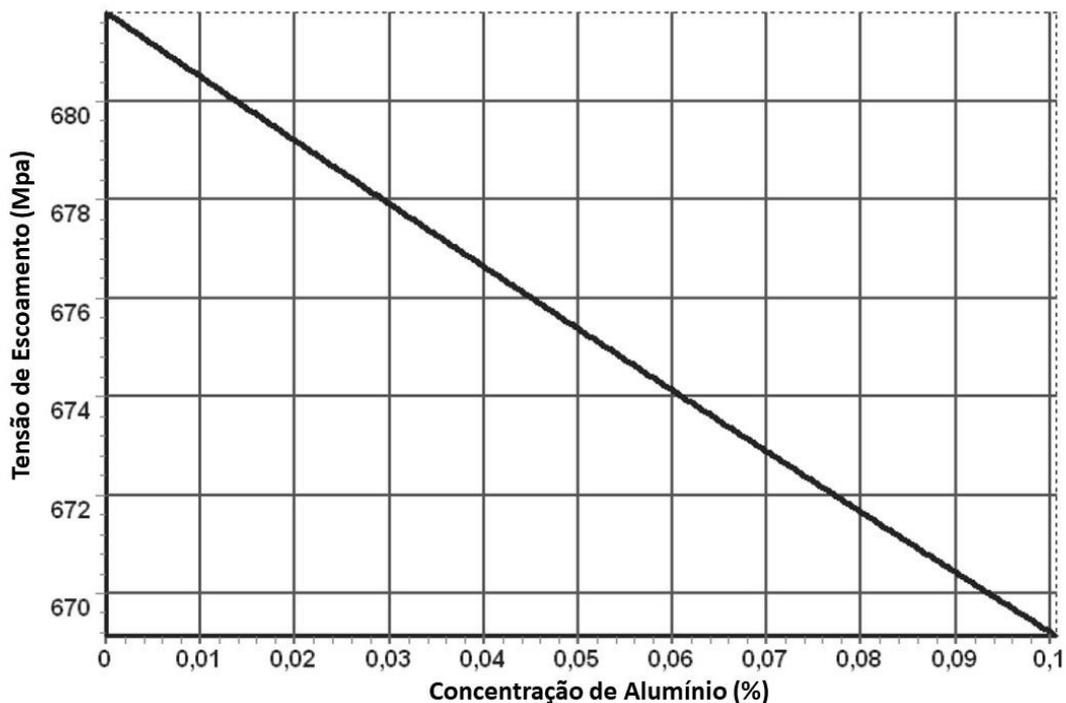


Figura 2.11: Influência da concentração de Alumínio na tensão de escoamento do aço ligado 24CrMo4.

Fonte: (Dobrzański & Honysz, [s.d.]

2.4.7 Cromo

O cromo é um metal cinza, duro, frágil e resistente à corrosão. Quando adicionado ao aço, aumenta a resistência à corrosão, tornando os aços com mais de 12% de cromo inoxidáveis e altamente resistentes à água e a vários ácidos. Além disso, a adição de cromo melhora a

resistência à tração do aço, sua temperabilidade, e aumenta significativamente a resistência a altas temperaturas e ao desgaste. (Totten, 2006; AMS Internacional, 1990)

Na figura 2.12, observa-se um aumento considerável da resistência mecânica conforme se aumenta o percentual de cromo na composição do aço. Com uma variação de 160 MPa de 0,4% a 2,1% de cromo, respectivamente.

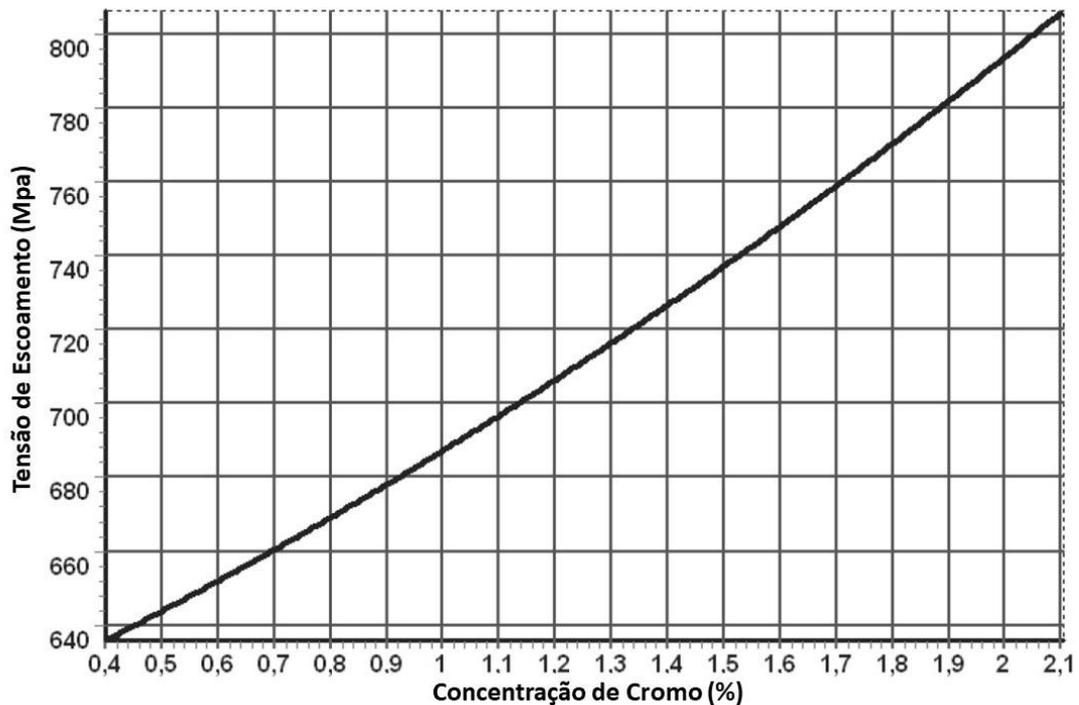


Figura 2.12: Influência da concentração de Cromo na tensão de escoamento do aço ligado 30CrMo5-2.

Fonte: (Dobrzański & Honysz, [s.d.])

2.4.8 Níquel

O níquel, usado como elemento de liga no aço, expande o campo austenítico do diagrama ferro-carbono, melhorando a resistência e tenacidade do material. Além disso, facilita o tratamento térmico ao reduzir a temperatura crítica de resfriamento. Em combinação com o cromo, o níquel gera ligas de aço com maior temperabilidade e resistência ao impacto e à fadiga. (Totten, 2006; AMS Internacional, 1990).

O níquel e o cromo são os elementos chave que compõe os aços inoxidáveis.

2.4.9 Molibdênio

O Molibdênio, empregado como elemento de liga, proporciona ao aço um aumento significativo em dureza e resistência a altas temperaturas. Comumente adicionado aos aços de construção em quantidades que variam de 0,10 a 1%.

O Molibdênio também pode promover endurecimento secundário durante o processo de revenimento em aços temperados. Além disso, ele aprimora a resistência à fluência em altas temperaturas nos aços de baixa liga. (AMS Internacional, 1990; Totten, 2006; Costa e Silva, 2008)

2.4.10 Titânio

O titânio é amplamente usado em aços como desoxidante devido à sua forte tendência para formar carbonetos em altas temperaturas. Além disso, contribui para retardar o crescimento dos grãos, aumentando assim a tenacidade do material.

Ao ser adicionado ao aço, o titânio eleva a resistência à corrosão intergranular e aprimora as propriedades mecânicas em altas temperaturas. Isso ocorre porque ele forma compostos intermetálicos grosseiros, que preservam a dureza do aço mesmo sob temperaturas elevadas. (Souza, 1989; AMS Internacional, 1990)

2.4.11 Vanádio

Adicionado como elemento de liga, o vanádio é comumente encontrado em aços com teores variando de 0,15% a 0,20%. Essa adição resulta na diminuição do tamanho do grão, melhora a resistência ao desgaste em altas temperaturas e favorece a formação de carbonetos duros. Em aços para ferramentas, isso eleva a capacidade de corte. (Totten, 2006)

O vanádio aumenta a resistência à tração dos aços ao carbono. Na figura 2.13, constata-se que a adição de pequenas quantidades desse elemento pode aumentar significativamente a resistência dos aços, sendo um dos principais contribuintes para o reforço por precipitação em aços micro ligados.

Além disso, o vanádio retarda o crescimento dos grãos no interior dos aços, mesmo após longas exposições a temperaturas elevadas. Ele ajuda a controlar o tamanho do grão, promovendo seu refinamento e aumentando a resistência ao impacto. (Totten, 2006; AMS Internacional, 1990)

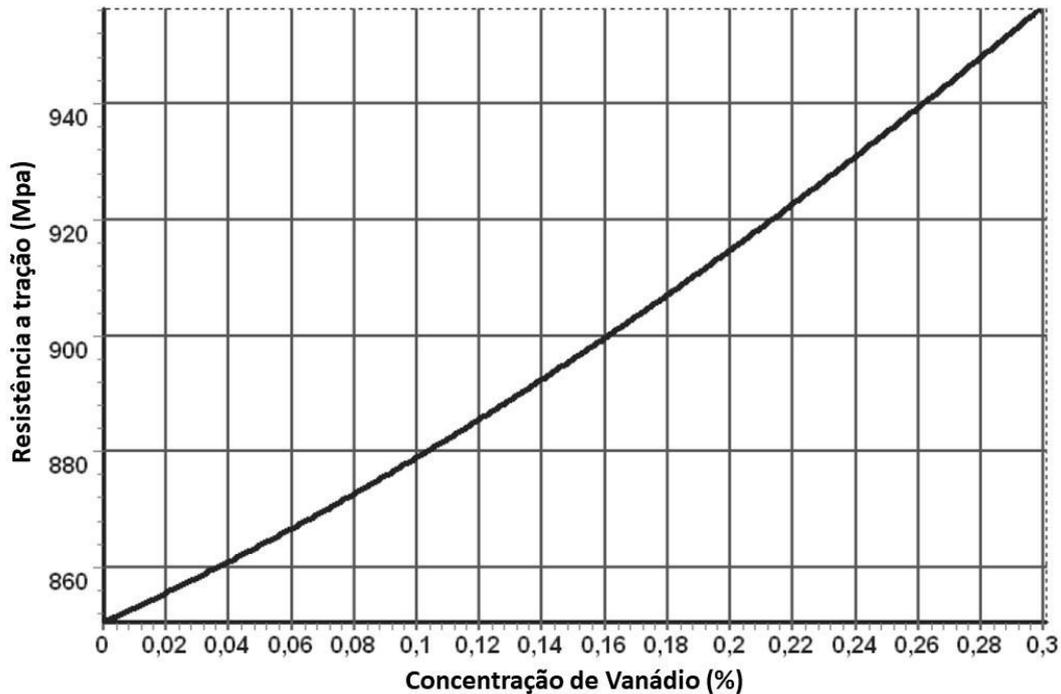


Figura 2.13: Influência da concentração de Vanádio na resistência a tração do aço ligado 42CrMo4.

Fonte: (Dobrzański & Honysz, [s.d.])

2.4.12 Nitrogênio

Embora frequentemente considerado nocivo aos aços por causar a fragilidade do mesmo, o nitrogênio também tem aplicações benéficas. Ele pode formar nitretos ao combinar-se com vários elementos, sendo usado no aço para melhorar sua dureza superficial. (Souza, 1989; AMS Internacional, 1990)

Além disso, o nitrogênio contribui para aumentar a resistência à corrosão localizada, especialmente quando combinado com molibdênio. Sua incorporação em aços austeníticos à base de cromo e níquel estabiliza a estrutura austenítica e reforça a resistência mecânica do material. (Chiaverini, 2005)

2.4.13 Cobre

Na utilização de teores de cobre entre 0,2% e 1,5% em aços, observa-se um aumento na temperabilidade e na resistência à corrosão, particularmente à atmosférica. No entanto, é

importante evitar quantidades muito superiores a esses valores, pois pode ocorrer endurecimento por precipitação, o que tende a diminuir a ductilidade do material quando aquecido. (Costa e Silva, 2008; Totten, 2006)

Outra característica do cobre como elemento de liga é a sua capacidade de aumentar a resistência do aço à fissuração induzida pela pressão de hidrogênio.

2.4.14 Nióbio

Com teores de cerca de 0,03%, a adição de Nióbio aos aços estruturais de alta resistência e baixa liga aumenta a resistência mecânica por meio do refinamento do grão. Com esse nível de concentração, pode-se obter um incremento de 20 a 30% na resistência mecânica de aços carbono comuns. (Chiaverini, 2005; AMS Internacional, 1990)

O nióbio também é empregado em aços inoxidáveis, visando a remoção do carbono que pode formar carboneto de cromo, elemento prejudicial em certos tipos de aços inoxidáveis. (Souza, 1989)

2.5 Redes Neurais Artificiais

O aprendizado de máquina se baseia em três elementos fundamentais: desempenho, tarefa e experiência. Nesse contexto, um software é programado para evoluir através da experiência adquirida em uma classe específica de tarefas. A essência desse aprendizado reside na melhoria contínua do desempenho do programa nas tarefas designadas à medida que acumula experiência ao longo do tempo. Esses sistemas de aprendizado de máquina podem ser representados de maneira concisa pela equação 12: (Liu et al., 2017a; Wu, 2012)

$$\textit{Objetivo} + \textit{Amostra} + \textit{Algoritmo} = \textit{Modelo} \quad (\text{Equação 12})$$

O "Objetivo" representa o problema a ser abordado, frequentemente expresso como uma função objetivo. A "Amostra" é um subconjunto da população selecionado para estudo, sendo frequentemente obtido por meio de pré-processamento de dados. Isso inclui a limpeza de dados, onde partes incompletas, incorretas, imprecisas ou irrelevantes são identificadas e tratadas. A engenharia de recursos também faz parte desse processo, envolvendo a extração, seleção, construção e aprendizado de recursos para otimizar a aplicação de algoritmos de aprendizado de máquina. O componente "Algoritmo" abrange o algoritmo de aprendizado de máquina e o

algoritmo de otimização do modelo. Entre os algoritmos de aprendizado de máquina mais comuns estão Support Vector Machine (SVM), Decision Tree (DT) e Artificial Neural Network (ANN). O "Modelo" é a descrição matemática resultante do processo, refletindo o algoritmo aprendido com base na Amostra. (Wu, 2012)

2.5.1 Fundamentos e Funcionamento das RNA's

As RNA's simulam o funcionamento do cérebro humano, imitando a maneira como os neurônios transmitem sinais entre si. Este mecanismo permite que um computador reconheça padrões e resolva problemas complexos e não lineares, utilizando dados atuais e históricos para executar funções como adaptação, generalização e aprendizado. (Hurwitz & Kirsch, 2018)

As RNA's são compostas por nós, ou neurônios artificiais, conectados em uma estrutura organizada em três camadas principais, conforme esquematizadas na figura 2.14:

1. Camada de entrada: Camada onde as informações são recebidas
2. Camadas ocultas intermediárias: Diversas camadas que tem como função transformar os dados de entrada para formatos onde a rede possa fazer previsões e realizar o chamado "Backpropagation", que é basicamente o algoritmo se ajustando com propósito de otimizar o resultado.
3. Camada de saída: Saídas geradas pela RNA, etapa onde se compara o resultado gerado pela rede com o resultado real, para analisar o erro do sistema.

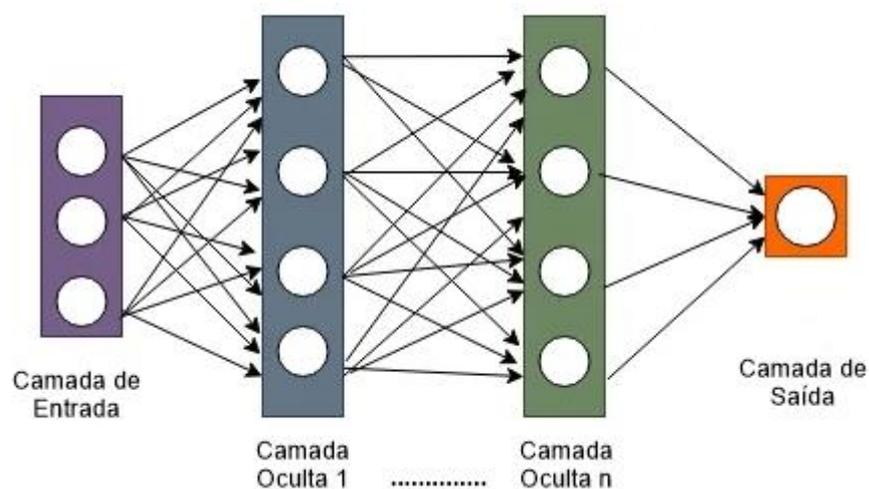


Figura 2.14: Representação esquemática das camadas de uma RNA.

Fonte: Medium (<https://iocratic.medium.com/deep-neural-network-dnn-its-scope-and-nature-of-complexity-56af59f87ea4>)

As RNA's são baseadas no funcionamento do cérebro humano e em conceitos matemáticos de aprendizagem, processamento e gerenciamento de informações. Na figura 2.15, observa-se as entradas ($X_1, X_2, X_3, \dots, X_i$) e os respectivos pesos ($W_1, W_2, W_3, \dots, W_i$) das funções de entrada. A combinação linear desses dados de entrada (funções de entrada e peso) resulta na saída. Nessa situação, 'j' representa a conexão entre os neurônios artificiais, e 'i' denota os pontos de processamento computacional. (Kashid & Kumar, 2013)

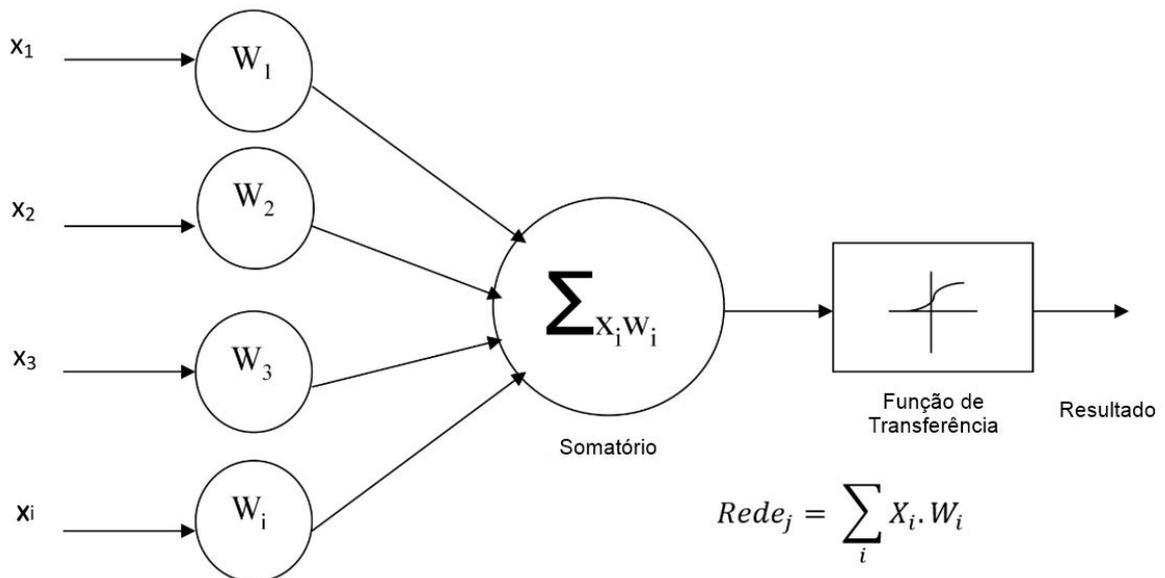


Figura 2.15: Representação de uma rede neural com dados de entrada e pesos.

Fonte: (Kashid & Kumar, 2013)

A rede neural usada varia conforme o uso pretendido, e a escolha da rede mais apropriada é influenciada pela complexidade do problema a qual se pretende usá-la. Decisões sobre a estrutura da rede, como o número de neurônios em cada camada e a função de transferência aplicada em cada uma, terão impacto significativo no desempenho e na eficácia de tomada de decisões da rede. (Kong & Nahavandi, [s.d.])

2.5.2 Aplicações de RNA's na Conformação Mecânica

Existem diversos trabalhos referentes a aplicação de RNA's em processos de usinagem e sistemas de monitoramento de ferramentas. A maior parte destes estudos investiga o uso de diversos parâmetros de entrada e utilizam RNA's para acompanhar o desgaste das ferramentas durante os processos. (Osakada & Yang, 1991)

As Redes Neurais Artificiais, inspiradas no funcionamento do cérebro humano, também são capazes de prever as condições das ferramentas e monitorar os processos de moldagem mecânica. (Kong & Nahavandi, [s.d.]

OSAKADA utilizou RNA's para identificar métodos apropriados de forjamento e a quantidade de etapas de moldagem necessárias para fabricar um componente específico com base na geometria do produto, como mostra a Figura 2.16.

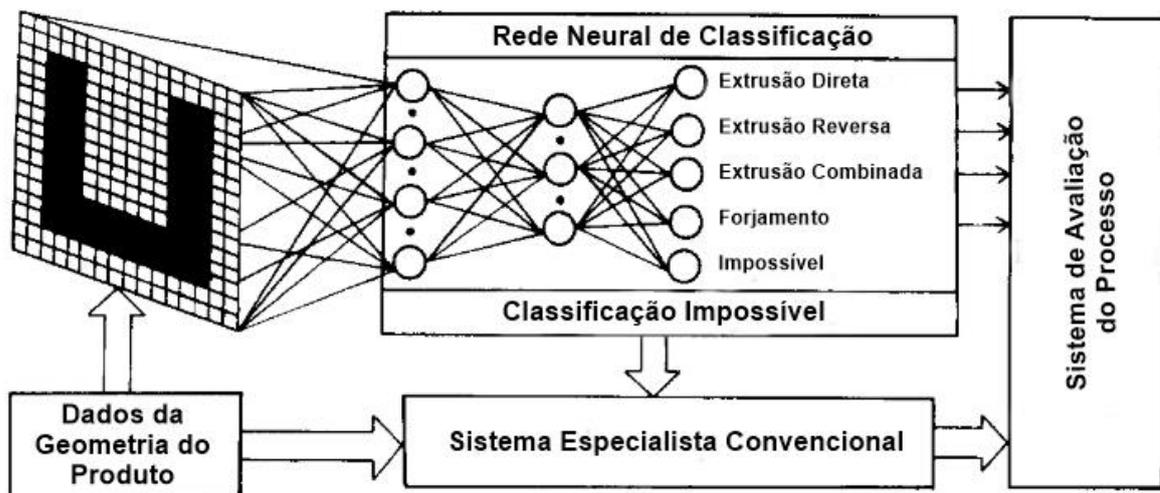


Figura 2.16: Diagrama para determinação do Método de Conformação
Fonte: (Osakada & Yang, 1991)

OSAKADA E YANG utilizaram RNA's para prever a ocorrência de fraturas na matriz e imperfeições na superfície do produto final. Além disso, integraram RNA's com o método dos elementos finitos para estimar as forças envolvidas e dimensionar a matriz usada no processo, projetar a geometria da ferramenta e antecipar as forças necessárias para o processo de moldagem.

Mrzyglód et al. empregaram RNA's no desenvolvimento de um sistema de assistência à produção, capaz de prever a vida útil das ferramentas de forjamento no processo de forjamento

a quente. Esse sistema calcula o desgaste geométrico da ferramenta com base em parâmetros operacionais como número de forjamentos, temperatura da ferramenta, tipo de revestimento protetor, pressão e atrito, e avalia a probabilidade de ocorrência dos mecanismos comuns de desgaste da ferramenta. Na figura 2.17 está uma ilustração simplificada da estrutura desse sistema.

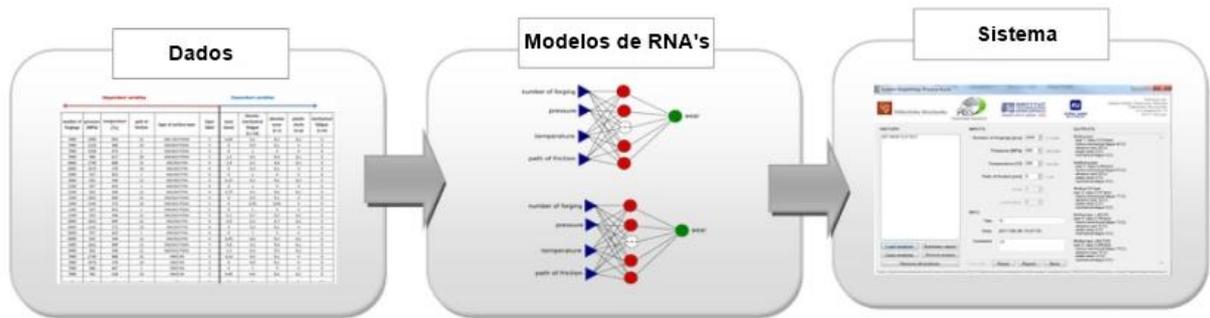


Figura 2.17: Ilustração simplificada da estrutura do sistema de assistência à produção

Fonte: (Mrzyglód et al., [s.d.])

SPATHOPOULOS & STAVROULAKIS desenvolveram um sistema baseado numa RNA para prever o retorno elástico em processos de moldagem de chapas metálicas, conforme ilustrado na Figura 2.18. Eles treinaram as redes neurais utilizando dados de entrada derivados de análises numéricas por elementos finitos. Os resultados mostraram um erro quadrático médio de 0,1473, um coeficiente de regressão de 0,9653 e um desvio médio de 1,1673, indicando uma alta correlação entre os valores previstos e os valores-alvo desejados.

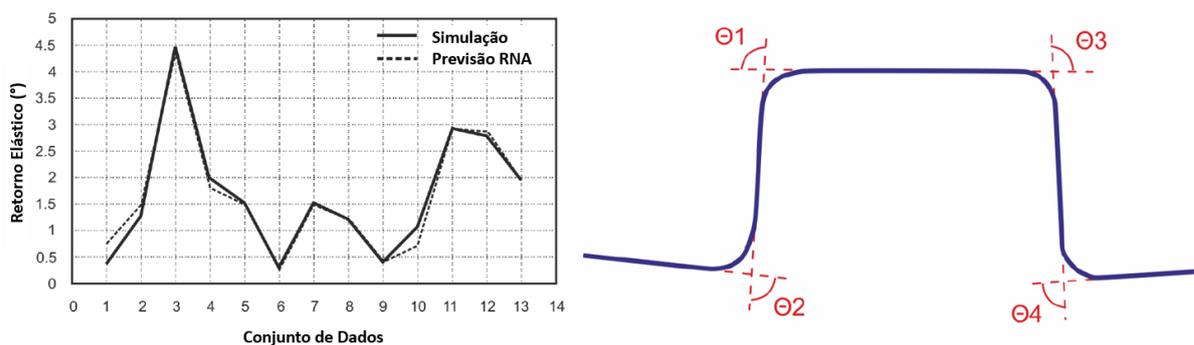


Figura 2.18: Comparação entre os resultados de previsão de elementos finitos e RNA de ângulos de retorno elástico

Fonte: (Spathopoulos & Stavroulakis, 2020)

NAJM E PANITI utilizaram Redes Neurais Artificiais para investigar e identificar materiais apropriados e a geometria ideal para ferramentas de estampagem incremental. Eles usaram parâmetros do processo como dados de entrada, derivados de valores experimentais reais. A RNA foi empregada para estimar a conformabilidade e a precisão geométrica dos produtos. Além disso, uma fórmula analítica foi desenvolvida para cada resultado, baseando-se nos pesos extraídos e na melhor previsão da rede. Esta abordagem analítica mostrou-se mais rápida e prática para definir os parâmetros do processo em comparação com métodos experimentais.(Najm & Paniti, [s.d.]

3.0 MATERIAIS E MÉTODOS

O objetivo principal deste estudo é desenvolver uma Rede Neural Artificial (RNA) que possa prever a tensão de escoamento a quente de vários materiais com base em sua composição química. Para atingir isso, é essencial cumprir vários objetivos específicos. A Figura 3.1 ilustra um fluxograma detalhando cada etapa desse processo.

Para explicar as fases deste trabalho de maneira clara e organizada, este capítulo está estruturado da seguinte forma:

- 3.1 Determinação de parâmetros para a RNA
- 3.2 Coleta e preparação dos dados
- 3.3 Projeto e calibração da RNA
- 3.4 Avaliação do desempenho da RNA
- 3.5 Validação experimental da RNA

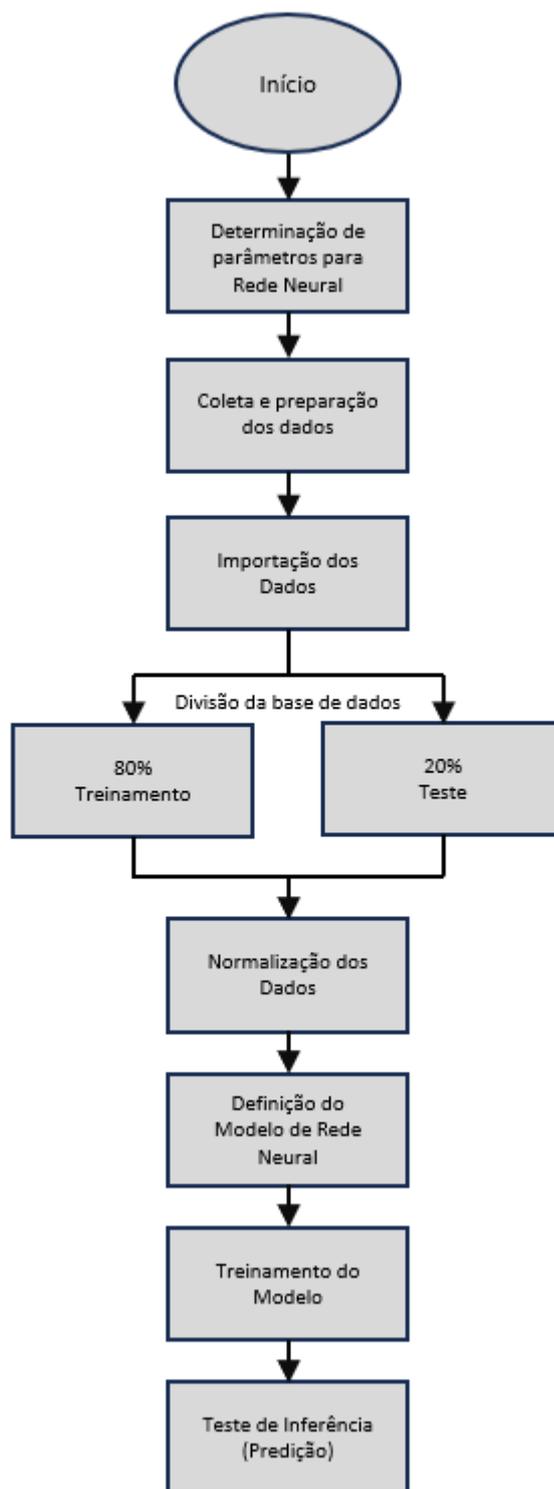


Figura 3.1: Fluxograma da Criação da Rede Neural

Fonte: Autor

3.1 Determinação de parâmetros para a RNA

Como visto na seção 2.4 deste trabalho, todos elementos de liga têm influência nas propriedades mecânicas do aço, em diferentes níveis de intensidade, e é exatamente essa diferença de composição e presença de elementos que altera as propriedades mecânicas de um aço em comparação com outro. Esses elementos, mesmo em pequenas quantidades, podem resultar em mudanças significativas nas propriedades mecânicas do aço, como dureza, ductilidade, resistência à tração e à corrosão.

A complexidade da interação entre essa composição de elementos e as propriedades mecânicas finais dos aços torna a aplicação de RNA's muito chamativa para entender, modelar e prever estes resultados.

Com a capacidade de aprender padrões complexos a partir de grandes conjuntos de dados, as RNAs podem identificar relações não óbvias entre a composição do aço e suas propriedades. Isso não apenas ajuda a entender melhor a ciência dos materiais, mas também permite o desenvolvimento de novas ligas com propriedades customizadas para aplicações específicas.

Neste trabalho, será desenvolvido uma Rede Neural que relaciona o teor de 15 elementos de ligas presentes em diferentes categorias de aços, sejam aços comuns ao carbono, como também os inoxidáveis.

Para isso, serão estabelecidos valores fixos de deformação, bem como valores fixos de velocidade de deformação, para verificar, nas mesmas condições, a diferença da tensão de escoamento do aço A para o aço B, por exemplo, que tenham respectivamente, 0,10% e 0,20% de carbono em sua composição química.

Na figura 3.2 abaixo, é ilustrado como é a relação entre a composição química e a tensão de escoamento a quente e como serão feitas essas análises.

- São inputs fixos os dados que tem relação com a execução do experimento, como a velocidade de deformação e a deformação total a qual a amostra será submetida.
- São inputs variáveis, os aços e suas composições químicas, e a temperatura de realização do ensaio, para obter a curva de escoamento para diferentes temperaturas.
- É output o resultado de tensão de escoamento para cada caso.

Inputs Variáveis					Inputs Fixos		Output	
Aços	Composição Química (%)				Temperatura (°C)	Deformação (mm)	Velocidade de deformação(s ⁻¹)	Tensão de Escoamento (Mpa)
	Carbono	Silício	Manganês	Outros Elementos				
Aço A	0,10	0,1	0,2	...	900	0,4	0,01	350
Aço B	0,20	0,15	0,25	...	900	0,4	0,01	450
.....								
Aço A	0,10	0,1	0,2	...	1200	0,4	0,01	200
Aço B	0,20	0,15	0,25	...	1200	0,4	0,01	300

Figura 3.2: Representação Esquemática da interação entre os elementos químicos do aço e obtenção da tensão de escoamento a quente.

Fonte: Autor

3.2 Coleta e preparação dos dados

O conjunto de dados de entrada utilizado neste trabalho foi obtido na biblioteca de materiais do software de elementos finitos QForm UK 10.2.1 (Micas Simulations Ltd.).

O banco de dados fornece informações de uma ampla gama de materiais comumente utilizados em processos de conformação mecânica, incluindo várias ligas de aço. É possível acessar a curva de escoamento de cada material, em diferentes taxas de deformação e temperaturas. Também estão disponíveis as composições químicas dos materiais. Todas essas informações podem ser baixadas como um documento Excel. Como não é possível obter informações de múltiplos materiais simultaneamente, foi necessário baixar os dados de cada material individualmente. Do software foram coletados os seguintes dados.

Nomenclatura e família dos aços: 10 diferentes famílias de aços foram registradas, conforme a figura 3.3 abaixo

Aços registrados (DIN)									
Aço C	Aço CrC	Aço CrV-CrMo	Aço Estrutural	Aço H	Aço Mn	Aço MnCr	Aço MoCr	Aço NiCr	Aço Inox
C10	15Cr3	14CrMoV6-9	P355N	X12CrNiMo12	95Mn28	16MncR5	9CrMo4-5	12Ni19	1-4044
C15	20Cr4	17CrMoV10	P355NL1	X12NiCrSi36-16	12Mn6	16MnCr55	10CrMo9-10	14NiCr14	X2CrNiMo17-13-2
C22	28Cr4	20CrMpV13-5	S690Q	X15CrNiSi20-12	17Mn4	20MnCr5	16CrMo4-4	14NiCr18	X2CrNiMoN22-5-3
C25	34Cr4	21CrMoV5-7	S690QL1	X53CrMnNiN21-9	19Mn5	90MnCr8V8	16Mo3	16CrNiMo6	X3CrNiMoAl13-8-2
C30	37Cr4	35CrMoV10-4	S790QL1		21Mn4		22CrMo4-4	17CrNi6-6	X4NiCrTi25
C35	38SiCrV6	42CrMoV7-3	S890QL1		28Mn6		34CrMo4	18NiCr6-4	X4NiCrTi25-15
C40	41Cr4	58CrV4	StE500		30Mn5		37CrMo3	20NiCrMo14-6	X5CrNiMo17-12-2
C45	55Cr3	115CrV3			36Mn4		42CrMo4		X6CrNiMoTi17-12-2
C45W	90CrSi5	X40CrMoV5-1-1			36Mn6		50CrMo4		X6CrNiTi18-10
C50D	100Cr6	X165CrMoV12			36Mn7		85CrMo7		X10NiCr32-20
C55					38MnSi4		G20Mo5		X12Cr13
C60					40Mn4				X15Cr13
C75					41MnV5				X20Cr13
35S20					46Mn5				X30Cr13
					64Mn3				X38Cr13
					70Mn3				X45CrSi9-3
					S355J2				X90CrMoV18
					S355J2G3				

Figura 3.3: Tabela de aços coletados

Fonte: Autor

Composição química: A definição da composição química foi realizada mediante o registro do carbono e outros 14 elementos químicos, conforme tabela abaixo.

Elementos químicos registrados	
Carbono	Molibdênio
Silício	Titânio
Manganês	Vanádio
Fósforo	Berílio
Enxofre	Nitrogênio
Alumínio	Cobre
Cromo	Nióbio
Níquel	

Tabela 3.1: Elementos químicos registrados.

Temperatura: Cada aço teve sua curva de escoamento registrada em cinco diferentes temperaturas, que variam entre 700°C a 1250°C. Essa ampla faixa de temperatura permite uma análise abrangente da tensão de escoamento a quente do material.

Temperatura (°C)
700
850
1000
1100
1250

Tabela 3.2: Faixas de temperatura registradas.

Velocidade de deformação: Serão considerados seis diferentes valores de velocidade de deformação para cada aço, variando de 0,01 até 100 s⁻¹.

Velocidades de Deformação (s ⁻¹)
0,01
0,1
1
10
100
500

Tabela 3.3: Valores de velocidade de Deformação.

Deformação: Serão registrados oito valores de deformação, que variam de 0,04 mm até 1,5 mm.

Valores fixos de deformação (mm)
0,04
0,10
0,20
0,40
0,60
0,90
1,20
1,50

Tabela 3.4: Valores de Deformação.

Na figura 3.4 abaixo, está a interface do banco de dados do software, onde A são as diferentes temperaturas, B os valores de deformação, C velocidades de deformação e D a composição química.

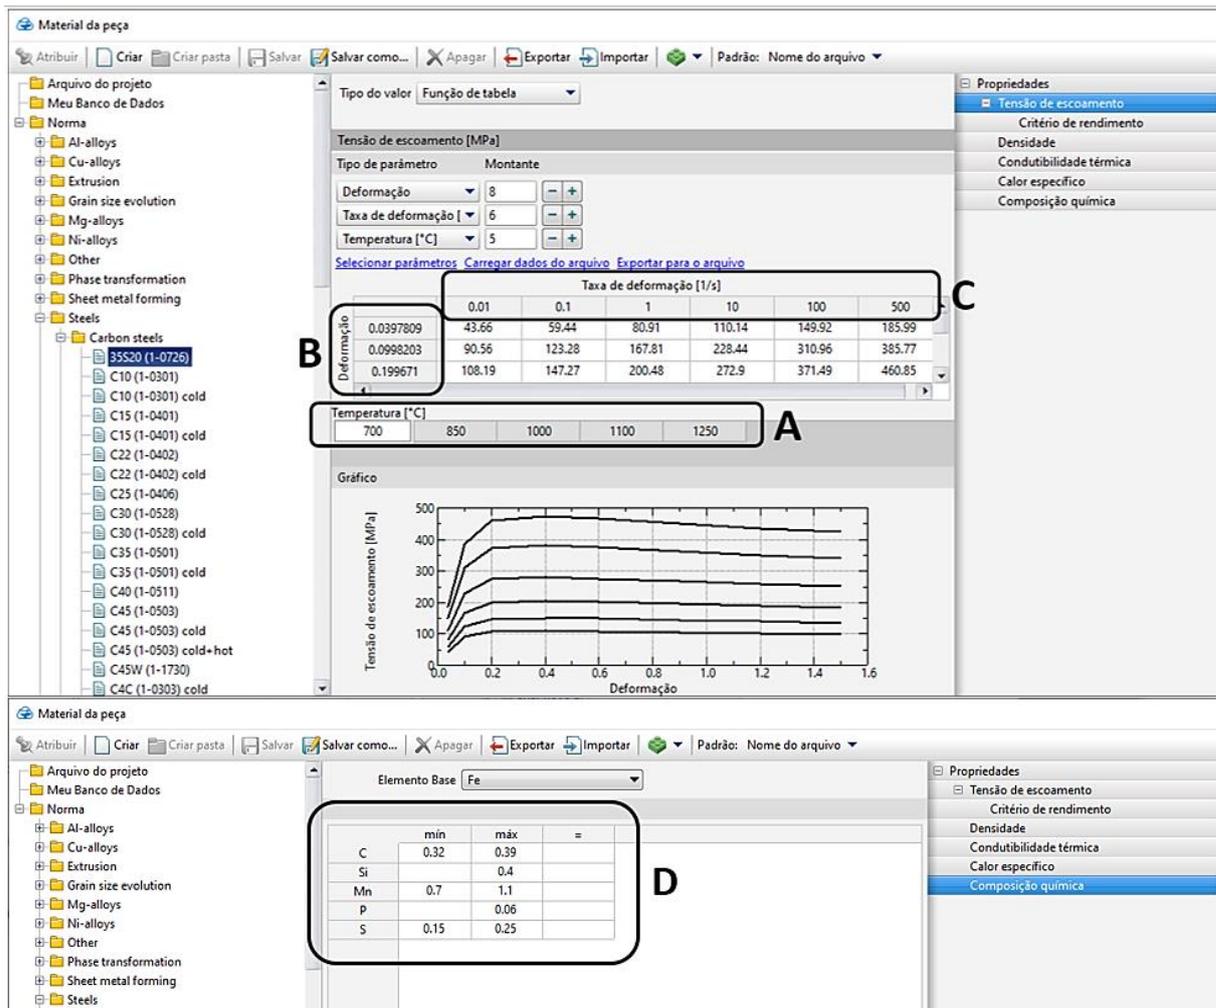


Figura 3.4: Banco de dados do software, mostrando as diferentes temperaturas, velocidades de deformação e deformação.

Fonte: Autor

Portanto, para cada aço, testado em cinco diferentes temperaturas, seis diferentes velocidades de deformação e oito valores de deformação, serão coletados 240 resultados de tensão de escoamento. Na figura 3.5 é mostrado uma parte da tabela.

AÇO	COMPOSIÇÃO QUÍMICA DO AÇO															TEMPERATURA	VELOCIDADE DEFORMAÇÃO	DEFORMAÇÃO	TENSÃO DE ESCOAMENTO	
	NOME	C	Si	Mn	P	S	Al	Cr	Ni	Mb	Ti	V	Be	N	Cu	Nb	VARIÁVEL	VARIÁVEL	FIXA	RESULTADO
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	0,03978087	43,66
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	0,099820335	90,56
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	0,199671195	108,19
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	0,400477567	111,54
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	0,599656837	109,42
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	0,898942094	105,59
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	1,200645014	102,26
35S20	0,39	0,4	1,1	0,06	0,25	0	0	0	0	0	0	0	0	0	0	0	700	0,01	1,500583508	99,46

Figura 3.5: Tabela dos dados coletados do software.

Fonte: Autor

3.3 Projeto e calibração da RNA

O trabalho é desenvolvido em duas fases principais compostas, respectivamente, pela fase de criação do conjunto de dados (capítulo anterior) e fase de previsão e análise.

Uma vez filtrados e transformados em arquivo csv, os dados foram importados para o GoogleColab. Esta ferramenta permite realizar testes rápidos e implementações de bibliotecas que minimizam o trabalho do desenvolvedor da solução na definição do projeto da rede neural artificial.

Para garantir que todas as características contribuam igualmente para o treinamento da rede, independentemente de suas escalas originais, foi realizada a normalização dos dados. O processo consiste em ajustar os valores das variáveis de entrada para que fiquem em uma escala padrão. Foi utilizada a técnica de normalização Z-score. Esta técnica utiliza a Equação 13 para gerar uma distribuição com média zero e desvio padrão igual a um.

$$Z = \frac{x-u}{s} \quad (\text{Equação 13})$$

Onde x corresponde ao valor da amostra de treinamento, u é a média e s é o desvio padrão das amostras de treinamento.

O próximo passo consiste na seleção da arquitetura da RNA. Esta tarefa desempenha um papel crucial no desempenho e na capacidade de generalização do modelo, e está intrinsecamente ligada às características dos dados de treinamento. Para atender a proposta deste trabalho, com a previsão de curva de escoamento de ligas de aço de forma eficaz e precisa, foi modelada uma arquitetura de Rede Neural Densa (RND). Essa classe de redes tem capacidade para aprender representações hierárquicas mais abstratas, sendo adequada para dados complexos com relações não lineares e padrões intrincados. Ao selecionar esta arquitetura busca-se fortalecer a propagação de recursos e maximizar o reconhecimento de conexões de rede entre os nós. Em uma RND, cada neurônio recebe uma soma ponderada das saídas dos neurônios conectados a eles, fazendo cálculos mais rápidos para aprender estimativas sobre os conjuntos de treinamento. (Morales-Molina et al., 2021)

Após a definição da arquitetura, é realizado o processo de desenvolvimento do modelo, onde diferentes arquiteturas são testadas e ajustadas. Para aprimorar o desempenho do modelo de inteligência artificial, é preciso encontrar a combinação ideal de parâmetros que melhor se adapta aos dados e ao problema em questão. Nesse processo, é adotada uma abordagem iterativa que envolve tentativa e erro. Inicialmente, o conjunto de treinamento é dividido em duas partes: um conjunto temporário de treinamento, que contém 80% dos dados, e um conjunto de validação, que engloba os 20% restantes. Essa divisão é realizada aleatoriamente e repetida. Para cada modelo, treinado com o conjunto temporário de treinamento, são efetuadas previsões no conjunto de validação e, em seguida, avaliações do desempenho preditivo.

É fundamental destacar que, para evitar qualquer viés nos resultados, é realizada essa divisão dos dados em 80% treinamento e 20% teste. Essa prática visa prevenir o overfitting, um fenômeno no qual o modelo se ajusta excessivamente aos dados de treinamento específicos, comprometendo sua capacidade de generalização. Ao adotar essa estratégia, busca-se assegurar a obtenção de métricas precisas e relevantes para avaliar a eficácia e a generalização do modelo em situações não vistas durante o treinamento. (Schmidhuber, 2015)

Um limite máximo de 5000 iterações de treinamento foi estabelecido para prevenir possíveis loops infinitos. Essa abordagem visa garantir eficiência computacional e evitar excessos na adaptação do modelo aos dados de treinamento.

Após a conclusão de todas as iterações de treinamento e predição, a fase subsequente envolve uma análise abrangente. Uma extensa bateria de métricas estatísticas é computada, e diversos gráficos são gerados para resumir as etapas de treinamento e previsão, fornecendo uma base sólida para a discussão dos resultados. (Fernández et al., 2020)

A avaliação do desempenho do modelo foi baseada em três métricas. A primeira é o Erro Quadrado Médio (MSE) definido por:

$$MSE = \sqrt{\frac{1}{j} \sum_{i=1}^j \left(\frac{y_i - y_i^*}{y_i} \right)^2} \quad (\text{Equação 14})$$

Onde j é o número de conjuntos que incluem dados de entrada e saída, y_i e y_i^* são, respectivamente, os valores de resposta medidos e previstos para as variáveis de saída.

O MSE é uma métrica comum em problemas de regressão. Ela mede a média dos quadrados das diferenças entre as previsões do modelo e os valores reais. Quanto menor o MSE, melhor o desempenho do modelo.

A segunda métrica é o Erro Médio Absoluto (MAE), que é dado por:

$$MAE = \frac{1}{j} \sum_{i=1}^j |y_i - y_i^*| \quad (\text{Equação 15})$$

Também foi calculado o valor R^2 , dado por:

$$R^2 = 1 - \frac{\sum_{i=1}^j (y_i - y_i^*)^2}{\sum_{i=1}^j (y_i - \bar{y})^2} \quad (\text{Equação 16})$$

Onde \bar{y} corresponde à média dos valores de resposta medidos das variáveis de saída. R^2 é uma métrica de regressão que mede a proporção da variabilidade nos dados explicada pelo modelo. Um R^2 mais alto indica um melhor ajuste do modelo aos dados e uma maior probabilidade de o modelo fazer boas previsões para dados não vistos.

4.0 RESULTADOS E DISCUSSÃO

4.1 Avaliação da influência uniforme de cada elemento

Na figura 4.1 abaixo está a relação entre o total de materiais registrados e a frequência que cada elemento de liga aparece, observa-se que existem elementos de liga que aparecem em todos os aços coletados (C, Si, Mn, P, S), seguidos do Cr que aparece em 90% dos aços coletados, Ni e Mb em 40% e os demais com aparições pontuais abaixo de 30%.

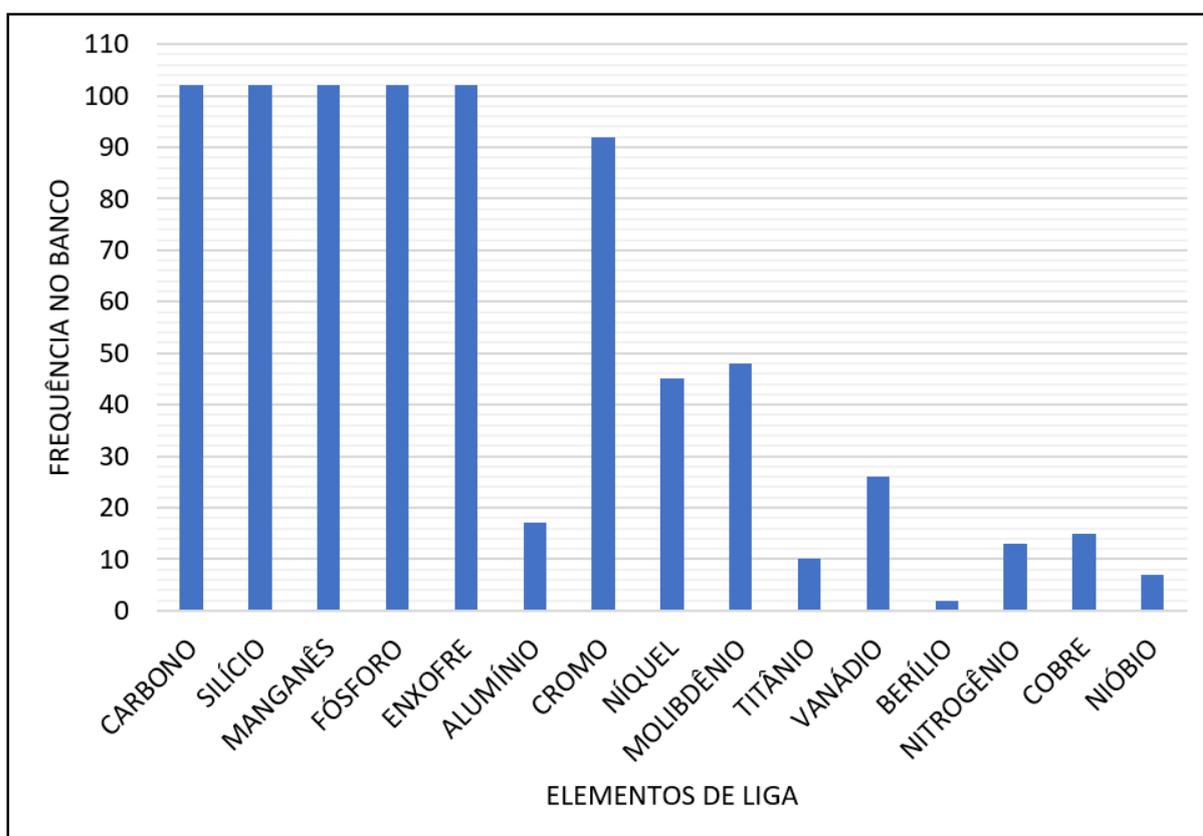


Figura 4.1: Frequência de cada elemento de liga na base de 102 materiais.

Fonte: Autor

Para explorar a natureza do banco de dados, foram plotados gráficos que relacionam a tensão de escoamento com o conteúdo dos elementos de liga. A Figura 4.2 mostra esta relação para os elementos C, Si, Mn, Cr, Mo e Ni. Os valores de k_f registrados correspondem a tensão de escoamento requerida para gerar uma deformação $\varphi = 1,5$ em uma velocidade de deformação $\dot{\varphi} = 1s^{-1}$ e a uma temperatura $\vartheta = 1000^\circ C$.

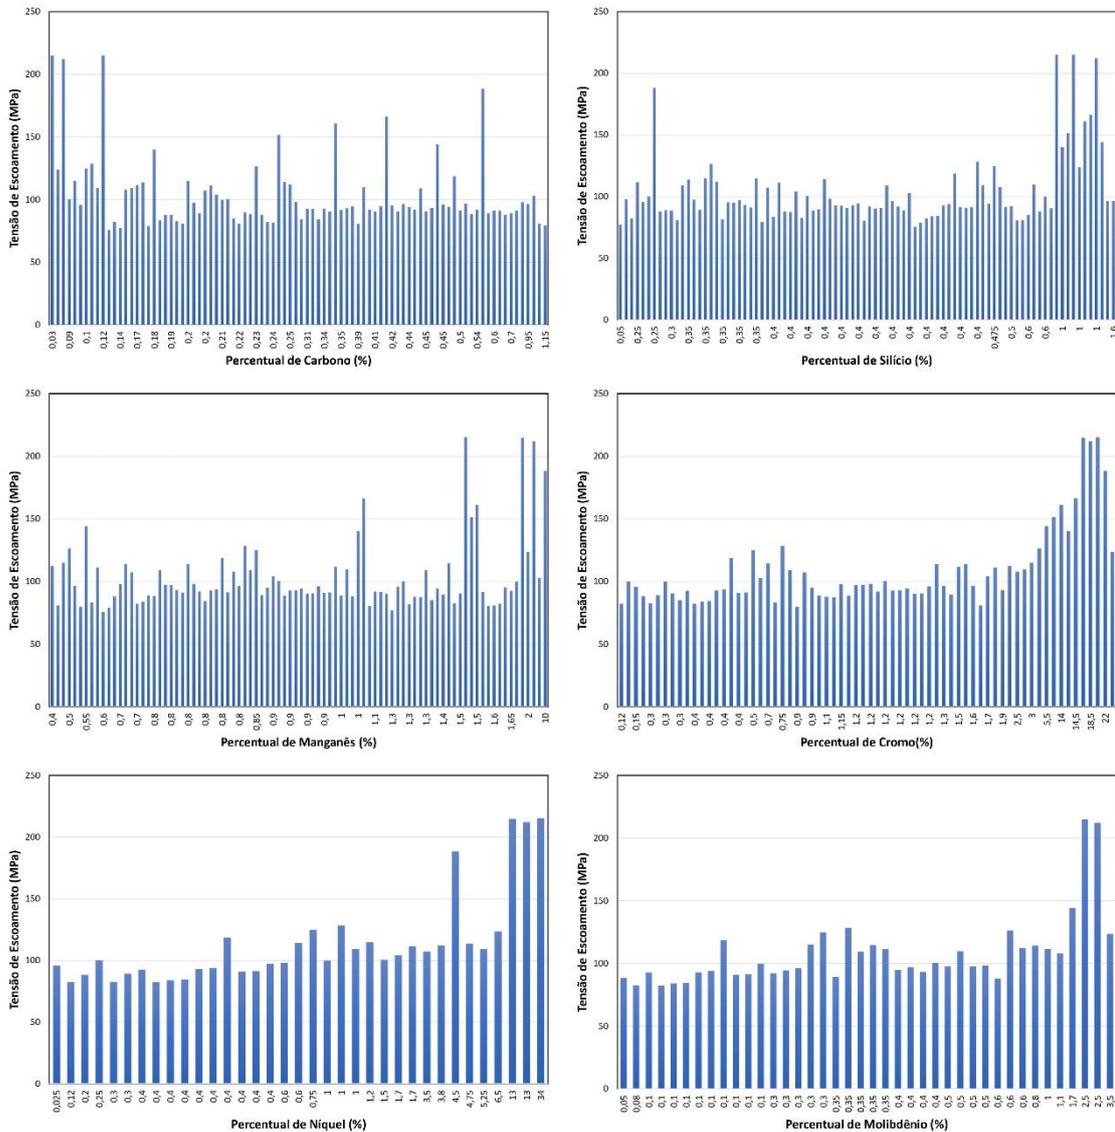


Figura 4.2: Análise da influência da composição dos elementos de liga na tensão de escoamento. Os valores de k_f registrados correspondem a tensão de escoamento requerida para gerar uma deformação $\varphi = 1,5$ em uma velocidade de deformação $\dot{\varphi} = 1s^{-1}$ e a uma temperatura $\vartheta = 1000^\circ C$.

Fonte: Autor

É possível observar que os dados apresentam relações intrincadas e não lineares. Ao analisar o gráfico relacionado ao teor de carbono, por exemplo, a expectativa seria de um aumento contínuo na tensão de escoamento com o aumento de % C. Entretanto, a Figura 4.2 revela que os valores de k_f não seguem uma relação linear com o teor de carbono. Isso é observado também para os demais elementos.

Do ponto de vista metalúrgico, essa observação destaca a complexidade envolvida na deformação a quente, tornando desafiador quantificar o efeito individual de cada elemento de liga na resistência mecânica dos aços. Ao contrário da conformação a frio, na qual a deformação está associada principalmente ao encruamento do material, o trabalho a quente engloba uma série de fenômenos metalúrgicos. Nesse contexto, o valor da tensão de escoamento não apenas reflete o impacto de um determinado elemento na magnitude da recuperação e na recristalização dinâmica, mas também influencia a cinética desses fenômenos. Essa complexidade acrescentada torna a análise consideravelmente mais desafiadora.

4.2 Avaliação do desempenho da RNA

O modelo foi adaptado com uma camada de entrada, duas camadas ocultas e uma camada de saída, conforme Figura 4.3. A camada de entrada possui 18 neurônios que incluem os elementos químicos que compõe a composição das ligas de aço, valores de deformação verdadeira (φ), de velocidade de deformação ($\dot{\varphi}$) e de temperatura (ϑ). As camadas ocultas são compostas por 20 neurônios cada uma e a camada de saída possui um neurônio. A saída da rede neural corresponde ao valor de tensão de escoamento (k_f) obtido quando o material, definido por uma determinada composição química, é submetido a um valor específico de φ , em uma determinada $\dot{\varphi}$ e ϑ . Como total, a rede possui 801 parâmetros para serem treinados.

As camadas ocultas permitem que a rede aprenda representações mais abstratas e complexas dos dados, o que é crucial quando as relações entre as variáveis não são simplesmente lineares. A capacidade das RND de atuarem como aproximadores universais, combinada com a flexibilidade proporcionada pelas camadas ocultas, facilita a modelagem de relações mais complexas e não lineares presentes nos dados. Esta topologia resultou de uma série de etapas de otimização destinadas a equilibrar a capacidade de aprendizagem com os recursos necessários para o treinamento. (Deshpande & Kumar, 2018)

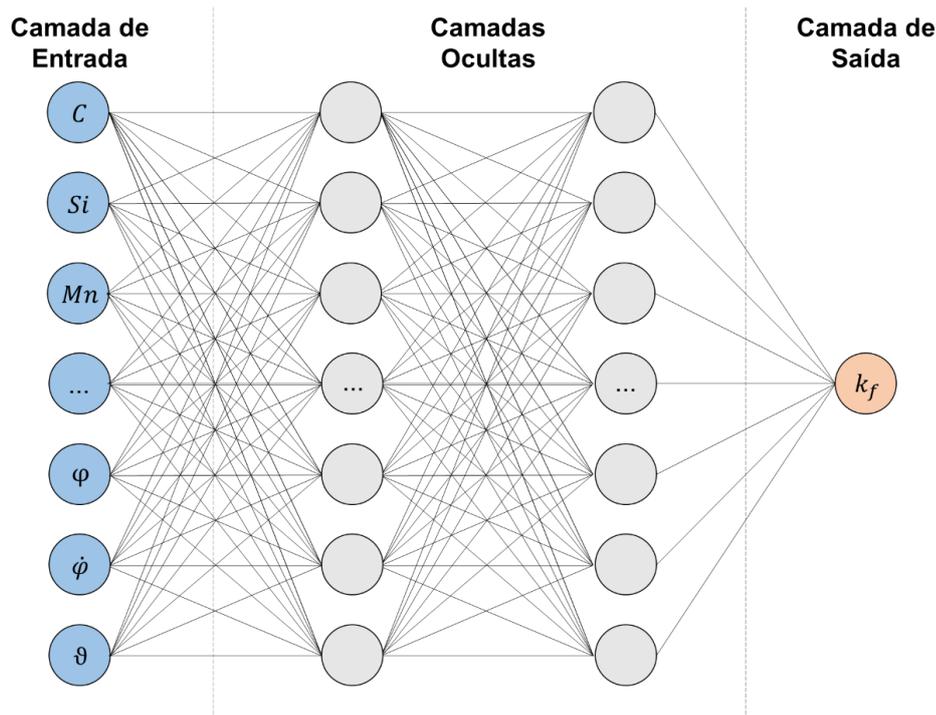


Figura 4.3: Arquitetura da Rede Neural Artificial Densa proposta.

Fonte: Autor

Inicialmente, a rede neural foi treinada com dados provenientes de 70 materiais e, posteriormente, a base de dados foi ampliada para 100 ligas de aço. A Figura 4.4 apresenta a evolução do Erro Absoluto Médio em função do número de iterações para o treinamento com (a) 70 e (b) 100 materiais. A Figura 4.5 apresenta a evolução do Erro Quadrático Médio em função do número de iterações para o treinamento com (a) 70 e (b) 100 materiais. Estes gráficos são ferramentas valiosas para compreender o desempenho e a convergência do modelo ao longo do tempo. Os gráficos fornecem insights sobre como o algoritmo de treinamento está ajustando os pesos da rede para minimizar os erros.

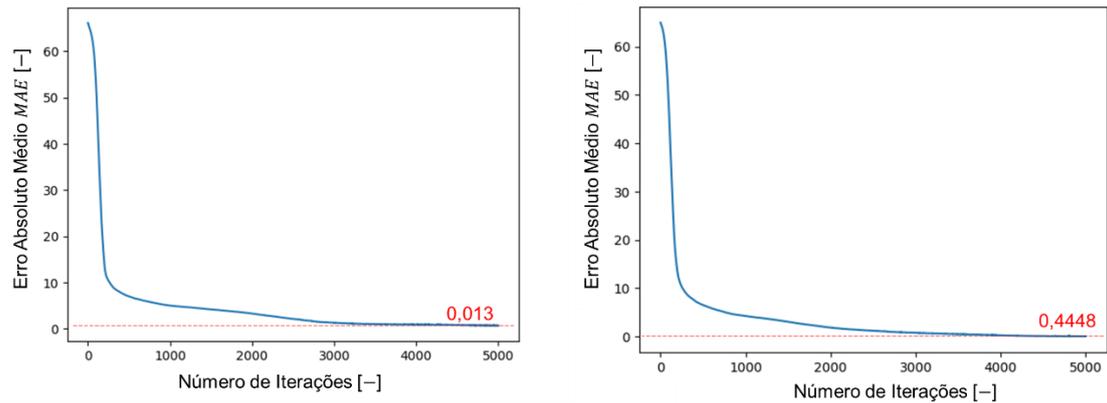


Figura 4.4: Evolução do Erro Absoluto Médio em função do número de iterações para o treinamento com (a) 70 e (b) 100 materiais.

Fonte: Autor

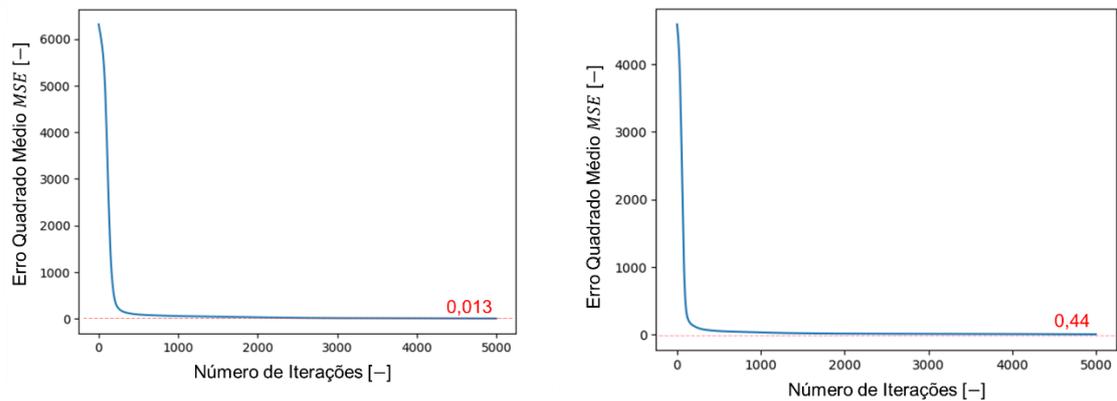


Figura 4.5: Evolução do Erro Quadrático Médio em função do número de iterações para o treinamento com (a) 70 e (b) 100 materiais.

Fonte: Autor

Inicialmente, tanto o MAE quanto o MSE diminuem à medida que o modelo se ajusta aos dados de treinamento. Isso reflete o processo de aprendizado da rede para reduzir as discrepâncias entre as previsões e os valores reais. À medida que o treinamento progride, observa-se a convergência dos erros para valores relativamente baixos. Isso indica que a RNA está aprendendo de forma eficaz e se aproximando de uma solução ótima. Em seguida, os gráficos mostram estabilidade com variações mínimas nos valores de erro. Isso indica que o modelo atingiu um ponto em que ajustes adicionais não proporcionam melhorias significativas.

Ambos os gráficos demonstram que o algoritmo de treinamento está constantemente buscando minimizar os erros. Em outras palavras, a curva de erro continua a se mover em direção a zero, indicando uma busca ativa por uma solução que se aproxime o máximo possível dos dados de treinamento.

Após as 5000 iterações, tanto o Erro Absoluto Médio, quanto o Erro Quadrático foram de 0,013. Estes valores sugerem um desempenho bastante preciso do modelo para prever a tensão de escoamento de ligas de aço. O MAE e o MSE são métricas comuns utilizadas para avaliar a qualidade das previsões de um modelo. Valores baixos para essas métricas indicam que as previsões do modelo estão muito próximas dos valores reais, refletindo uma boa capacidade de generalização.

A capacidade de generalização é a competência de um modelo em prever corretamente novos exemplos diferentes daqueles usados para treinamento. Esta propriedade do modelo depende da qualidade dos dados, do tamanho da base de dados e do algoritmo de treinamento. Melhorar esta competência, minimizando o erro do modelo, é o objetivo universal do machine learning. O valor MSE pode variar em uma ampla faixa, por exemplo, de 0,004467 para um modelo com boa capacidade de generalização a 20,195 para um modelo com baixa capacidade de generalização. (Liu et al., 2017b)

A Figura 4.6 apresenta o gráfico de predição do modelo. Este gráfico é uma ferramenta poderosa para avaliar a qualidade das previsões de uma RNA de maneira intuitiva e visual. Se os pontos no gráfico estão aproximadamente alinhados ao longo de uma linha reta, isso sugere que o modelo está capturando de forma eficaz as relações lineares nos dados. Uma distribuição linear indica uma boa correspondência entre as previsões e os valores reais.

Do gráfico pode ser extraído o valor de R^2 . Esta métrica de desempenho mostra a proporção da variabilidade dos dados que é explicada pelo modelo. O modelo proposto apresenta $R^2 = 0,79$. Isso indica que o modelo explica aproximadamente 79% da variabilidade total nos dados, o que é considerado um bom ajuste do modelo aos padrões subjacentes nos dados.

Na Figura 4.6 é possível identificar dois pontos que estão significativamente afastados da linha diagonal. Estes pontos indicam casos em que o modelo pode estar com dificuldade em fazer previsões precisas. Este é um indicativo que a capacidade preditiva do modelo ainda pode ser melhorada.

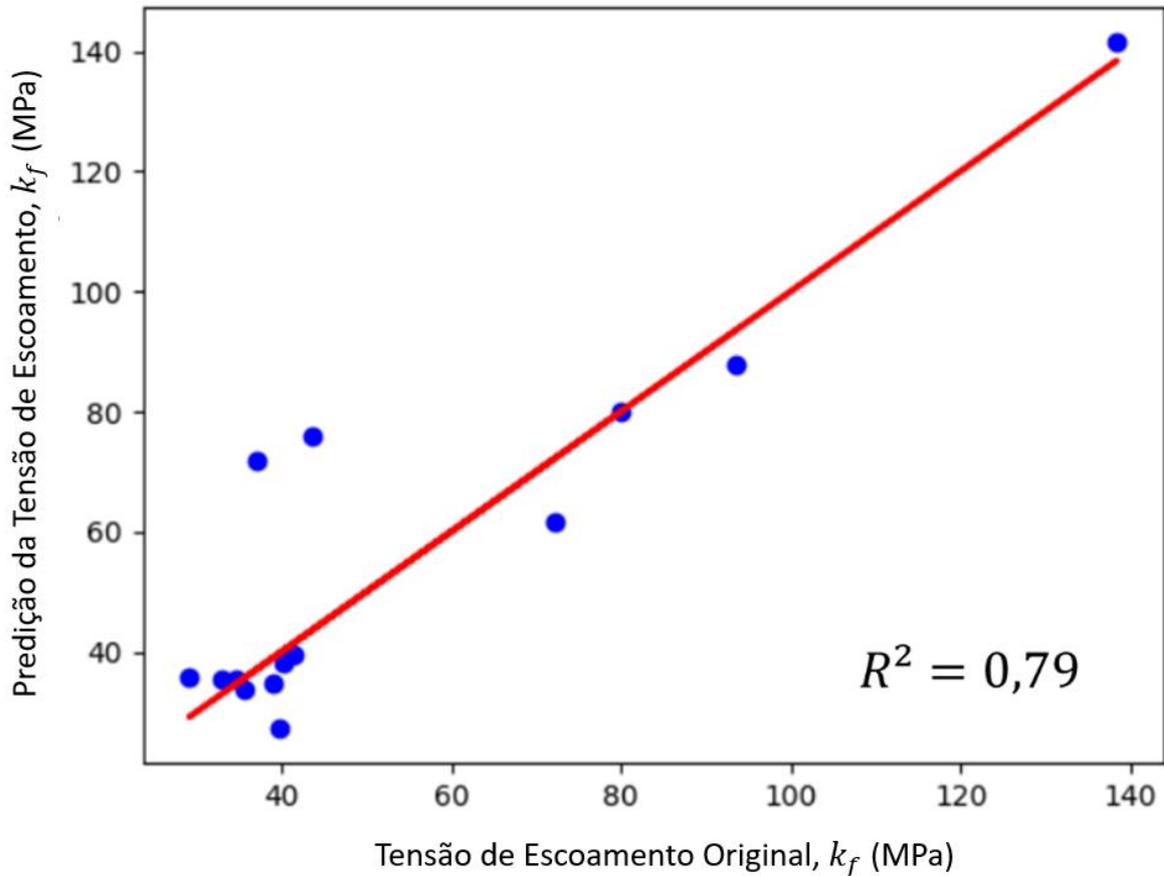


Figura 4.6: Predição da tensão de escoamento em função do respectivo valor original.

Fonte: Autor

Embora os resultados obtidos tenham sido promissores, é crucial destacar que o tamanho limitado do conjunto de dados de entrada empregado neste estudo representa uma restrição à capacidade de aprendizado da rede neural. Outro aspecto crítico para a capacidade preditiva do modelo está associado a presença de dados de entrada com valor zero. Durante o treinamento, os pesos da rede neural são ajustados para minimizar o erro. Se uma entrada específica tem um valor nulo, os pesos correspondentes a essa entrada podem não ser atualizados de maneira eficaz, já que a multiplicação por zero não contribui para a atualização dos pesos. Além disso, se a relação entre a entrada de entrada com valor zero e a saída da rede for não linear, a incapacidade da rede de ajustar os pesos correspondentes pode resultar em uma representação inadequada dessa relação.

Após a criação do modelo, conduziu-se um teste de inferência para avaliar a capacidade preditiva. Selecionou-se um tipo de material da base de dados de teste, proporcionando uma oportunidade de verificar a precisão da predição. O material em questão, na condição

selecionada, apresenta $k_f = 33,02MPa$. O valor previsto pelo modelo foi de $k_f = 33,019474 MPa$. Esse resultado revela uma notável proximidade em relação ao valor real. Além disso, destaca-se a agilidade para a obtenção do resultado. O tempo necessário para realizar a predição foi de apenas 20ms.

O teste de inferência destaca um desempenho positivo do modelo, evidenciando o considerável potencial das técnicas de Inteligência Artificial (IA) para previsões precisas. Vale ressaltar que, para outros materiais, podem ocorrer variações dentro do erro calculado, o que ressalta a importância de considerar diferentes contextos e características específicas de cada material ao aplicar o modelo preditivo.

A Figura 4.7 mostra a curva de escoamento real do aço X15Cr13, deformado a 1250°C em uma velocidade de deformação de $0,1s^{-1}$ e sua aproximação usando os valores previstos usando a metodologia descrita neste trabalho. É possível observar que a RNA é capaz de prever de maneira satisfatória o comportamento real do material. A discrepância máxima entre os dados reais e previstos é de apenas 12%.

A discrepância entre as curvas pode ser melhor quantificada calculando a área delimitada entre ambas as curvas. A área da entre as duas curvas corresponde a 6,5% da área abaixo da curva real. Este desvio pode ser utilizado como indicativo do erro cometido ao utilizar a aproximação em vez da curva real. (Merayo et al., 2020)

Considerando a dispersão de propriedades mecânicas que ocorre em um mesmo tipo de aço, o desempenho da RNA pode ser considerado adequado para a previsão da curva de escoamento de ligas de aço. Como já mencionado, a caracterização do comportamento mecânico das ligas metálicas quando deformadas a quente é um processo demorado, caro e que consome muitos recursos. Porém, com base neste exemplo, pode-se afirmar que a utilização da metodologia descrita neste trabalho permite encurtar prazos e ter uma estimativa dos resultados esperados.

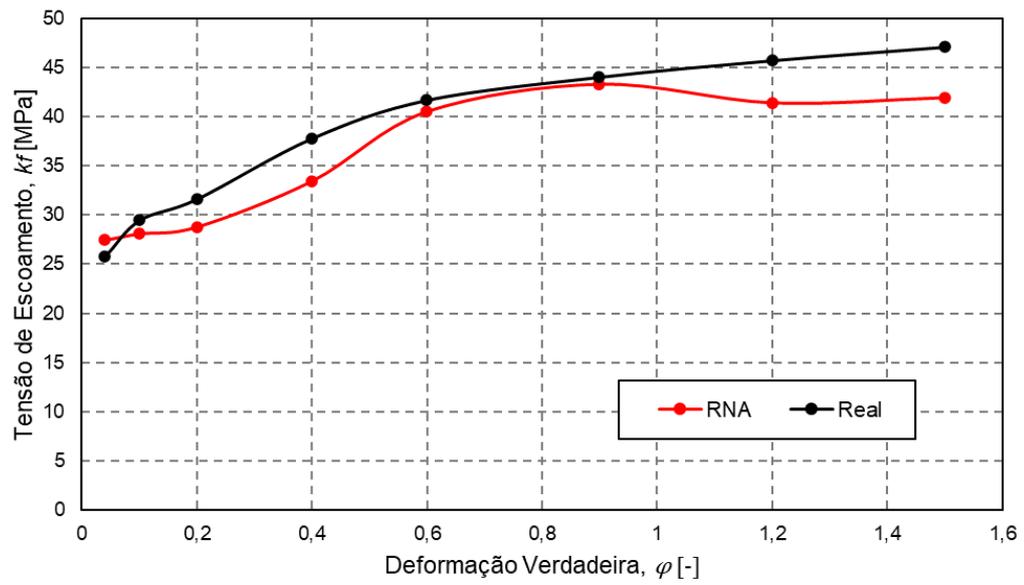


Figura 4.7: Curva de escoamento real do aço X15Cr13 (1250°C , $0,1\text{s}^{-1}$) e sua aproximação usando os valores previstos pela RNA.

Fonte: Autor

5.0 CONCLUSÕES

Este estudo investigou a aplicabilidade de redes neurais artificiais (RNA's) na previsão da curva de escoamento de ligas de aço submetidas à deformação plástica a quente. Os resultados apontam para avanços significativos. Demonstrou-se que as RNA's são eficazes em prever o comportamento mecânico dessas ligas, considerando fatores como composição química e condições de conformação ($\varphi, \dot{\varphi}, \vartheta$). Uma RNA densa, com duas camadas ocultas contendo 20 neurônios cada, mostrou-se capaz de aprender relações complexas, resultando em desempenho robusto, evidenciado por Erro Absoluto Médio e Erro Quadrático de 0,013 e uma discrepância máxima entre dados reais e previstos de 12%. Apesar do sucesso, a capacidade preditiva do modelo, indicada por $R^2 = 0,79$, sugere oportunidades de aprimoramento, principalmente através do enriquecimento do conjunto de dados.

Este trabalho contribui para o desenvolvimento de processos de conformação mecânica, proporcionando uma ferramenta eficaz baseada em inteligência artificial. Além disso, abre possibilidades para pesquisas semelhantes em outros metais. As RNAs mostraram-se adequadas para descrever o comportamento plástico de materiais industriais sem a necessidade de testes onerosos. Explorar arquiteturas de rede mais avançadas oferece potencial para melhorias substanciais, considerando as diversas topologias disponíveis. O estudo também levanta questões sobre a possibilidade de projetar sistemas baseados em inteligência artificial capazes de prever a curva de escoamento com maior precisão. Há um amplo espectro de topologias de rede que sugere muitas oportunidades para futuras investigações e inovações nesse campo.

6.0 SUGESTÕES PARA TRABALHOS FUTUROS

- Enriquecimento do banco de dados, coletando mais informações experimentais ou integrando dados de fontes adicionais.
- Explorar diferentes arquiteturas de redes neurais para comparar resultados e precisão de aferência.
- Análise de sensibilidade buscando compreender como diferentes parâmetros de entrada influenciam as previsões do modelo.
- Expansão deste tipo de pesquisa para outras classes de materiais.
- Dividir a pesquisa em diferentes tipos de aço, para levar em consideração fatores como a microestrutura, principalmente em aços para trabalho a quente.

7.0 REFERÊNCIAS BIBLIOGRÁFICAS

1. Altan, Taylan., Ngaile, Gracious., & Shen, Gangshu. (2005). **Cold and hot forging : fundamentals and applications**. ASM International.
2. AMS International. AMS HANDBOOK, VOLUME I, **Properties and Selection: Irons, Steels, and High-Performance Alloys**. Tenth edition - 1990.
3. Boeira Ercolani, J., & Rodrigo Kehl, L. ([s.d.]). **AVALIAÇÃO DOS MÉTODOS DE TRAÇÃO E COMPRESSÃO PARA OBTENÇÃO DE CURVAS DE ESCOAMENTO DE LIGAS DE ALUMÍNIO**.
4. Brito Mira, H. DE, & Moreno, F. DE. ([s.d.]). **DISCIPLINA: CONFORMAÇÃO MECÂNICA DOS METAIS PROCESSOS DE FABRICAÇÃO: CONFORMAÇÃO MECÂNICA DOS METAIS VOLUME I**
5. Carlos, J., De Verney, K., César, J. L., & Ziulkoski, C. (2018). **OBTENÇÃO DE CURVAS DE ESCOAMENTO PARA O AÇO DIN 16MnCr5 EMPREGADO NO FORJAMENTO A FRIO**. <https://www.researchgate.net/publication/328171856>
6. Chiaverini, Vicente; **Aços e Ferros Fundidos: características gerais, tratamentos térmicos, principais tipos** - 7.ed.ampl e ver.-São Paulo-2005, 599 folhas.
7. Costa e Silva, André Luiz V. da; Mei, Paulo Roberto. **Aços e Ligas Especiais**, 2o edição, 2008 - 646 folhas.

8. Deshpande, Anand., & Kumar, Manish. (2018). **Artificial Intelligence for big data : complete guide to automating big data solutions using artificial intelligence techniques.** Packt Publishing.
9. Dieter, G. E., Kuhn, H. A., & Semiatin, S. L. (2003). **Handbook of workability and process design.** ASM International.
10. Dobrzański, L. A., & Honysz, R. ([s.d.]). **Virtual examinations of alloying elements influence on alloy structural steels mechanical properties Analysis and modelling.**
11. **Estampagem.** ([s.d.]).
12. Fábio Martins, P. D. ([s.d.]). **CONFORMAÇÃO MECÂNICA ME-65 I.**
13. Fernández, D. M., Rodríguez-Prieto, A., & Camacho, A. M. (2020). **Prediction of the bilinear stress-strain curve of aluminum alloys using artificial intelligence and big data.** *Metals*, 10(7), 1–29. <https://doi.org/10.3390/met10070904>
14. FROTA JUNIOR, R. T. C. **Avaliação de parâmetros do processo de forjamento a quente em matriz aberta pelo método de elementos finitos.** Dissertação (Mestrado em Engenharia Aeronáutica e Mecânica). Instituto Tecnológico da Aeronáutica, São José dos Campos, 2009.
15. George E. Totten – **Steel Heat Treatment: Metallurgy and Technologies** – editor p.cm. – 2006 – segunda edição - 833 folhas
16. Golpaert, Humbertus. **Metalografia dos Produtos Siderúrgicos - Segunda Edição- 1974.**
17. Helman, H., & Cetlin, P. R. (2005). **Tensões e deformações 3 FUNDAMENTOS DA CONFORMAÇÃO MECÂNICA DOS METAIS.** www.artliber.com.br
18. Hurwitz, J., & Kirsch, D. (2018). *Machine Learning IBM Limited Edition.* <http://www.wiley.com/go/permissions>.

19. Kashid, S., & Kumar, S. (2013). **Applications of Artificial Neural Network to Sheet Metal Work - A Review**. *American Journal of Intelligent Systems*, 2(7), 168–176. <https://doi.org/10.5923/j.ajis.20120207.03>
20. Kong, L. X., & Nahavandi, S. ([s.d.]). **On-line tool condition monitoring and control system in forging processes**.
21. Liu, Y., Zhao, T., Ju, W., & Shi, S. (2017a). **Materials discovery and design using machine learning**. Em *Journal of Materiomics* (Vol. 3, Número 3, p. 159–177). Chinese Ceramic Society. <https://doi.org/10.1016/j.jmat.2017.08.002>
22. Marcio de Almeida Ramos – **Metalurgia** – PETROBRAS (SEDES/DITED/SEIND) – Edição 1989, Serviço de Desenvolvimento de Recursos Humanos, Divisão de Tecnologia Educacional, Setor de Introdução e Didática.
23. Merayo, D., Rodriguez-Prieto, A., & Camacho, A. M. (2020). **Prediction of Physical and Mechanical Properties for Metallic Materials Selection Using Big Data and Artificial Neural Networks**. *IEEE Access*, 8, 13444–13456. <https://doi.org/10.1109/ACCESS.2020.2965769>
24. Morales-Molina, C. D., Hernandez-Suarez, A., Sanchez-Perez, G., Toscano-Medina, L. K., Perez-Meana, H., Olivares-Mercado, J., Portillo-Portillo, J., Sanchez, V., & Garcia-Villalba, L. J. (2021). **A dense neural network approach for detecting clone id attacks on the rpl protocol of the iot**. *Sensors*, 21(9). <https://doi.org/10.3390/s21093173>
25. Mrzyglód, B., Hawryluk, M., Janik, M., & Olejarczyk-Woźeńska, I. ([s.d.]). **Sensitivity analysis of the artificial neural networks in a system for durability prediction of forging tools to forgings made of C45 steel**. <https://doi.org/10.1007/s00170-020-05641-y>/Published

26. Murugesan, M., Sajjad, M., & Jung, D. W. (2020). **Microstructure evaluation and constitutive modeling of AISI-1045 steel for flow stress prediction under hotworking conditions.** *Symmetry*, 12(5). <https://doi.org/10.3390/SYM12050782>
27. Najm, S. M., & Paniti, I. ([s.d.]). **Artificial neural network for modeling and investigating the effects of forming tool characteristics on the accuracy and formability of thin aluminum alloy blanks when using SPIF.** <https://doi.org/10.1007/s00170-021-06712-4>/Published
28. Osakada, K., & Yang, G. (1991). **APPLICATION OF NEURAL NETWORKS TO AN EXPERT SYSTEM FOR COLD FORGING.** Em *Int. J. Mach. Tools Manufact* (Vol. 31, Número 4).
29. Palizdar, Y. (2011). **Understanding the effect of aluminium on the microstructure on low level nitrogen steel.**
30. RODRIGUES, J., & MARTINS, P. **Tecnologia Mecânica: Tecnologia da deformação Plástica. (Vol. I).** Lisboa, Portugal: Escolar Editora, 2010.
31. Rosiak, A. ([s.d.]). MINISTÉRIO DA EDUCAÇÃO UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL Escola de Engenharia Departamento de Metalurgia **OBTENÇÃO DA CURVA DE ESCOAMENTO A QUENTE DO AÇO 22MnB5 A PARTIR DO MÉTODO DO EMPILHAMENTO DE CHAPAS FINAS.**
32. SCHAEFFER, L. **Forjamento - Introdução ao Processo.** Porto Alegre: Imprensa Livre, 2006.
33. Schmidhuber, J. (2015). **Deep Learning in neural networks: An overview.** Em *Neural Networks* (Vol. 61, p. 85–117). Elsevier Ltd. <https://doi.org/10.1016/j.neunet.2014.09.003>
34. Singh, V., Kumar, A., Mondal, C., Bhattacharjee, P. P., & Ghosal, P. (2019). **Hot deformation of high-Nb-containing γ -TiAl alloy in the temperature range of 1000–**

- 1200 °C: microstructural attributes to hot workability.** SN Applied Sciences, 1(4).
<https://doi.org/10.1007/s42452-019-0380-0>
35. Spathopoulos, S. C., & Stavroulakis, G. E. (2020). **Springback Prediction in Sheet Metal Forming, Based on Finite Element Analysis and Artificial Neural Network Approach.** Applied Mechanics, 1(2), 97–110.
<https://doi.org/10.3390/applmech1020007>
36. Vallim, P. S. S., Gorni, A. A., & Plaut, R. L. ([s.d.]). **APLICAÇÃO DE REDE NEURAL PARA CÁLCULO DA TENSÃO DE ESCOAMENTO NA LAMINAÇÃO DE TIRAS A QUENTE DE AÇOS C-MN 1.**
37. William D. Calister, Jr; **Ciência e Engenharia de Materiais, Uma introdução –** Quinta Edição – 2002 - 589 Folhas.
38. william. ([s.d.]). **PROPRIEDADES MECÂNICAS DE MATERIAIS METÁLICOS.**
39. Wu, S. (2012). **Warranty data analysis: A review.** Em Quality and Reliability Engineering International (Vol. 28, Número 8, p. 795–805).
<https://doi.org/10.1002/qre.1282>