



MINISTÉRIO DA EDUCAÇÃO  
Universidade Federal de Ouro Preto  
Instituto de Ciências Exatas e Aplicadas  
Especialização em Ciência de Dados



**DESENVOLVIMENTO DE MODELO DE PREVISÃO DA  
CONDIÇÃO TÉRMICA DA PLACA PARA O FORNO  
*PUSHER* DA LINHA DE TIRAS A QUENTE**

**Priscila Batista Dias Santos**

João Monlevade, MG  
2023

Priscila Batista Dias Santos

**DESENVOLVIMENTO DE MODELO DE PREVISÃO DA  
CONDIÇÃO TÉRMICA DA PLACA PARA O FORNO  
*PUSHER* DA LINHA DE TIRAS A QUENTE**

Trabalho de conclusão de curso apresentado ao curso de Especialização em Ciência dos Dados do Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto, como parte dos requisitos necessários para a obtenção do título de Especialista em Ciência dos Dados.

Orientador: Profa. Dra. Sarah Negreiros de Carvalho Leite

João Monlevade, MG

2023

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

S237d Santos, Priscila Batista Dias.  
Desenvolvimento de modelo de previsão da condição térmica da placa para o forno pusher da linha de tiras a quente. [manuscrito] / Priscila Batista Dias Santos. - 2023.  
31 f.: il.: color., gráf..

Orientadora: Profa. Dra. Sarah Negreiros de Carvalho Leite.  
Produção Científica (Especialização). Universidade Federal de Ouro Preto. Departamento de Engenharia de Produção.

1. Aprendizado do computador - Algoritmos. 2. Fornos - Usinas siderúrgicas. 3. Laminação (Metalurgia). 4. Modelos matemáticos. 5. Redes neurais (Computação). I. Leite, Sarah Negreiros de Carvalho. II. Universidade Federal de Ouro Preto. III. Título.

CDU 519.254:004.85

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



## FOLHA DE APROVAÇÃO

**Priscila Batista Dias Santos**

### **Desenvolvimento de modelo de previsão da condição térmica da placa para o forno *pusher* da linha de tiras a quente**

Monografia apresentada ao Curso de Especialização em Ciência dos Dados da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Especialista em Ciência dos Dados

Aprovada em 28 de Junho de 2023.

#### Membros da banca

Dra. Sarah Negreiros de Carvalho Leite - Orientadora - Universidade Federal de Ouro Preto  
Dr. Harlei Miguel de Arruda Leite - Universidade Federal de Ouro Preto  
Me. Jônatas Venâncio Barbosa - USIMINAS

Sarah Negreiros de Carvalho Leite, orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 12 de julho de 2023.



Documento assinado eletronicamente por **Sarah Negreiros de Carvalho Leite, PROFESSOR DE MAGISTERIO SUPERIOR**, em 12/07/2023, às 21:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0557207** e o código CRC **F43CD4EB**.

*Dedico esse trabalho à Deus que tem direcionado minha vida.  
A meu esposo, meu filho e meus pais pelo amor e apoio em todos os momentos.*

# Agradecimentos

Agradeço a todos que contribuíram para que este trabalho fosse concluído e, de uma forma especial:

À USIMINAS, por meio da Gerência Técnica de Laminação e ao meu gerente Fabricio Mazola pela confiança e apoio para a realização deste trabalho;

Aos colegas de trabalho Jônatas Venancio Barbosa, Cristovão Ney Giacomini, Vinicius Amaral Marques e Robson Miranda de Oliveira Pinto pelas discussões técnicas, ideias e colaboração para que este trabalho fosse desenvolvido;

À UFOP e seus professores pelo conhecimento adquirido e em especial a Profa. Dra. Sarah Negreiros de Carvalho Leite por me conduzir na execução desse estudo;

Aos meus colegas de estudo, em especial Felipe Finamor e Kleber Macedo pela troca de experiências e parceria durante todo o curso.

*‘Grandes coisas fez o Senhor por nós, pelas quais estamos alegres’*

Salmos 126:3

:

# Resumo

O processo de laminação de tiras a quente se inicia com o reaquecimento, que tem como objetivo aumentar a ductilidade da placa para possibilitar a laminação até a espessura final desejada. Durante todo o processo, é desejada a temperatura da placa, porém, devido à imprecisão da sua medição dentro do forno, é necessário calcular essa temperatura por meio de modelos matemáticos relacionados às temperaturas de ambiente. Entre os tipos de fornos utilizados, o forno *pusher*, datado da década de 60 e com baixo custo de implantação, apresenta limitações de controle e não conta com um modelo matemático de automação, o que pode se tornar um gargalo para a produção. Com os avanços em sistemas computacionais e a abordagem orientada a dados, torna-se viável o uso de algoritmos de *Machine Learning* para modelar os parâmetros do processo, como as condições de reaquecimento. Neste trabalho, foram aplicados algoritmos de redes neurais a dados históricos de reaquecimento de um forno *pusher* da linha de Tiras a Quente da Usina de Ipatinga, com o objetivo de prever a força de laminação no primeiro passe de desbaste, que indiretamente, pode indicar a homogeneidade térmica da placa. Os resultados de previsão apresentaram um erro médio de 5% em relação aos dados reais. Considerando as incertezas e a precisão dos equipamentos de medição convencionais, o erro da rede neural mostra-se promissor para ser utilizado como referência de controle para a equipe de operação. Além disso, foi possível identificar as variáveis que mais influenciaram na previsão da força, abrindo caminho para a otimização do processo.

**Palavras-chaves:** Forno de reaquecimento. Encharque. Redes Neurais. Forno *pusher*.



# *Abstract*

The hot strip rolling process begins with reheating, which aims to increase the ductility of the slab to enable rolling to the desired final thickness. Throughout the process, the slab temperature is desired, but due to the imprecision of its measurement inside the furnace, it is necessary to calculate this temperature using mathematical models related to ambient temperatures. Among the types of furnaces used, the pusher furnace, dating back to the 1960s and with low implementation costs, has control limitations and lacks a mathematical model for automation, which can become a bottleneck for production. With advancements in computational systems and a data-driven approach, it becomes viable to use Machine Learning algorithms to model process parameters, such as the reheating conditions. In this study, neural network algorithms were applied to historical reheating data from a pusher furnace in the Hot Strip Mill at the Ipatinga, aiming to predict the rolling force in the first roughing pass, which indirectly indicates the plate's thermal homogeneity. The prediction results showed a mean error of 5% compared to the actual data. Considering the uncertainties and precision of conventional measurement equipment, the error of the neural network shows promise as a control reference for the operating team. Furthermore, it was possible to identify the variables that most influenced the force prediction, paving the way for process optimization.

***Keywords:*** *Slab reheating furnace. Soak. Neural network. Pusher furnace*

# Lista de ilustrações

Figura 1 – Layout da linha de tiras a quente. . . . .	3
Figura 2 – Princípio da laminação de planos. . . . .	4
Figura 3 – Vista longitudinal de um forno <i>pusher</i> . . . . .	5
Figura 4 – Modelo de um neurônio artificial. . . . .	8
Figura 5 – Estrutura de uma rede neural: camada de entrada, camada intermediária e camada de saída. . . . .	9
Figura 6 – Arquitetura <i>Feedforward</i> e recorrente. . . . .	9
Figura 7 – Relação de ajuste da TEQ fornecida pelo modelo de <i>set-up</i> , em função da TEQ fornecida pela rede neural. . . . .	11
Figura 8 – Desempenho do modelo RNA proposto na previsão da (a) força e (b) torque de laminação. . . . .	12
Figura 9 – Representação das variáveis de reaquecimento calculadas para o forno <i>pusher</i> . . . . .	14
Figura 10 – Descrição das variáveis. . . . .	14
Figura 11 – Exemplo de algumas variáveis utilizadas do banco de dados. . . . .	15
Figura 12 – Parâmetros e configurações testadas. . . . .	17
Figura 13 – Histograma do conjunto de dados utilizado. . . . .	20
Figura 14 – Histograma do conjunto de dados utilizado. . . . .	21
Figura 15 – <i>Heatmap</i> . . . . .	22
Figura 16 – Variância explicada em função do número de componentes principais. . . . .	23
Figura 17 – Componentes principais PC1 e PC2 e sua relação com a força de laminação. . . . .	24
Figura 18 – Melhor seleção de parâmetros encontrada para a rede MLP testada. . . . .	24
Figura 19 – Desempenho da RNA no treinamento e validação. . . . .	25
Figura 20 – Gráfico de dispersão entre valores previstos e reais. . . . .	26
Figura 21 – Exemplo de aplicação da RNA desenvolvida. . . . .	26

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>2</b>	<b>REVISÃO DE LITERATURA</b>	<b>3</b>
2.1	Laminação de tiras a quente	3
2.2	Fornos de reaquecimento	4
2.3	Reaquecimento de placas	6
2.4	Redes neurais artificiais	7
2.4.1	Arquitetura da rede neural	8
2.4.2	Construção da RNA	9
2.5	Redes neurais aplicadas na laminação	10
<b>3</b>	<b>METODOLOGIA</b>	<b>13</b>
3.1	Construção da base de dados	13
3.1.1	Obtenção dos dados de reaquecimento	13
3.2	Pré-processamento dos dados	14
3.3	Normalização dos dados	15
3.4	Análise de componentes principais	15
3.5	Modelamento da rede neural artificial	16
3.5.1	Partição da base de dados	16
3.5.2	Rede neural MLP	17
3.5.2.1	Compilando o modelo	17
<b>4</b>	<b>RESULTADOS</b>	<b>19</b>
4.1	Exploração da base de dados para modelamento	19
4.2	Análise de componentes principais	23
4.3	Previsão da RNA	24
4.4	Estudo de caso - Trabalhos Futuros	26
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>28</b>
	<b>REFERÊNCIAS</b>	<b>29</b>

# 1 Introdução

Fornos de reaquecimento são equipamentos essenciais nas industriais siderúrgicas para aquecer as placas de aço uniformemente e garantir a plasticidade adequada para a sua conformação durante a laminação de forma que, ao final do processo, o produto obtenha as propriedades mecânicas e dimensionais requeridos pelo cliente (GIACOMIN et al., 2017). Um dos desafios dessa etapa é a otimização do controle dinâmico de temperatura dos fornos, que afeta diretamente o consumo de combustível e, conseqüentemente, os custos de operação e do produto final. Portanto, é recomendável considerar a modernização desses equipamentos ou a substituição por modelos mais recentes e automatizados para aprimorar o processo produtivo e garantir a qualidade das tiras produzidas.

Dentre os tipos de fornos utilizados, o forno *pusher* é um dos mais antigos (década de 60). Nele, a cada peça enfiada pelo empurrador, tem-se outra peça desenfiada pela rampa de descarga (GIACOMIN et al., 2017). A falta de controle automático das variáveis de processo e a automação parcial podem resultar na aquisição desses equipamentos a um custo menor de implantação (JÚNIOR, 2007). Entretanto, durante a operação, devido às suas limitações de controle, à variação das temperaturas de *set point* em paradas de linha e/ou às alterações no mix de combustíveis, esse equipamento pode se tornar um gargalo afetando a produção.

Com os avanços na capacidade de processamento dos sistemas computacionais e a busca das empresas por tornar seus processos organizacionais orientados a dados (*data driven*) faz-se cada vez mais viável o uso de algoritmos de *Machine Learning* (ML) para modelamento de parâmetros de processo, qualidade do produto e propriedades mecânicas (AGHASAFARI; ABDI; SALIMI, 2014) e (FINAMOR; WOLFF; LAGE, 2021).

Este trabalho propõe uma abordagem por meio do uso de algoritmos de redes neurais artificiais (RNA) para contornar a falta de referência da condição térmica da placa do forno *pusher* que atualmente está em operação na Linha de Tiras a Quente da Usiminas, planta de Ipatinga. Para isto, foi utilizado o banco de dados histórico das variáveis deste forno. Foram consideradas diversas variáveis associadas ao processo como, temperaturas e tempos de reaquecimento, características dimensionais da placa (largura, comprimento e espessura) e parâmetros de laminação dos passes de desbaste (redução no primeiro passe) para desenvolvimento de um modelo capaz de prever a força de laminação, que de uma forma indireta, permite avaliar a condição térmica da placa após o reaquecimento.

Adicionalmente, a análise estatística descritiva das variáveis de processo com maior correlação com a condição térmica da placa foi realizada para se estabelecer uma referência de atuação da equipe de operação. A previsão da força de laminação associada às variáveis mais importantes no processo podem ser utilizadas para um direcionamento mais efetivo do controle do forno.

Este trabalho foi norteado pelas seguintes etapas de desenvolvimento:

- criar um sistema de consulta e tratamento de dados das variáveis de processo do forno *pusher* da Linha de Tiras a Quente da Usiminas, planta de Ipatinga;
- construir um banco de dados contendo as informações do processo de reaquecimento, materiais e de processo;
- aplicar estatística descritiva das variáveis de processo que possuem maior correlação com a condição térmica da placa. Foram consideradas as principais variáveis de controle do processo de reaquecimento e de produto que influenciam na força de laminação;
- com base nos resultados da análise estatística foram aplicadas as técnicas de redução de dimensão/PCA (Análise de Componentes Principais) para selecionar as variáveis mais relevantes para a predição da força de laminação;
- gerar uma rede neural artificial que receba as variáveis de processo e produto e realize a predição da força de laminação no primeiro passe da etapa de desbaste;
- treinar e ajustar os parâmetros da rede neural projetada;
- avaliar o desempenho do modelo preditivo gerado e analisar a sua coerência a luz dos especialistas da área da linha de produção.

O restante deste trabalho é organizado como segue: o Capítulo 2 apresenta os detalhes de funcionamento do forno *pusher*. O Capítulo 3 descreve a base de dados e as técnicas utilizadas para gerar o modelo preditivo. O Capítulo 4 apresenta e discute os resultados. As considerações finais estão no Capítulo 5.


## 2 Revisão de Literatura

### 2.1 Laminação de tiras a quente

A linha de Tiras a Quente da Usina de Ipatinga possui três fornos de reaquecimento, dois laminadores desbastadores com descarepações de entrada e saída, uma tesoura de pontas (*Crop-Shear*), um Trem Acabador (TA) de seis cadeiras e duas bobinadeiras, sendo a temperatura do produto monitorada por pirômetros instalados ao longo da linha, conforme mostra a Figura 1.

Inicialmente, as placas são reaquecidas a altas temperaturas e em seguida submetidas a uma sequência de deformações. Na fase de desbaste a espessura inicial da placa é reduzida para uma espessura intermediária. Na sequência ela é laminada para a espessura final na fase de acabamento e, finalmente, já na forma de tira, é resfriada e bobinada.

Figura 1 – Layout da linha de tiras a quente.




Fonte: (BARBOSA; DADOMI; DIAS, 2015).

A laminação é um processo de deformação plástica de metais ou ligas, na qual ocorre a aplicação de força mecânica entre cilindros para se obter a forma desejada ou características específicas no material laminado, como mostra a Figura 2.

A carga ou força de laminação é um parâmetro fundamental para se garantir a precisão dimensional de um produto plano e permitir o controle do processo de conformação. A determinação da carga durante a laminação a quente é influenciada por uma série de fatores, sendo a temperatura um dos elementos de maior importância. A temperatura desempenha um papel crucial na relação exponencial entre a tensão de escoamento do aço e o processo de laminação (DEVADAS et al., 1991).

A qualidade do aquecimento e o controle da temperatura do material durante o processo de laminação a quente são essenciais em termos de produtividade, qualidade do produto e custos de produção (SANTOS; GIACOMIN; RESENDE, ).

Figura 2 – Princípio da laminação de planos.



Fonte: (BARBOSA, 2014).

Segundo BARBOSA (2006) o termo encharque geralmente é utilizado no sentido de homogeneidade. No etapa de reaquecimento de placas para a laminação a quente, por exemplo, diz respeito a homogeneidade térmica das placas, ou seja, a diferença entre a temperatura da superfície e do centro da placa. Uma placa com uma diferença significativa de temperatura (mal encharcada), resultará, na maioria dos casos, em uma maior dificuldade de conformação mecânica devido à baixa temperatura, e em consequência, exigirá cargas mais elevadas na laminação. Esse parâmetro de processo de uma forma indireta pode afirmar se as placas estão saindo ou não, efetivamente, com um bom encharque do forno.

## 2.2 Fornos de reaquecimento

Os fornos de reaquecimento possuem diversas configurações e podem ser classificados em função do método de deslocamento das placas e do seu formato (GIACOMIN et al., 2017). Na Linha de Tiras a Quente da Usiminas de Ipatinga, por exemplo, existem dois tipos de fornos de reaquecimento, ambos contínuos.


Na planta, há dois fornos do tipo *walking beam*, uma concepção mais moderna na qual a movimentação da carga é realizada por meio de vigas móveis, o que reduz a probabilidade de ocorrência de defeitos nas tiras decorrentes do processo no forno. Além disso, a configuração de queimadores, a disposição das placas e os mecanismos de enformamento e desenformamento permitem menor consumo de energia e maior homogeneidade na temperatura das placas desenformadas. Os fornos do tipo *walking beam* possuem um modelo matemático de controle de combustão e de cálculo da temperatura de placa (SANTOS; SCHIAVO; GIACOMIN, 2013; SANTOS; TEIXEIRA; MARQUES, 2015).

Um terceiro forno desta planta é do tipo *pusher*, de concepção mais antiga, que foi instalado em 1973 e foi o foco deste trabalho. A principal característica deste equipamento é que, para manter a sua continuidade, o deslocamento das placas dentro forno ocorre com a placa anterior empurrando a posterior. Quando uma placa é enfornada na entrada, ela empurra toda a carga do forno e uma placa é desenfornada na saída. Esse tipo de forno apresenta uma eficiência de aquecimento de placas inferior quando comparado a outros modelos, fornecendo placas com menor homogeneidade térmica, além de ser propenso a ocorrência de defeitos nas bordas e superfície inferior das tiras devido ao seu método de deslocamento conforme descrito por (RIZZO, 2007).

A Figura 3 apresenta a vista longitudinal de um forno *pusher*. O controle deste forno é dividido em diferentes regiões chamadas zonas de aquecimento (superior e inferior) e zona de encharque. Cada uma dessas zonas possui queimadores, cujo fluxo de combustível e ar pode ser ajustado independentemente por meio da abertura e fechamento de válvulas de controle. A primeira zona é a zona de aquecimento, onde ocorrem as maiores variações de temperatura ambiente, especialmente quando uma sequência de placas frias entra. Nessa zona, há uma troca de calor mais intensa entre a atmosfera do forno e as placas, sendo utilizada para pré-aquecer o material a uma temperatura intermediária. A zona de encharque, também chamada de zona de homogeneização, é a região final do forno. Neste etapa do reaquecimento é assegurado que haja a distribuição homogênea de temperatura entre o ponto mais quente e o mais frio de cada placa.

Durante o processo de reaquecimento, as temperaturas ambientes de cada zona são controladas levando em consideração a temperatura de desenformamento desejada. Além disso, busca-se um tempo mínimo de permanência total no forno garantindo que a placa ao final do processo, atinja a condição térmica adequada para a laminação.

Figura 3 – Vista longitudinal de um forno *pusher*.



Fonte: Da autora.



Segundo [ARAÚJO \(2009\)](#), neste fornos antigos não existe espaço livre entre as peças dentro do forno, em virtude do seu processo de enforamento, e a transferência de calor ocorre basicamente pela superfície superior das placas o que pode afetar a efetividade do aquecimento. Além disso, em função do controle parcial de alguns parâmetros de processo a sua operação é realizada manualmente, o que impossibilita a estimativa da temperatura da placa ao ser desenforada, ao contrário do que ocorre nos fornos do tipo *walking beam*.

## 2.3 Reaquecimento de placas

De acordo com [Rizzo \(2007\)](#), o reaquecimento de placas é uma etapa primordial no processo de laminação de tiras a quente cuja finalidade é aumentar a ductilidade da placa permitindo sua laminação até a espessura final requerida após a laminação. Além disso, busca-se a redução do consumo de combustíveis, a emissão de poluentes, a formação e acúmulo de carepa, e por outro lado, maximizar a disponibilidade do forno para a operação aumentando a produtividade.

Esses objetivos levam a ações contraditórias durante a operação do equipamento. Por exemplo, quando se opera aumentando o ritmo de produção, objetivando ajustar a temperatura de saída da placa, o consumo de combustíveis tende a ser elevado devido à variedade de dimensões e qualidade de materiais enforados enquanto que, operar em modo econômico visando menor consumo de combustível, pode comprometer a obtenção da condição térmica adequada. Assim, a operação em modo manual dos fornos é complexa e, por mais experiente que seja a equipe operacional, é difícil de se realizar a melhoria de controle dos parâmetros do processo. Desta forma, é conveniente o emprego de sistemas de controle automático, que consigam avaliar rapidamente e autonomamente os parâmetros de forma a otimizar a operação.

O que se deseja ao final do reaquecimento é a temperatura da placa, mas o que se controla durante todo o processo são as temperaturas ambientes em cada zona do forno. Como a medição da temperatura da placa dentro do forno é imprecisa, é necessário calculá-la por modelos matemáticos relacionando-as com as temperaturas de reaquecimento ([SANTOS; SCHIAVO; GIACOMIN, 2013](#); [SANTOS; TEIXEIRA; MARQUES, 2015](#)).

Considerando-se todos os fenômenos que ocorrem no interior do forno, a análise do processo de aquecimento se torna muito complexa, ou seja, devem ser considerados os aspectos relacionados à combustão, à fluidodinâmica dos gases e às interações térmicas entre as paredes do forno e placa ([RENAUX et al., 1998](#)).

Vários autores desde a década de setenta discutiram problemas e diferentes modelos para desenvolver o controle dos fornos de reaquecimento, motivados pelo potencial de ganho em redução de combustível, que afeta de forma onerosa o custo de produção e na necessidade de controle de temperatura das placas (YANG; LU, 1988; WANG; SHAO; CHAI, 1999). Muitos modelos matemáticos foram desenvolvidos baseados no comportamento termodinâmico do reaquecimento em função da temperatura da atmosfera do forno (TEIXEIRA; JOTA; TEIXEIRA, 2007; GIACOMIN et al., 2017). Entretanto, a implementação de técnicas de controle avançado de processos pressupõe a existência de modelos matemáticos capazes de representar as dinâmicas deste processo, que não são triviais.

## 2.4 Redes neurais artificiais

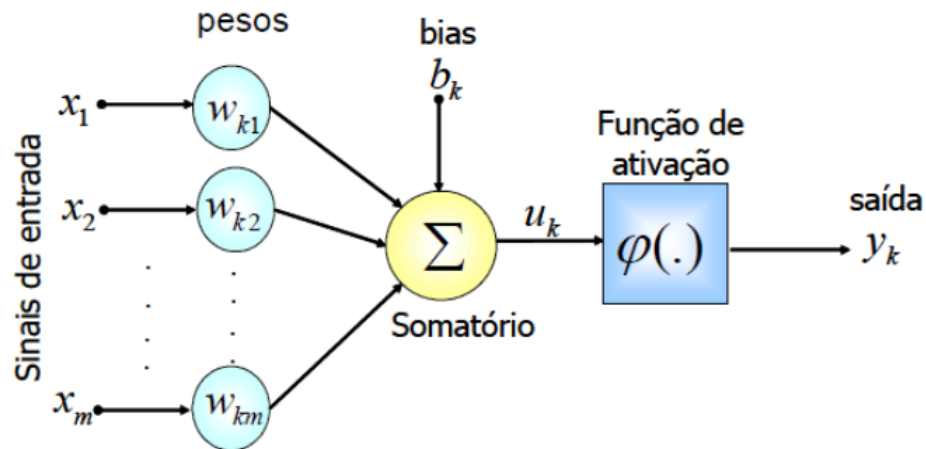
A maior parte dos problemas práticos envolvendo processos industriais possui soluções complexas e não lineares, o que dificulta a sua representação devido à falta de conhecimento sobre a relação entre as variáveis de entrada e de saída. As redes neurais artificiais distribuem essa não linearidade de maneira muito mais simples através da sua estrutura interna (VALLIM; GORNI; PLAUT, 2009).

Após serem devidamente ajustadas, as redes neurais adquirem a capacidade de gerar resultados apropriados para entradas que não foram incluídas no seu treinamento, desde que essas entradas pertençam à mesma população-alvo do problema. Isso é conhecido como a capacidade de generalização da rede, ou seja, sua habilidade de fornecer respostas coerentes a padrões ou casos inéditos (VALLIM; GORNI; PLAUT, 2009), o que permite que a rede seja eficaz em lidar com diferentes conjuntos de dados, além daqueles com os quais foi treinada inicialmente.

Uma rede neural artificial é um modelo matemático inspirado no funcionamento de um conjunto de neurônios biológicos. Não existe uma única definição para uma rede neural, uma vez que existem diversos tipos de redes com diferenças na topologia (ou seja, a forma como os neurônios estão conectados), nas funções de ativação e nos algoritmos de aprendizado utilizados (HAYKIN, 1998; HAYKIN, 2001; FAUSETT, 2006).

A Figura 4 apresenta o esquema de um neurônio artificial, que é a unidade fundamental de processamento de informação em uma rede neural, sendo  $x_m$  as entradas da rede,  $w_{km}$  os pesos sinápticos associados a cada entrada;  $b_k$  o bias,  $u_k$  a combinação linear dos sinais de entrada,  $\varphi(\cdot)$  a função de ativação e  $y_k$  a saída do neurônio artificial. O primeiro modelo de um neurônio artificial foi proposto em 1943 por (MCCULLOCH; PITTS, 1943) e posteriormente aprimorado por (ROSENBLATT, 1958), que o renomeou de *perceptron*.

Figura 4 – Modelo de um neurônio artificial.



Fonte: (SOARES; SILVA, 2011).

Os pesos são os parâmetros ajustáveis que mudam e se adaptam à medida que o conjunto de treinamento é apresentado à rede. Dessa forma, no aprendizado supervisionado de uma RNA, ocorrem iterações sucessivas de ajuste dos pesos sinápticos, de modo a fazer com que a saída da rede se aproxime o máximo possível da resposta desejada. O bias tem o efeito de adicionar ou subtrair um valor na entrada da função de ativação da rede, dependendo se é positivo ou negativo, respectivamente. O bias permite aumentar os graus de liberdade permitindo uma melhor adaptação da rede neural ao conhecimento fornecido a ela (SOARES; SILVA, 2011).

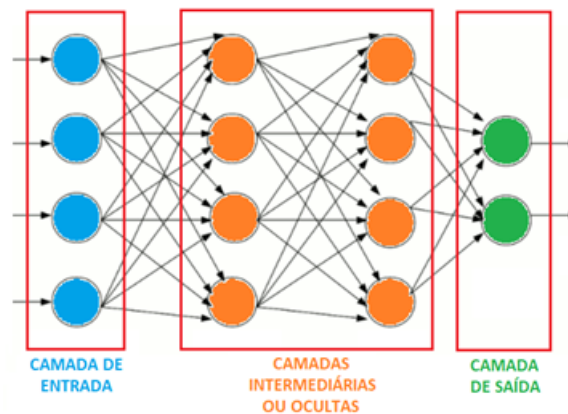
Na RNA os neurônios recebem um ou mais sinais de entrada e produzem um único sinal de saída, que pode ser transmitido como sinal de rede ou como entrada para um ou mais neurônios nas camadas subsequentes (HAYKIN, 2001).

### 2.4.1 Arquitetura da rede neural

A arquitetura da rede neural é determinada pela forma como um conjunto de neurônios artificiais se conecta, levando em consideração a complexidade do problema, a dimensão do conjunto de dados e as características dinâmicas ou estáticas do problema.

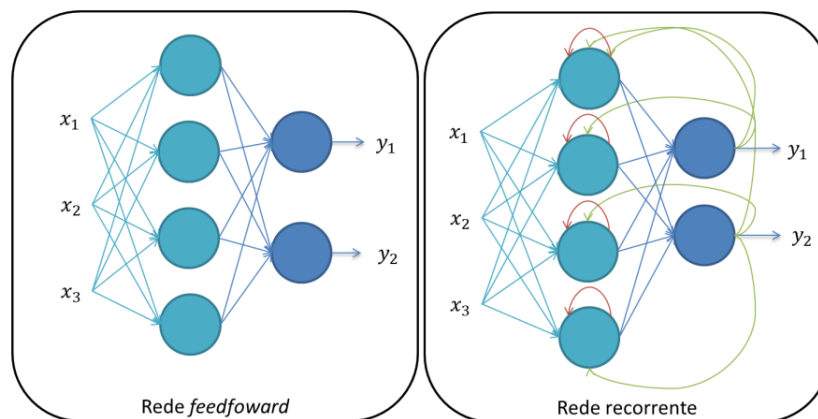
A estrutura mostrada na Figura 5 mostra as camadas típicas de uma rede neural. Geralmente, ela é constituída por uma camada de entrada, que recebe as informações provenientes do banco de dados, uma ou mais camadas intermediárias ou ocultas responsável por extrair as informações relevantes dos dados e, por fim, uma camada de saída que gera o resultado final da rede.

Figura 5 – Estrutura de uma rede neural: camada de entrada, camada intermediária e camada de saída.



As redes neurais podem ser do tipo *feedforward* ou recorrentes como mostrado na Figura 6. Redes neurais recorrentes (RNRs) possuem conexões retroalimentadas, permitindo a existência de ciclos e a passagem de informações em *loops* temporais. Nas RNRs as saídas podem ser utilizadas como entradas, formando uma espécie de memória interna. Essa capacidade de manter informações contextuais e processar sequências temporais torna as RNRs especialmente adequadas para lidar com dados sequenciais, como texto, áudio e séries temporais.

Figura 6 – Arquitetura *Feedforward* e recorrente.



Já as redes neurais do tipo *feedforward* são formadas por unidades de processamento interligadas conhecidas como neurônios, cada camada se conecta à próxima camada, porém não há conexões de volta. Dentre os principais tipos de redes *feedforward*, destaca-se a rede *multilayer perceptron* (MLP).

#### 2.4.2 Construção da RNA

O desempenho global da rede neural é o fator determinante para avaliar se o sistema está projetado e configurado de forma adequada, ou seja, se pode ser aprimorado pela adição de camadas ocultas adicionais ou mais ajustes.

Inicialmente, pode-se inferir que um maior número de camadas de neurônios resulte em um desempenho aprimorado da rede neural, pois isso aumentaria sua capacidade de aprendizado e melhoraria a precisão na delimitação de regiões de decisão. No entanto, aumentar o número de camadas intermediárias acarreta no aumento do custo computacional e pode gerar sobreajustes (*overfitting*) no modelo (VALLIM; GORNI; PLAUT, 2009).

Segundo Schempp (1989) não existe uma resposta definitiva sobre qual é o melhor número de camadas, isso depende do problema específico e da natureza dos dados. Ele ainda afirma que, em muitos casos, uma única camada intermediária pode ser suficiente para aproximar uma função arbitrária a partir dos dados fornecidos.

Sobre o número de camadas intermediárias, Cybenko (1989) cita em seus estudos que uma única camada oculta é suficiente para representar qualquer função contínua e que duas camadas intermediárias aproximam qualquer função matemática. No entanto, é importante destacar que esse resultado se baseiou em condições ideais e não leva em consideração fatores práticos, como o tamanho do conjunto de dados e a complexidade do problema em questão.

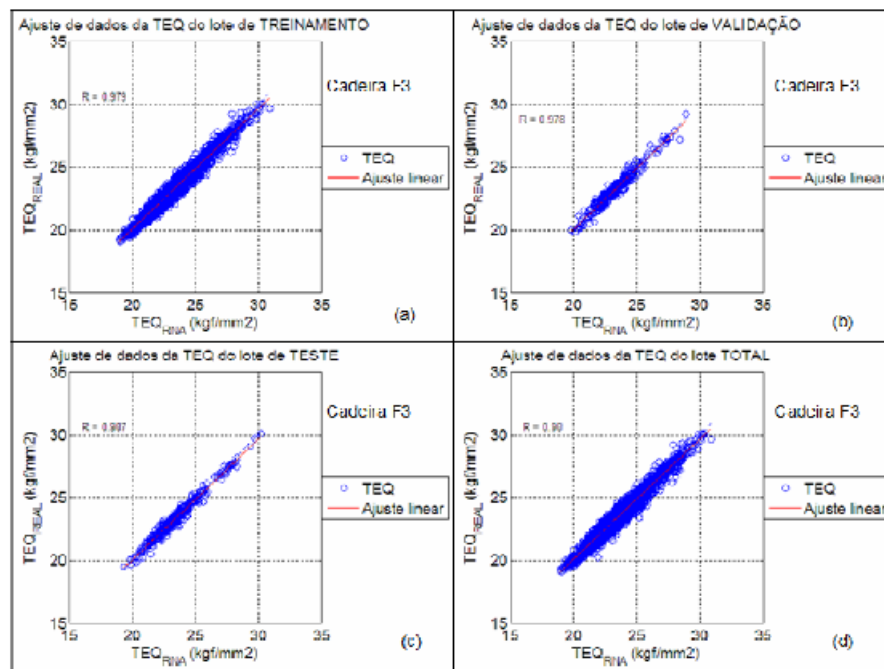
Na prática, a escolha do número de camadas em uma rede neural ainda depende de vários fatores como, a disponibilidade de dados de treinamento, a complexidade do problema, os recursos computacionais e a capacidade de generalização desejada. Portanto, é importante considerar as características específicas do problema e realizar experimentos para determinar o número de camadas mais adequado em cada caso.

## 2.5 Redes neurais aplicadas na laminação

Vários estudos foram desenvolvidos utilizando redes neurais para a realizar a previsão e/ou predição das variáveis de controle ou saída do processo de laminação (FINAMOR; WOLFF; LAGE, 2021; AGHASAFARI; ABDI; SALIMI, 2014; VALLIM; GORNI; PLAUT, 2009; BAGHERIPOOR; BISADI, 2011). Esses modelos podem oferecer alternativas poderosas para a resolução de problemas em diversas áreas de atuação abordando problemas complexos como o da laminação de tiras a quente.

Vallim, Gorni e Plaut (2009) realizaram a aplicação de redes neurais artificiais do tipo multicamada, de fluxo à vante, com correção de erro por retropropagação para calcular a tensão de escoamento a quente (TEQ) no processo de tiras a quente de aços C-Mn. O melhor resultado obtido foi utilizando uma RNA de 4 camadas de neurônios e 737 parâmetros livres (pesos e bias) que apresentou uma precisão de acerto superior ao modelo matemático de controle que estava em operação como mostrado na Figura 7.

Figura 7 – Relação de ajuste da TEQ fornecida pelo modelo de *set-up*, em função da TEQ fornecida pela rede neural.



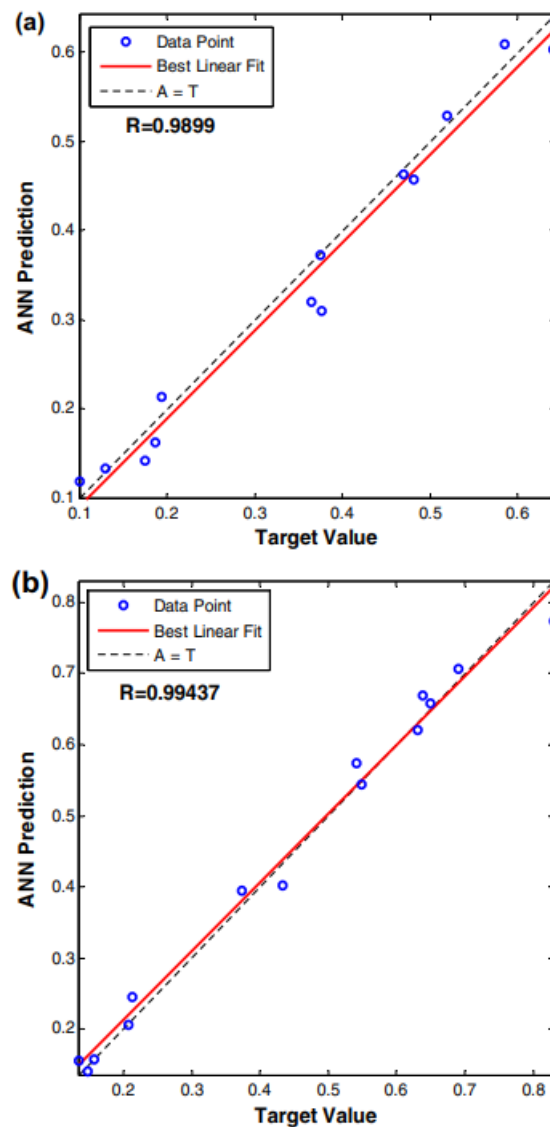
Fonte: (VALLIM; GORNI; PLAUT, 2009).

Aghasafari, Abdi e Salimi (2014) desenvolveram um modelo de redes neurais para prever as variações de tensão de escoamento durante o processo de laminação a quente utilizando uma MLP. Os resultados da rede foram comparados com os do método analítico convencional e erro médio absoluto foi reduzido drasticamente.

Bagheripoor e Bisadi (2013) aplicaram a rede MLP para a previsão da força e do torque no processo de laminação de tiras a quente. As variáveis de entrada foram a velocidade de laminação, o percentual de redução de espessura, a temperatura inicial da tira e o coeficiente de atrito no arco de contato. A função de ativação utilizada foram sigmoide e tangencial nas camadas ocultas e de saída e o algoritmo de retropropagação *Levenverg-Marquardt* foi selecionado como função de treinamento. Segundo os autores, este método é mais rápido para treinar redes neurais de tamanho moderado. A RNA mostrou-se capaz de fornecer previsões confiáveis para o controle *on-line* e otimização do processo. A Figura 8 mostra o desempenho da RNA.

Em todos esses trabalhos, a temperatura de processo foi utilizada como variável de entrada tanto para previsão de forças de laminação, tensão de fluxo, quanto propriedades mecânicas finais do produto. Isso porque uma das características de fundamental importância no processo de laminação à quente é a qualidade do aquecimento da placa.

Figura 8 – Desempenho do modelo RNA proposto na previsão da (a) força e (b) torque de laminação.



Fonte: (BAGHERIPOOR; BISADI, 2013).

O presente trabalho busca aplicar em variáveis de processo históricas de reaquecimento a arquitetura de redes neurais para realizar a previsão da força de laminação que servirá como referência para indicar a condição de encharque da placa. Como resultados espera-se um ganho em performance da linha de produção da laminação a quente da Usiminas de Ipatinga e a redução de custo de consumo de combustível do forno de aquecimento do tipo *pusher*.

## 3 Metodologia

### 3.1 Construção da base de dados

Para alimentação do modelo de predição da força de laminação após o reaquecimento foi extraída uma base histórica de dados referentes a 1 ano de operação do forno *pusher* para que fosse possível abranger grande parte do portfólio de produtos processados nesse equipamento. Os registros do processo de laminação e de informações dos produtos são armazenados em banco de dados *Oracle* e no banco de dados corporativo, acessados via PIMS e SQL server. A base de dados obtida possui 25.200 produtos e 700.000 observações.

A fim de se ter acesso aos dados de processo foi desenvolvida uma *query* para buscas nas tabelas do banco de dados relacionais e o resultado da consulta foi salvo em planilhas no formato “.xlsx” para que ficassem disponíveis para utilização no modelo de previsão.

#### 3.1.1 Obtenção dos dados de reaquecimento

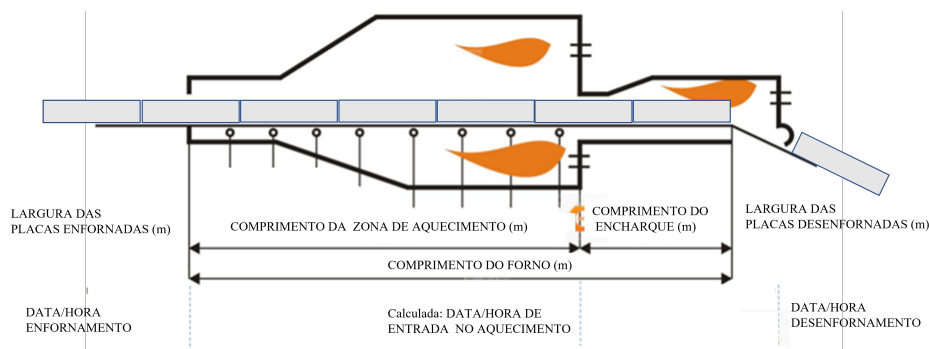
Como o forno em estudo não possui modelo automático de controle, as variáveis disponíveis para avaliação do aquecimento são a data/hora de início e fim de processo (tempo total) e as variações de temperaturas do ambiente do forno medidas por termopares. Portanto, avaliar o processo de reaquecimento apenas com esses dados sem considerar as paradas de linha e as variações de ajuste de temperatura em cada zona individualmente, por exemplo, pode tornar o modelo preditivo pouco preciso.

É importante ressaltar que a precisão de uma RNA está intrinsecamente relacionada a qualidade e quantidade dos dados de entrada usados no seu treinamento (AGHASAFARI; ABDI; SALIMI, 2014).

Desta forma, a fim de fornecer mais dados úteis e melhorar a precisão da rede, foi desenvolvido um algoritmo em linguagem *python* para cálculo dos tempos de residência por zona de aquecimento do forno e as suas respectivas temperaturas médias de controle. Isso só foi possível devido à principal característica desse equipamento, que é o deslocamento das placas dentro do forno por meio do empurrão da placa anterior sobre a posterior. Quando uma placa é enfiada, ela empurra toda a carga existente e em consequência uma placa é desenfiada na saída. Sendo assim, foi utilizado como referência a data e hora de entrada e saída das placas enfiadas e a sua largura, que foi correlacionada com o comprimento do forno, como mostrado na Figura 9, para calcular o momento que a placa iria estar na zona intermediária ou seja saindo da zona de aquecimento e entrando na zona de encharque. Assim, os tempos de aquecimento e encharque puderam ser calculados com precisão.



Figura 9 – Representação das variáveis de reaquecimento calculadas para o forno *pusher*.



Fonte: Própria autora.

Com base na data/hora calculada de entrada e saída da placa em cada zona do forno, foram obtidas as temperaturas médias de ambiente para cada etapa do aquecimento (temp. média de aquecimento superior e inferior e temp. média de encharque), excluindo os momentos em que ocorreram grandes reduções de temperatura (temperaturas ambientes < 900°C), indicando que ocorreu parada na linha e interrupção parcial do aquecimento.

Com esse procedimento foram calculadas novas variáveis de processo. A descrição das variáveis aplicadas no modelo são mostradas na Figura 10.

Figura 10 – Descrição das variáveis.

Código da Variável	Descrição	Origem	U.M	Tipo
TEMPO TOTAL	Tempo total de permanência no forno	Banco de Dados	min	Entrada
LARGURA PLACA	Largura da placa	Banco de Dados	mm	Entrada
PESO PLACA	Peso da placa	Banco de Dados	kg	Entrada
REDUCAO PASSE	Redução a quente no primeiro passe de desbaste	Banco de Dados	mm	Entrada
GRAU DE AÇO	Grupo de Aço	Banco de Dados		Entrada
TEMPO AQUECIMENTO	Tempo total de permanência na zona de aquecimento	Calculada	min	Entrada
TEMPO ENCHARQUE	Tempo total de permanência na zona de encharque	Calculada	min	Entrada
TEMP MEDIA AQUECIMENTO INF	Temperatura média na zona de aquecimento inferior	Calculada	°C	Entrada
TEMP MEDIA AQUECIMENTO SUP	Temperatura média na zona de aquecimento superior	Calculada	°C	Entrada
TEMP MEDIA ENCHARQUE	Temperatura média da zona de encharque	Calculada	°C	Entrada
TEMPO EFETIVO - FORNO	Tempo de permanência desconsiderando o tempo de parada de linha	Calculada	min	Entrada
TEMP MEDIA ÁGUA	Temperatura média da água de resfriamento da vigas das zonas de aquecimento	Calculada	°C	Entrada
FORÇA	Força de laminação no primeiro passe de desbaste	Banco de Dados	t	Saída

### 3.2 Pré-processamento dos dados

Após a preparação da base de dados, a etapa de pré-processamento envolveu a eliminação de *outliers*, erros/variações de medições e dados faltantes. Toda a implementação deste trabalho foi feita utilizando a linguagem *python*. Nesta etapa, foi utilizado o pacote *Pandas* para estruturação e análise dos dados (TEAM, 2020).

Em função da dimensão da base de dados, optou-se pela imputação de dados ao invés da exclusão das observações com valores faltantes (*missing values*). Os dados faltantes foram substituídos pela mediana.

Além disso, algumas observações apresentaram valores muito destoantes quando se considera o valor z-score (*outliers*). Os valores com mais de três desvios padrão foram removidos que correspondem a 700 observações.

### 3.3 Normalização dos dados

A Figura 11 apresenta a estatística descritiva da base de dados, constituída pelos valores de contagem, média, desvio padrão e dos intervalos interquartílicos, respectivamente. Os dados apresentam consistência com os valores correntes de utilização industrial.

Figura 11 – Exemplo de algumas variáveis utilizadas do banco de dados.

	PESO PLACA (kg)	FOR_HOR_LAM	RED_PASS_HOT	TEI_TR_TOPO	MIN_AQUECIMENTO	MIN_ENCHARQUE	MEDIA_AQUECIMENTO_INF	MEDIA_AQUECIMENTO_SUP	MEDIA_AGUA	Tempo Efetivo	MEDIA_ENCHARQUE	GRAU DE AÇO
count	22588.00	22588.00	22588.00	22588.00	22588.00	22588.00	22588.00	22588.00	22588.00	22588.00	22588.00	22588.00
mean	14551.34	1235.25	25.36	984.21	194.12	96.27	1285.09	1287.77	45.24	285.67	1295.16	86.07
std	2518.32	185.71	0.45	147.53	65.42	49.96	14.77	22.85	4.56	66.87	110.94	45.90
min	6380.00	541.00	17.27	0.00	41.00	-1155.00	1184.77	1197.47	30.18	0.04	0.00	1.00
25%	12850.00	1110.00	25.40	994.00	160.00	75.00	1278.46	1274.99	43.06	252.00	1298.08	48.00
50%	14520.00	1227.00	25.61	1007.00	181.00	95.00	1286.65	1290.74	46.22	276.00	1304.61	96.00
75%	15730.00	1352.25	25.61	1018.00	211.00	115.00	1296.30	1303.66	48.67	308.00	1315.73	119.00
max	23090.00	2087.00	26.12	1090.00	1465.00	773.00	1320.76	1352.01	54.27	934.00	1346.08	185.00

Nota-se entretanto, que as variáveis assumem valores com diferentes grandezas variando na ordem de 23090 (peso da placa em quilos) a 26 (redução em mm), ou seja, as variáveis que possuem valores mais altos tendem a ter uma variância também maior e, portanto, sua importância pode ser superestimada no processo de análise. Para uniformizar as medidas foi empregado o método supervisionado de aprendizagem da biblioteca *Scikit-Learn* (PEDREGOSA et al., 2011) que possui a classe *MinMaxScaler* que dimensiona todos os recursos de dados no intervalo [0, 1]. A normalização é realizada através da Equação (3.1). Onde,  $x(t)$  é o novo valor de  $x$  após a transformação, em função dos pontos máximos e mínimos para cada variável contínua do banco de dados. Outros métodos como a padronização foram aplicados mas, este foi o que melhor ajustou a base de dados.

$$x(t) = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

### 3.4 Análise de componentes principais

Em processos de produção é comum a geração de grandes volumes de dados, resultantes de medições e registros de diversas variáveis ao longo do tempo. Quando se trata de relações de dependência ou de interações entre as variáveis, a análise de componentes principais (PCA) é uma técnica comumente utilizada para reduzir a dimensionalidade de um conjunto de dados sem perda significativa de informações relevantes.

O método da PCA permite obter novas componentes a partir de combinações lineares das componentes originais, por meio de operações de soma e multiplicação escalar (BÜCKER, 2012). De acordo com Neto e Moita (1998), essa técnica também pode ser empregada para avaliar a importância das variáveis originais selecionadas. Em outras palavras, as variáveis originais que possuem maiores pesos na combinação linear das primeiras componentes principais são consideradas as mais relevantes do ponto de vista estatístico.

Dessa forma, o uso de um baixo número de dimensões é fundamental para a extração de conhecimento e permite realizar representações gráficas de forma mais simples, além da redução do custo computacional (GHODSI, 2006).

O uso de técnicas de redução de dimensão é uma estratégia eficiente para lidar com essa grande quantidade de informações disponíveis, eliminar correlação entre as variáveis da base de dados, reconstruindo a mesma apenas com as variáveis de maior importância melhorando a precisão dos modelos de aprendizado de máquinas. Além disso, é importante eliminar do modelo as variáveis desnecessárias para se evitar *overfitting*.

## 3.5 Modelamento da rede neural artificial

Neste trabalho foi adotado a abordagem supervisionada em que a base de dados escolhida possui entradas rotuladas que determinam as variáveis de saída e a etapa de aprendizagem consiste na criação de um modelo que se ajuste a estes dados.

### 3.5.1 Partição da base de dados

A base de dados foi dividida em dois conjuntos: treinamento e validação na seguinte proporção 80% e 20%. Essa divisão é feita a fim de evitar o sobreajuste dos dados e estimar o desempenho e a capacidade de generalização do modelo preditivo gerado. Os dados de treinamento foram aplicados para calibrar o modelo, enquanto os de validação foram utilizados para eleger o modelo com o melhor desempenho preditivo.

### 3.5.2 Rede neural MLP

Dentre as topologias de redes neurais do tipo *feedforward*, a *Multilayer Perceptron* está entre as mais frequentemente utilizadas. Sua arquitetura é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Durante a propagação do sinal de entrada pela rede, este é transmitido em direção à camada de saída, passando por cada camada oculta, sendo capaz de aprender e mapear as relações complexas entre os dados de entrada e saída. (HAYKIN, 1998). A MLP é muito aplicada no modelamento de funções complexas e o seu aprendizado ocorre por meio de algoritmos capazes de determinar os pesos de cada neurônio, tanto das camadas intermediárias como da camada de saída, de modo que todos os parâmetros da rede estejam sintonizados de maneira iterativa.

Neste trabalho, a MLP foi desenvolvida utilizando o *framework* do *TensorFlow* (ABADI et al., 2016), mais especificamente, o API *KerasTuner* (CHOLLET et al., 2015). Esta API é uma biblioteca de aprendizado profundo capaz de realizar buscas de treinamento e validação de forma automatizada, estabelecendo a melhor rede testada dentro das configurações estabelecidas. Nesse caso, o algoritmo ajusta de forma aleatória as camadas, número de neurônios, funções de ativação, além dos parâmetros de perda e otimização.

#### 3.5.2.1 Compilando o modelo

Os parâmetros de rede foram testados pelo algoritmo com 100 épocas em cada execução e são mostrados na Figura 12. Para a execução da RNA foram utilizados os otimizadores mais comuns disponíveis no Keras para ajuste dos pesos sinápticos da rede.

Figura 12 – Parâmetros e configurações testadas.

Parâmetros de rede MLP	
Nº de camadas densas	1 a 4
Nº de neurônios em cada camada	0 a 250
Otimizador	adam, adamax, nadam, SGD, RMSprop
Inicialização dos pesos sinápticos	Uniforme
Função de ativação camada intermediárias	relu, sigmoid, tanh
Função de ativação camada de saída	linear
Função de custo	MAE, MAPE
Métricas	MAE, MAPE

As funções de custo usadas pelo otimizador para ajuste dos pesos sinápticos e as métricas para comparação do desempenho da previsão dos modelos foi feita pelo cálculo dos valores de composição do erro absoluto médio (MAE) Eq. (3.2) e do erro absoluto médio percentual (MAPE) (Eq. 3.3) do modelo final.

$$\varepsilon_{MAE} = \frac{\sum_{i=0}^{n-1} |y_{\text{verdadeiro}} - y_{\text{predito}}|}{n} \quad (3.2)$$

sendo  $\epsilon_{MAE}$  o erro absoluto médio,  $y_{verdadero}$  a saída real,  $y_{predito}$  a saída da rede neural e  $n$  o número de amostras consideradas.

$$\epsilon_{MAPE} = \frac{100}{n} \times \frac{\sum_{i=0}^{n-1} |y_{verdadero} - y_{predito}|}{y_{verdadero}} \quad (3.3)$$

sendo  $\epsilon_{MAPE}$  o erro absoluto médio percentual.

## 4 Resultados

### 4.1 Exploração da base de dados para modelamento

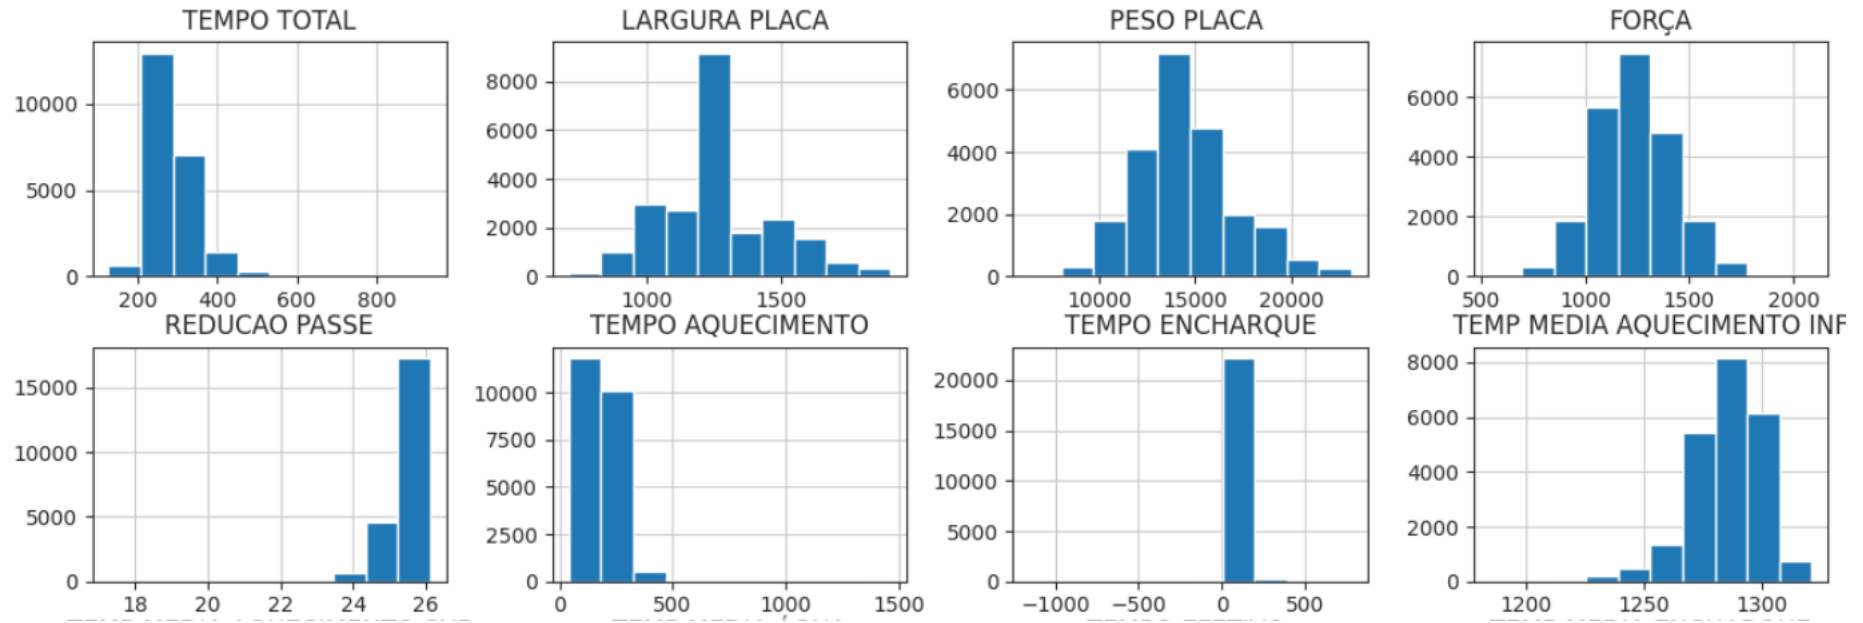
O banco de dados utilizado na RNA para previsão da força de laminação contém variáveis associadas ao processo de reaquecimento, características dimensionais da placa (largura e peso) e parâmetros de laminação dos passes de desbaste (redução no primeiro passe) que após o tratamento de dados apresentou 261.600 observações. Nas Figuras 13 e 14 são mostrados os histogramas do conjunto de dados, onde o eixo da abscissa representa a grandeza avaliada e o eixo da ordenada representa a frequência absoluta com que o valor da grandeza se repete no conjunto de dados.

Nota-se que os valores de força de laminação que são utilizados como variável resposta da RNA estão distribuídos de maneira normal, o que pode melhorar o desempenho dos algoritmos nas etapas de aprendizagem e previsão. Entretanto, algumas variáveis não apresentam esse mesmo comportamento como a temperatura média da água de refrigeração das vigas de apoio da placa no forno, o grau de aço e a largura. Isso ocorre porque a temperatura da água é influenciada diretamente pelas condições de temperatura ambiente do forno que podem sofrer grandes alterações quando em parada ou operação da linha, situações que não foram tratadas de forma separada para essa variável. A distribuição do peso, largura e grupo de aço são influenciados diretamente pelo mix de produtos produzidos no período estipulado para coleta dos dados.

Em relação às variáveis de controle do forno, é observado que tanto a temperatura quanto o tempo de permanência na zona de aquecimento apresentam maiores variações em comparação à zona de encharque. Isso se deve ao fato de que na zona de aquecimento ocorrem as maiores variações de temperatura ambiente, devido à diferença significativa de temperatura entre a placa quando é enfornada (fria) e o ambiente do forno. Além disso, é importante destacar que a zona de aquecimento compreende a maior parte do comprimento do forno, o que a torna responsável pela maior influência no tempo total de permanência da placa.

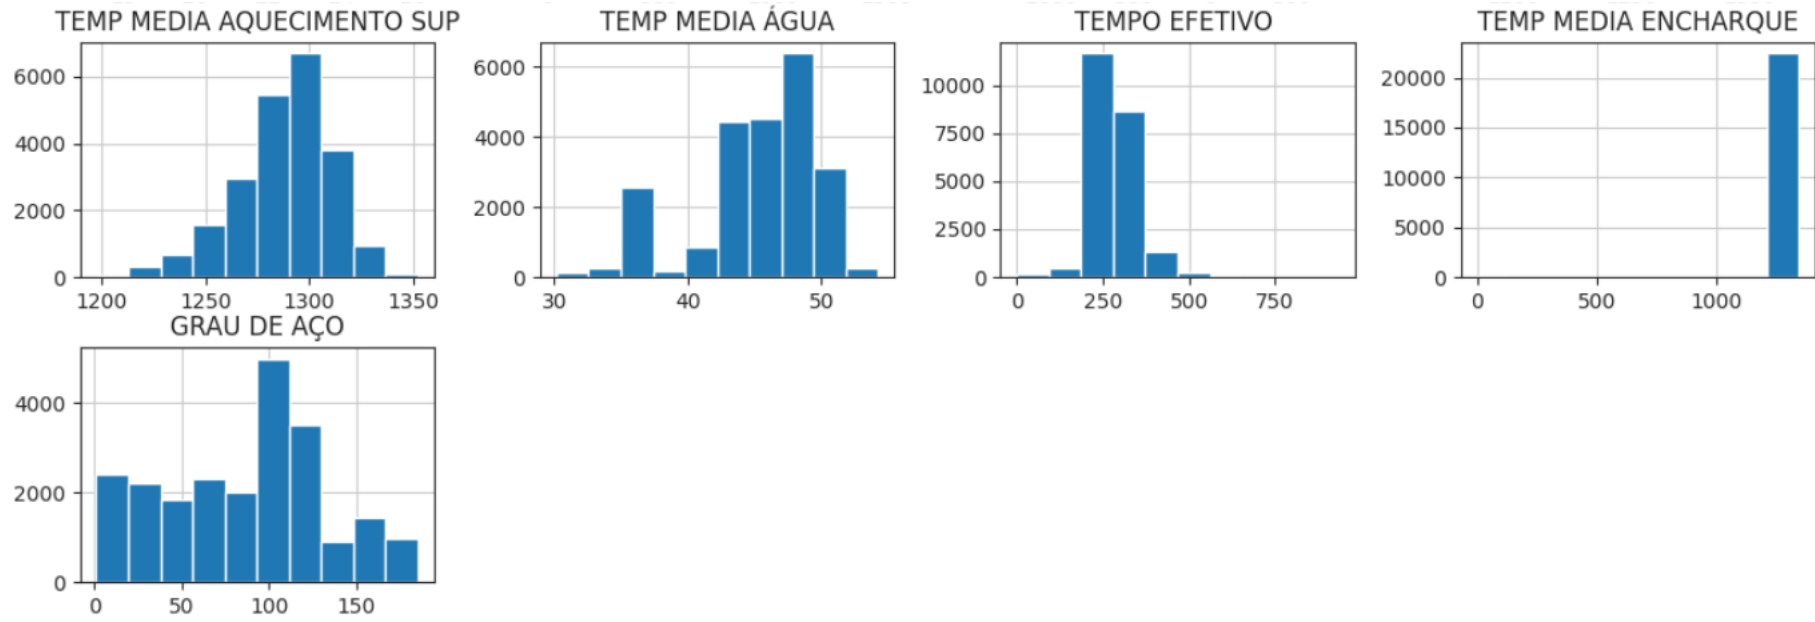
Outro ponto que chamou atenção são as variáveis de controle relacionadas a zona de encharque que não apresentaram variações significativas. Isso pode ser explicado pelo fato de que essa etapa corresponde ao final do processo de reaquecimento, quando a temperatura da placa se aproxima da temperatura ambiente do forno, exigindo assim uma maior estabilidade térmica nessa região para garantir que a placa alcance a temperatura desejada ao término do processo. Embora essa zona exerça uma influência direta na homogeneidade térmica da placa durante a operação prática, devido à menor variabilidade dos dados, a RNA pode subestimar a sua importância.

Figura 13 – Histograma do conjunto de dados utilizado.



Fonte: Própria Autora.

Figura 14 – Histograma do conjunto de dados utilizado.




Fonte: Própria Autora.



Na Figura 15 é mostrado o mapa de calor *Heatmap* que apresenta o índice de correlação de *Pearson* por um mapa de cores (forte ou fraca). Nota-se que existem variáveis correlacionadas, com valores absolutos de correlação maiores que 0,60 que são, por exemplo, a largura da placa com o seu peso, o tempo total de permanência com o tempo efetivo e de aquecimento. Essas relações lineares fortes de variáveis derivadas como largura e peso podem gerar perturbações no processo de treinamento dos algoritmos.

Figura 15 – *Heatmap*.




Fonte: Própria Autora.

## 4.2 Análise de componentes principais

Foi empregado a técnica de PCA buscando reduzir o número de entradas da RNA para melhorar o seu desempenho, o tempo de treinamento e atenuar o efeito de correlação de algumas variáveis como mostrado no *Heatmap*. A Figura 16 mostra o número de componentes principais e o grau de variância que essa componente explica. Se observa que os seis primeiros componentes principais representam uma variância acumulada total de 94%.

Figura 16 – Variância explicada em função do número de componentes principais.

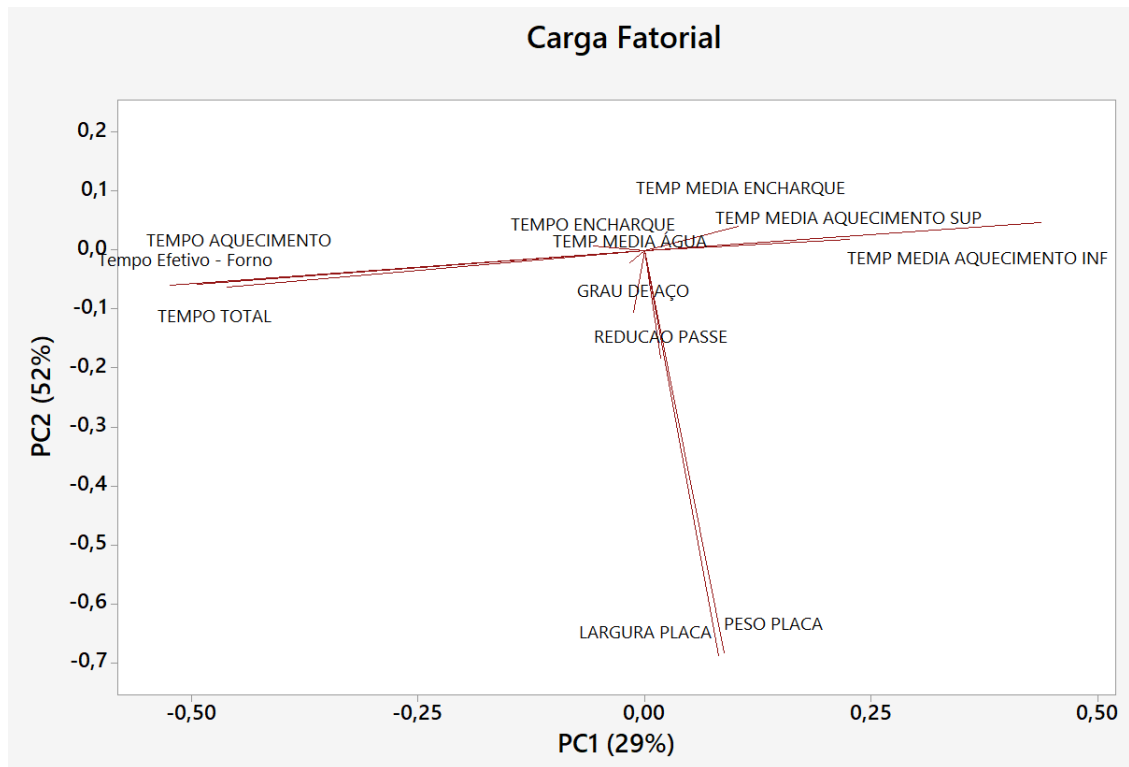


Fonte: Própria Autora.

A relação entre as componentes principais PC1 e PC2 e o peso das variáveis na composição das componentes principais são mostrados na Figura 17. Nota-se que é possível realizar o agrupamento de algumas variáveis que estão correlacionadas como o tempo de aquecimento com o tempo total, a largura com o peso e as temperatura de aquecimento superior inferior.

Para a base de dados estudada as condições de processo na zona de aquecimento, o dimensional da placa e as reduções aplicadas foram as variável que mais contribuíram para explicar a variância dos dados. Foram aplicadas no modelo 7 das 12 variáveis iniciais considerando os agrupamentos possíveis e as variáveis de maior importância que foram: largura da placa, redução no passe, tempo de aquecimento, tempo de encharque, temperatura média de aquecimento das zonas superior e inferior (agrupada), temperatura média de encharque e grau de aço.

Figura 17 – Componentes principais PC1 e PC2 e sua relação com a força de laminação.



Fonte: Própria Autora.

### 4.3 Previsão da RNA

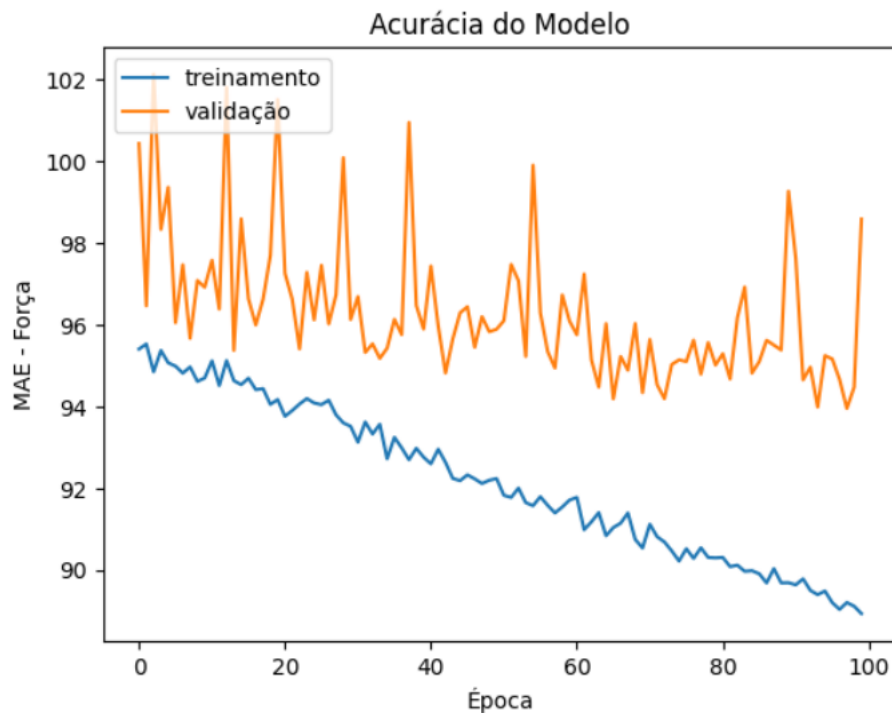
O treinamento da RNA com as várias configurações de arquitetura foi realizado e na figura 18 é mostrado o melhor modelo de rede encontrado.

Figura 18 – Melhor seleção de parâmetros encontrada para a rede MLP testada.

Melhor seleção de parâmetros para a rede MLP		
Camadas	Nº neurônios	Função de ativação
Densa 1	176	linear
Densa 2	208	relu
Densa 3	208	tanh
Densa 4	160	relu
Otimizador	adamax	

Observa-se na figura 19 o resultado de desempenho da RNA. A generalização desse resultado foi bastante adequada considerando o grau de ajuste obtido para os conjuntos de treinamento e validação. Além disso, as variáveis de reauecimento e dimensionais de placa se mostraram suficientes para previsão da força de laminação no primeiro passe de desbaste utilizando a RNA.

Figura 19 – Desempenho da RNA no treinamento e validação.

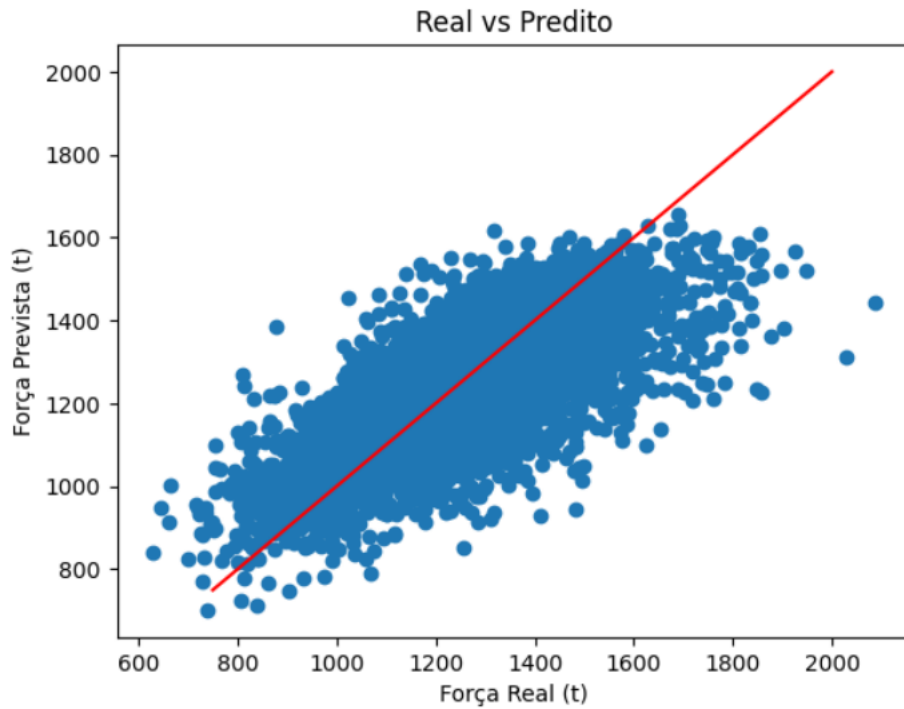


Fonte: Própria Autora.

Na Figura 20 é mostrado o gráfico de dispersão entre os valores reais e previstos, empregando-se a base de testes padronizada para a RNA, bem como o erro de previsão MAE de 95 t. O erro da RNA, se comparado com as medidas de incerteza e precisão dos equipamentos de medição usuais e as tolerâncias de erro dos modelos de controle online esse valor pode ser considerado satisfatório, representando um valor médio de, aproximadamente, 5% com relação ao valor real. Entretanto, nota-se uma dispersão dos resultados previstos em relação ao real que pode ser melhorada aumentando a base de dados e discriminando algumas variáveis como o grupo de aço separa-o por classes de materiais com características metalúrgicas semelhantes no que tange o tamanho de grão austenítico e elementos em solução sólida, por exemplo.

Além disso, observa-se uma redução no desempenho da rede neural ao prever valores de carga mais elevados, acima de 1800 t. Essa limitação pode ser atribuída à menor quantidade de dados reais disponíveis nessa faixa, especificamente 73 de um total de 25200 produtos. Além do número baixo de observações, ao dividir a base de dados em conjuntos de treinamento e validação, pode ter ocorrido um desequilíbrio na distribuição dos dados entre os dois conjuntos. Para melhorar o desempenho da RNA nesses casos, é recomendado realizar um novo treinamento da rede utilizando dados de produção de um período mais abrangente. Isso permitirá uma maior variedade de dados e, conseqüentemente, um melhor desempenho da rede neural.

Figura 20 – Gráfico de dispersão entre valores previstos e reais.




Fonte: Própria Autora.

#### 4.4 Estudo de caso - Trabalhos Futuros

Uma forma de se aplicar a RNA desenvolvida na linha de produção seria para realizar a previsão da força que o material atingiria quando laminado no primeiro passe da etapa de desbaste antes da extração da placa, como mostrado no esquema da figura 21.

Figura 21 – Exemplo de aplicação da RNA desenvolvida.



Fonte: Própria Autora.

Quando o material entrar na zona de encharque, que é a última etapa do reaquecimento, a rede neural calcula a força prevista para cada placa a ser desenfundada. Em seguida, compara-se o valor previsto com o histórico de força de cada grupo de aço, determinando se a condição de encharque da placa está adequada. Se os valores previstos estiverem distantes dos valores de referência a operação do forno deverá atuar no controle das temperatura de ambiente e no ritmo da linha de forma mais ágil buscando melhorar a homogeneidade térmica das placas ou seja reduzindo os valores de força previstos. Com essa referência da condição térmica da placa, espera-se uma maior assertividade de controle de processo e um ganho em performance da linha de produção.

## 5 Considerações Finais

Este trabalho teve como objetivo principal o uso de algoritmos de redes neurais artificiais para prever a força de laminação no primeiro passe de desbaste, a fim de contornar a falta de referência da condição térmica da placa após o processamento no forno do tipo *pusher*. Foram selecionados dados históricos de reaquecimento, dimensionais e diferentes grupos de produtos já processados nesse forno para composição da base de dados.

Os resultados obtidos com a rede neural foram consistentes, apresentando um erro médio de aproximadamente 5% em relação aos valores reais de medição de força e se mostraram promissores considerando o ajuste obtido nos conjuntos de treinamento e validação.

Recomenda-se que o modelo seja aplicado em uma base de dados de teste independente, para prever a força de laminação em materiais na etapa final de reaquecimento e comparar as previsões com os valores de força medidos pelas células de carga após a laminação, a fim de avaliar seu desempenho em produção.

Adicionalmente, foi constatado que a largura da placa, a redução aplicada no passe e as temperaturas e tempos da zona de aquecimento foram as variáveis de processo com maior relevância na previsão da força, ou seja, na condição térmica da placa. Essas variáveis podem ser empregadas como referência para otimizar os parâmetros de controle do forno, buscando aprimorar o seu desempenho e a eficiência do processo.

Como trabalhos futuros, sugere-se utilizar as mesmas variáveis de processo para criação de uma RNA categórica de previsão da força de laminação para ser utilizada como dupla verificação da condição térmica da placa, ou seja, caso a força prevista estivesse dentro do intervalo estipulado para o grupo de aço ao qual a placa pertence, indicaria que a condição do forno está adequada. Caso contrário, o modelo neural desenvolvido neste estudo poderia calcular o valor relativo de força esperado para a placa inconsistente, permitindo que o operador avalie e atue na melhoria do controle do processo.

# Referências

- ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M. et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. **arXiv preprint arXiv:1603.04467**, 2016. 17
- AGHASAFARI, P.; ABDI, H.; SALIMI, M. Artificial neural network modeling of flow stress in hot rolling. **ISIJ international**, The Iron and Steel Institute of Japan, v. 54, n. 4, p. 872–879, 2014. 1, 10, 11, 13
- ARAÚJO, L. A. d. Manual de siderurgia–volume 1–produção. **Editora Arte & Ciência**, 2009. 6
- BAGHERIPOOR, M.; BISADI, H. Effects of rolling parameters on temperature distribution in the hot rolling of aluminum strips. **Applied thermal engineering**, Elsevier, v. 31, n. 10, p. 1556–1565, 2011. 10
- BAGHERIPOOR, M.; BISADI, H. Application of artificial neural networks for the prediction of roll force and roll torque in hot strip rolling process. **Applied Mathematical Modelling**, Elsevier, v. 37, n. 7, p. 4593–4607, 2013. 11, 12
- BARBOSA, A. A. e. a. Avaliação do encharque da placa baseada no cálculo da energia de deformação no processo do desbaste. In: ABM (Ed.). **SEMINÁRIO DE LAMINAÇÃO – PROCESSOS E PRODUTOS LAMINADOS E REVESTIDOS**. [S.l.: s.n.], 2006. 4
- BARBOSA, G. C. Simulação por elementos finitos do processo de laminação de tiras a quente de aços c-mn. **Universidade Federal Fluminense**, 2014. 4
- BARBOSA, J. V.; DADOMI, E. F.; DIAS, P. B. Melhoria de qualidade do aço elétrico ligado ao silício através da laminação em fase ferrítica na linha de tiras a quente. **Seminário de laminação ABM Week**, v. 52, p. 246–255, 2015. 3
- BÜCKER, M. Alan julian izenman: Modern statistical techniques: regression, classification, and manifold learning. **Statistical Papers**, Springer Nature BV, v. 53, n. 4, p. 1065, 2012. 16
- CHOLLET, F. et al. **Keras**. 2015. <<https://keras.io>>. 17
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of control, signals and systems**, Springer, v. 2, n. 4, p. 303–314, 1989. 10
- DEVADAS, C.; BARAGAR, D.; RUDDLE, G.; SAMARASEKERA, I.; HAWBOLT, E. The thermal and metallurgical state of steel strip during hot rolling: Part ii. factors influencing rolling loads. **Metallurgical Transactions A**, Springer, v. 22, p. 321–333, 1991. 3
- FAUSETT, L. V. **Fundamentals of neural networks: architectures, algorithms and applications**. [S.l.]: Pearson Education India, 2006. 7
- FINAMOR, F.; WOLFF, M.; LAGE, V. Prediction of forming limit diagrams from tensile tests of automotive grade steels by a machine learning approach. In: IOP PUBLISHING. **IOP Conference Series: Materials Science and Engineering**. [S.l.], 2021. v. 1157, n. 1, p. 012080. 1, 10



- GHODSI, A. Dimensionality reduction a short tutorial. **Department of Statistics and Actuarial Science, Univ. of Waterloo, Ontario, Canada**, v. 37, n. 38, p. 2006, 2006. 16
- GIACOMIN, C. N.; BAHIA, J. V.; SANTOS, A. A. dos; SOUZA, A. de C. Desenvolvimento de software de balanço térmico de fornos de reaquecimento de placas integrado com sistema de controle. **54º Seminário de Laminação e Conformação: Anais do Seminário de Laminação e Conformação, Sao Paulo**, v. 1, n. 1, p. 236–247, 2017. 1, 4, 7
- HAYKIN, S. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice Hall PTR, 1998. 7, 17
- HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001. 7, 8
- JÚNIOR, J. Claudino de L. **Simulação numérica de um forno de reaquecimento**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2007. 1
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943. 7
- NETO, J. M. M.; MOITA, G. C. An introduction analysis exploratory multivariate data. **Química Nova**, SciELO Brasil, v. 21, p. 467–469, 1998. 16
- PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V. et al. Scikit-learn: Machine learning in python. **the Journal of machine Learning research**, JMLR. org, v. 12, p. 2825–2830, 2011. 15
- RENAUX, J.; LECIGNE, R.; MEUNIER, R.; REGNIER, M.-C.; HUG, P. Modernization of steel slab reheating furnaces leads to improved productivity and thermal homogeneity. **Industrial heating**, Business News Publishing, v. 65, n. 6, 1998. 6
- RIZZO, E. M. da S. **Processos de laminação dos aços: uma introdução**. [S.l.]: ABM, 2007. 5, 6
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958. 7
- SANTOS, A. A. d.; SCHIAVO, C. P.; GIACOMIN, C. N. Simulação computacional do processo de reaquecimento de placas em fornos de viga móvel. **Tecnologia em Metalurgia, Materiais e Mineração**, ABM-Associação Brasileira de Metalurgia, Materiais e Mineração, v. 5, n. 1, p. 35–39, 2013. 4, 6
- SANTOS, A. A. d.; TEIXEIRA, M. H.; MARQUES, V. A. Ajuste do modelo matemático dos fornos de reaquecimento de placas para operação com gás natural. **Tecnologia em Metalurgia, Materiais e Mineração**, ABM-Associação Brasileira de Metalurgia, Materiais e Mineração, v. 1, n. 1, p. 214–223, 2015. 4, 6
- SANTOS, A. A. dos; GIACOMIN, C. N.; RESENDE, B. A. Previsão da evolução térmica durante a laminação a quente dos aços. 3
- SCHEMPP, W. Neurocomputer architectures. **Results in Mathematics**, Springer, v. 16, n. 3-4, p. 345–382, 1989. 10

- SOARES, P. L. B.; SILVA, J. P. da. Aplicação de redes neurais artificiais em conjunto com o método vetorial da propagação de feixes na análise de um acoplador direcional baseado em fibra ótica. **Revista Brasileira de Computação Aplicada**, v. 3, n. 2, p. 58–72, 2011. [8](#)
- TEAM, T. P. D. Pandas-dev/pandas. **Pandas**, Zenodo, 2020. [14](#)
- TEIXEIRA, B. O. S.; JOTA, F. G.; TEIXEIRA, M. H. Modelagem, controle e otimização do processo dos fornos de reaquecimento de placas. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, SciELO Brasil, v. 18, p. 67–93, 2007. [7](#)
- VALLIM, P. S.; GORNI, A. A.; PLAUT, R. L. Aplicação de rede neural para cálculo da tensão de escoamento na laminação de tiras a quente de aços c-mn. **Anais. São Paulo, ABM, 2009**, 2009. [7](#), [10](#), [11](#)
- WANG, Z.; SHAO, C.; CHAI, T. Application of multivariable technique in temperature control of reheating furnaces. In: IEEE. **Proceedings of the 1999 IEEE International Conference on Control Applications (Cat. No. 99CH36328)**. [S.l.], 1999. v. 1, p. 29–32. [7](#)
- YANG, Y.-y.; LU, Y.-z. Dynamic model based optimization control for reheating furnaces. **Computers in industry**, Elsevier, v. 10, n. 1, p. 11–20, 1988. [7](#)