

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



# Previsão do nível de retrabalho da desempenadeira a quente por meio de redes neurais artificiais

Kleber Macedo da Silveira

João Monlevade, MG 2023 Kleber Macedo da Silveira

# Previsão do nível de retrabalho da desempenadeira a quente por meio de redes neurais artificiais

Trabalho de conclusão de curso apresentado ao curso de Ciência de 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 de Dados.

Orientador: Prof. Dr. Harlei Miguel de Arruda Leite

João Monlevade, MG

2023

#### SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO



Bibliotecário(a) Responsável: Sione Galvão Rodrigues - CRB6 / 2526



#### MINISTÉRIO DA EDUCAÇÃO UNIVERSIDADE FEDERAL DE OURO PRETO REITORIA INSTITUTO DE CIENCIAS EXATAS E APLICADAS DEPARTAMENTO DE COMPUTACAO E SISTEMAS



#### FOLHA DE APROVAÇÃO

Kleber Macedo da Silveira

Previsão do nível de retrabalho da desempenadeira a quente por meio de redes neurais artificiais

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

Aprovada em 07 de junho de 2023

Membros da banca

Prof. Dr. Harlei Miguel de Arruda Leite - Orientador (Universidade Federal de ouro Preto) Profa. Dra. Sarah Negreiros de Carvalho Leite - (Universidade Federal de Ouro Preto) Prof. Dr. Thiago Augusto de Oliveira Silva - (Universidade Federal de Ouro Preto)

Prof. Dr. Harlei Miguel de Arruda Leite, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 10/07/2023



Documento assinado eletronicamente por **Harlei Miguel de Arruda Leite**, **PROFESSOR DE MAGISTERIO SUPERIOR**, em 10/07/2023, às 21:29, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do <u>Decreto nº 8.539, de 8 de</u> outubro de 2015.



A autenticidade deste documento pode ser conferida no site <u>http://sei.ufop.br/sei/controlador\_externo.php?</u> acao=documento\_conferir&id\_orgao\_acesso\_externo=0, informando o código verificador **0555987** e o código CRC **9836F1D7**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.009043/2023-42

Aos amores da minha vida: Lucilene e Júlia! Aos meus pais Agenor e Maria Macedo e minhas irmãs Karla, Kelli e Kátia.

# Agradecimentos

A Deus, pela minha vida, e por me permitir superar os desafios encontrados ao longo da realização deste curso.

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

À USIMINAS, por meio da Gerência Corporativa de Tecnologia e Segurança da Informação e aos gerentes Eduardo Sebastiao de Carvalho e Cristiano de Lanna e também ao Guilherme Públio pela confiança e apoio para a realização deste trabalho.

A Lucilene e Júlia, aos meus pais Agenor e Maria Macedo, minhas irmãs Karla, Kelli e Kátia, Dona Delaide e Sr. Armando que me incentivaram e compreenderam a minha ausência enquanto eu me dedicava à realização deste curso.

Aos colegas de trabalho: Fabricio Mazola, Gustavo Linhares, Elanderson Quitete, Lucas Xavier, Maciel Cimini Mota, Waldenize Silva Gomes, Fernando Miranda Fontes, pelas contribuições e sugestões para a execução deste trabalho.

À UFOP e seus professores, pela qualidade dos ensinamentos e atenção em todos os aspectos deste curso.

Ao professor Prof. Dr. Harlei Miguel de Arruda Leite por ter sido meu orientador e por toda dedicação e paciência.

Ao Felipe Finamor por toda ajuda na realização do trabalho e pela amizade que construímos ao longo do curso.

Aos colegas da turma de especialização em Ciência de dados, em especial ao Felipe Finamor, Priscila Batista e Glaucia Amanda Perucci, pela sinergia e comprometimento que permitiu ao nosso grupo obter ótimos resultados.

"Um navio está seguro no porto, mas não é para isto que os navios são construídos." Willian G. T. Shedd

# Resumo

A laminação de chapas grossas transforma as placas recebidas da Aciaria em chapas de aco para diversos tipos de aplicação. Para isso, são utilizados diversos processos e equipamentos de alta precisão para a obtenção de produtos com controles rigorosos de dimensões, forma e propriedades mecânicas. Nesse sentido, a desempenadeira a quente tem papel fundamental na correção de defeitos de planicidade que ocorrem no processo de laminação, reduzindo o retrabalho na desempenadeira a frio. Entretanto, atualmente, a operação da desempenadeira a quente é realizada por meio de tabelas de ajuste que exigem atualizações periódicas para a melhoria no acerto da planicidade. Visando melhorar esse processo, o presente trabalho propôs a aplicação de uma Rede Neural Artificial (RNA) Multilayer Perceptron (MLP), na previsão da utilização da desempenadeira a frio, que tem a função de corrigir a planicidade das chapas processadas na desempenadeira a quente. Para o desenvolvimento deste trabalho criou-se um banco de dados histórico envolvendo os materiais processados e a classificação dos acertos da planicidade, levando em consideração as observações de qualidade superficial, dimensões, temperatura do material e desvio para a desempenadeira a frio. Ademais, como o ritmo de produção pode restringir o tempo de desempeno, o banco de dados ficou restrito a materiais que necessitaram de somente um passe para atingir os resultados esperados de planicidade. Como a quantidade de amostras da base de dados se diferenciava entre as classes, técnicas de balanceamento foram empregadas. O modelo de previsão de retrabalho, utilizando a rede MLP e a técnica de oversampling SMOTE-Tomek, obteve desempenho acima de 97% de acurácia e *f1-score*, tanto para a predição de chapas com retrabalho quanto para a predição de chapas sem retrabalho. Desta forma, o uso do sistema desenvolvido nesse trabalho pode ser indicado aos especialistas da área de laminação de chapas grossas na tratativa de controle do processo de desempeno permitindo ajustes mais precisos na correção de planicidade dos produtos.

**Palavras-chaves**: Laminação de Chapas Grossas; Planicidade; Chapas de Aço; Qualidade do Produto; Rede Neural Artificial; Desempenadeira a Quente.

# Abstract

The plate mill rolling transforms slabs received from the steel plant into steel plates for different types of application. For this, several processes and high precision equipment are used to obtain products with strict control of dimensions, shape and mechanical properties. The hot leveller has a key role in correcting flatness defects that occur in the rolling process of plate mill, reducing rework on the cold leveller. However, currently, the operation of the hot leveller is performed using adjustment tables that require periodic updates to improve flatness. Aiming to improve this process, the present work proposed the application of a Artificial Neural Network (ANN) *MLP*, in the prediction of the rework at cold leveller which has the function of correcting the flatness of the plates processed in the hot leveller. For the development of this work, a historical database of processed materials was used and the flatness hits were classified, taking into account observations of surface quality, dimensions, material temperature and deviation to the cold leveller. The pace of production can restrict the straightening time, therefore, the database was restricted to materials that required only one pass to achieve the expected flatness results. Due to the class imbalance, balancing techniques were employed. The rework prediction model, using RNA MLP and the oversampling technique SMOTE-Tomek, obtained a performance above 97% accuracy and f1 -score, both for predicting plates with rework and for predicting plates without rework. Furthermore, the use of the system developed in this work can be indicated to specialists in the plate mill area, allowing more precise adjustments in the flatness correction of the products.

**Keywords**: plate mill rolling; flatness; steel plates; product quality; artificial neural network, hot leveller.

# Lista de ilustrações

Figura 1 – Layout da Laminação de Chapas Grossas.	1
Figura 2 – Planicidade do Material.  Image: Comparison of the second se	2
Figura 3 – Defeitos de Planicidade.	3
Figura 4  –  Processo de Sinterização.	6
Figura 5  –  Processo de Coqueria.	7
Figura 6  Processo de Alto-Forno.	7
Figura 7 – Fluxograma do processo de refino do aço na aciaria da Usiminas	8
Figura 8 – Desulfuração do gusa líquido em carro torpedo (à esquerda) e em panela de	
gusa (à direita).	9
Figura 9  Processo Forno Panela.	11
Figura 10 – Processo RH.  .	12
Figura 11 – Processo CAS-OB.	13
Figura 12 – Processo de Lingotamento.	14
Figura 13 – Layout da Linha de Chapas Grossas - Laminação a Quente (Parte A)	15
Figura 14 – Layout da Linha de Chapas Grossas - Laminação a Quente (Parte B)	15
Figura 15 – Pátio de Placas da Usiminas.	16
Figura 16 – Enformamento de Placas.	17
Figura 17 – Desenfornamento de placa.	17
Figura 18 – Descarepador.	18
Figura 19 – Jatos de descarepação	18
Figura 20 – Tipos de Laminadores	19
Figura 21 – Representação de Laminação de uma placa de aço	19
Figura 22 – Laminador de Chapas Grossas 4HI Reversível.	20
Figura 23 – Representação esquemática de um laminador quádruo	21
Figura 24 – Representação dos passes de laminação na chapa de aço	22
Figura 25 – Representação da escala de passes de laminação	23
Figura 26 – Representação da abertura entre os cilindros de trabalho - GAP	23
Figura 27 – Desempenadeira a Quente da Usiminas.	24
Figura 28 – Representação de defeito de ondulação de borda	25
Figura 29 – Representação de defeito de ondulação central	25
Figura 30 – Princípio do Desempeno a Quente	26
Figura 31 – Abertura crescente entre os rolos superiores e inferiores da desempenadeira.	26
Figura 32 – Chapa submetida a flexão elástico-plástica alternada entre os rolos	27
Figura 33 – Etapas do processo KDD	28
Figura 34 – Sistemas de Automação e armazenamento de dados	32
Figura 35 – Distribuição dos dados com relação aos níveis de retrabalho.	33

Figura 36 – Mapa de calor obtido pelas correlações de Pearson	35
Figura 37 – Saída de resultado do colab notebook mostrando quantidade de dados faltantes	. 36
Figura 38 – Boxplot relacionando o nível de retrabalho com a distribuição da variável.	37
Figura 39 – Distribuição após <i>oversampling</i> e <i>undersampling</i>	39
Figura 40 – Base dados desbalanceada x Base de dados após SMOTE-Tomek. Classe 0:	
classe minoritária e Classe 1: classe majoritária	40
Figura 41 – Balanceamento da Classe Retrabalho após a aplicação das técnicas under-	
sampling.	41
Figura 42 – Balanceamento da Classe Retrabalho após a aplicação das técnicas oversam-	
<i>pling</i>	41
Figura 43 – Balanceamento da Classe Retrabalho após a aplicação das técnicas under-	
sampling	42
Figura 44 – Neurônios e suas conexões	43
Figura 45 – Neurônio artificial	43
Figura 46 – Topologia de uma MLP com duas camadas intermediárias	45
Figura 47 – Configuração da MLP.	46
Figura 48 – Matriz de Confusão	48
Figura 49 – Matriz de Confusão.	49
Figura 50 – Matriz de Confusão e valores de precisão (precision), recuperação (recall)	
e fl-score obtidos após o treinamento da rede MLP - base de dados sem	
tratamento	52
Figura 51 – Matriz de Confusão e valores de precisão ( <i>precision</i> ), recuperação ( <i>recall</i> )	
e fl-score obtidos após o treinamento da rede MLP - base de dados com	
oversampling	53
Figura 52 – Matriz de Confusão e valores de precisão ( <i>precision</i> ), recuperação ( <i>recall</i> )	
e f1-score obtidos após o treinamento da rede MLP - base de dados com	
undersample	54
Figura 53 – Resultados de desempenho e valores de acurácia para treinamento e validação	
considerando as bases de dados com <i>oversampling</i>	55
Figura 54 – Matriz de confusão e valores de precisão ( <i>precision</i> ), Sensibilidade ( <i>recall</i> ) e	
f1-score obtidos após o treinamento da rede MLP com ajuste de hiperparâme-	
tros a partir das bases com <i>oversampling</i>	56
Figura 55 – Resultados de desempenho e valores de acurácia para treinamento e validação	
considerando as bases de dados com <i>undersampling</i>	57
Figura 56 – Matriz de confusão e valores de precisão ( <i>precision</i> ), Sensibilidade ( <i>recall</i> ) e	
f1-score obtidos após o treinamento da rede MLP com ajuste de hiperparâme-	
tros a partir da base com <i>undersampling</i>	58
Figura 57 – Desempenho médio considerando <i>oversampling</i> e <i>undersampling</i>	59
Figura 58 – Gráfico com os resultados de acurácia dos modelos MLP	61

Figura 59 -	Gráfico com os resultados de <i>f1-score</i> dos modelos MLP	62
Figura 60 –	Retrabalho x Espessura.	63
Figura 61 –	Retrabalho x Níquel	64
Figura 62 –	Gráficos de dispersão entre valores previstos e reais para a força de desem-	
	penadeira obtido após treinamento e ajuste de hiperparâmetros de uma rede	
	MLP	65
Figura 63 –	Gráficos de dispersão entre valores previstos e reais para o GAP de entrada	
	obtido após treinamento e ajuste de hiperparâmetros de uma rede MLP	65
Figura 64 –	Gráficos de dispersão entre valores previstos e reais para o GAP de saída	
	obtido após treinamento e ajuste de hiperparâmetros de uma rede MLP	66

# Lista de tabelas

Tabela 1	_	Dicionário de dados	31
Tabela 2	_	Tabela com estatísticas das variáveis.	34
Tabela 3	_	Tabela de configuração de busca de hiperparâmetros utilizada para previsão	
		de retrabalho	47
Tabela 4	_	Configuração da rede neural MLP	51
Tabela 5	_	Modelo de RNA do tipo MLP para base oversampling sugerido pelo Keras	
		Tuner	55
Tabela 6	_	Configuração e hiniperparâmetros para base undersampling utilizando o	
		Keras Tuner	57
Tabela 7	_	Resumo dos resultados obtidos para as bases de dados não balanceadas e	
		balanceadas	60

# Lista de abreviaturas e siglas

- **ANN** Artificial Neural Network
- CAS-OB Composition Adjustment by Sealed Argon Bubling
- CLC Continuos On-Line Control
- COG Coke Oven gas
- **CS** Crop Shear
- **DCS** Distributed Control System
- **DS** Diveded Shear
- **DSS** Double Side Shear
- FM Finishing Mill
- FN Falso Negativo
- FP Falso Positivo
- FTT Forno de Tratamento térmico
- GAP Abertura entre os cilindros de trabalho
- HL Hot Leveller
- HL-CLC Hot Leveller Continuos On-Line Control
- HSB Hot Scale Breaker
- KDD Knowledge Discovery in Databases
- LCG Laminação de Chapas Grossas
- LT Linha de Tesouras
- LT1CG Linha de Tesouras 1 Chapas Grossas
- MLP Multilayer Perceptron
- **PDI** Process Data Input
- PLC Programmable Logic Controller
- RH Ruhrstahl Heraeus

**RNA** Rede Neural Artificial

**SMOTE** Synthetic Minority Oversampling Technique

**TN** True Negative

**TP** True Positive

VN Verdadeiro Negativo

**VP** Verdadeiro Positivo

# Sumário

1	<b>INTRODUÇÃO</b>
1.1	Objetivo geral
1.1.1	Objetivos específicos
1.2	Organização do trabalho
2	PROCESSO SIDERÚRGICO
2.1	Produção do aço
2.2	<b>Redução</b>
2.3	<b>Refino</b>
2.3.1	Dessulfuração do gusa
2.3.2	Refino primário
2.3.3	Refino secundário
2.3.4	Lingotamento contínuo do aço
2.4	Linha de produção de laminação de chapas grossas
2.4.1	Pátio de placas
2.4.2	Forno de reaquecimento
2.4.3	Descarepador - HSB
2.5	Laminação a quente
2.6	Laminador de chapas grossas
2.7	Desempenadeira a quente
3	<b>METODOLOGIA</b> 28
3.1	Metodologia de mineração dos dados
3.2	<b>KDD</b>
3.3	Seleção dos dados
3.4	Pré-processamento dos dados
3.4.1	Distribuição dos dados
3.4.2	Estatística descritiva
3.4.3	Análise de correlação
3.4.4	Análise de dados faltantes
3.5	Transformação dos dados
3.5.1	Padronização dos dados
3.5.2	Eliminação de dados <i>outliers</i>
3.5.3	Normalização dos dados
3.5.4	Transformação de variáveis categóricas para numéricos
3.5.5	Balanceamento da base de dados

3.5.6	Base de dados de treinamento e testes	42
3.6	Redes Neurais Artificiais	43
3.7	Rede Neural Artificial do tipo MLP	44
3.7.1	Desenvolvimento da RNA do tipo MLP	45
3.8	Avaliação da MLP	47
4	RESULTADOS	51
5	CONSIDERAÇÕES FINAIS	60
5.1	Sugestão de trabalhos futuros	63
5.1.1	Influência da espessura e níquel no retrabalho	63
5.1.2	Previsão da força da desempenadeira a quente e dos valores de aberturas de	
	entrada e saída	64
	<b>REFERÊNCIAS</b>	67

# 1 Introdução

A Laminação de Chapas Grossas da Usiminas recebe placas das aciarias e de fornecedores externos. As placas são laminadas e transformadas em chapas através de processos termomecânicos no *Finishing Mill* (FM) com controles precisos das dimensões e forma, garantindo a obtenção de propriedades mecânicas especificadas para cada produto laminado. Para isto, são utilizados diversos equipamentos, sendo que os principais são representados na Figura 1: Fornos de Reaquecimento, Descarepador, Laminador Acabador, Desempenadeira a Quente, Resfriamento Acelerado, Leitos de Resfriamento ao ar e Tesouras para aparamento de bordas e subdivisão dos laminados em chapas.





As placas recebidas da aciaria são armazenadas no pátio de placas e após serem sequenciadas tem o seu peso e dimensões coletados de forma automática. Em seguida, as placas passam por um forno de reaquecimento onde são reaquecidas a uma temperatura de aproximadamente 1200°C. Após o desenfornamento, passam por um descarepador para retirar a formação de óxido de ferro das superfícies das placas. Em seguida, a placa é processada pelo FM onde, de acordo com Laugwitz *et al.* (2022), são definidas as dimensões das chapas grossas e, até certo ponto, também as propriedades mecânicas. As propriedades mecânicas também podem ser obtidas utilizando os equipamentos *Continuos On-Line Control* (CLC) ou Forno de Tratamento térmico (FTT). Ao sair do laminador, o material passa por uma desempenadeira a quente de forma a corrigir defeitos de planicidade que possam existir no laminado. Os materiais programados para o processo de resfriamento acelerado passam pelo CLC e seguem para as Linha de Tesouras (LT). Estes processos possuem controles precisos de temperatura, dimensões e forma. Além disso, existem uma série de controles que devem ser efetuados para que as chapas obtenham as dimensões e características mecânicas e metalúrgicas desejadas.

Fonte: Próprio autor.

De acordo com Molleda, Usamentiaga e Garcia (2013), a planicidade dos produtos laminados é um parâmetro fundamental na produção de aço, pois é utilizada pela maioria dos processos subsequentes e podem determinar a aceitação ou rejeição dos materiais produzidos. Portanto, um dos principais problemas de qualidade que podem ocorrer nos materiais laminados são os defeitos de planicidade. Para a avaliação dos defeitos de planicidade é possível dividir o produto laminado em fibras longitudinais adjacentes, conforme mostrado na Figura 2.

Figura 2 – Planicidade do Material.



Fonte: (MOLLEDA; USAMENTIAGA; GARCIA, 2013).

- (a) Laminado com todas as fibras de mesmo comprimento;
- (b) Laminado com diferentes comprimentos de fibra;
- (c) Laminado apresentando defeitos de planicidade, devido ao alongamento de diferentes fibras.

Quando todas as fibras do laminado têm o mesmo comprimento após a laminação, o produto é considerado plano, conforme mostrado na Figura 2a. Se cada fibra longitudinal do produto for alongada independentemente no processo de laminação, o produto resultante é como mostrado na Figura 2b. No entanto, no processo real de laminação, o alongamento pode ocorrer em diferentes seções das fibras adjacentes provocando ondas, como mostrado na Figura 2c e, portanto, defeitos de planicidade.

Existem três principais defeitos de planicidade em chapas no processo de laminação a quente:

- (a) Ondulação de borda: quando o comprimento das fibras nas bordas do laminado é maior do que o comprimento das fibras no centro - Figura 3a.
- (b) Ondulação central: quando o comprimento das fibras no centro é maior do que o comprimento das fibras nas bordas - Figura 3b.

(c) Nivelamento ruim: quando o comprimento das fibras aumenta a partir de uma borda do laminado - Figura 3c.



Figura 3 – Defeitos de Planicidade.

Fonte: (MOLLEDA; USAMENTIAGA; GARCIA, 2013).

Em função dos problemas de planicidade que podem ser originados no processo de laminação o material passa pelo processo de desempeno. Esse processo emprega uma desempenadeira a quente que tem como principal objetivo reduzir os efeitos de ondulações de borda e ondulações centrais no laminado, reduzindo as tensões internas e melhorando a qualidade superficial do laminado.

Atualmente, o processo de *setup* da desempenadeira a quente utiliza valores tabelados para abertura dos cilindros de entrada e saída. As aberturas da tabela são escolhidas em função da espessura, largura, qualidade da chapa e temperatura de entrada na *Hot Leveller* (HL). Como as tabelas funcionam por agrupamento destes parâmetros, em muitos casos, são necessários ajustes empíricos nos valores da tabela baseados na experiência dos operadores para que se obtenha melhoria da planicidade.

Sobre a busca de acerto de planicidade na desempenadeira a quente, Edwards *et al.* (1987) afirmam que para obter os melhores resultados, é necessário um modelo matemático do processo para prever as configurações ideais da máquina e evitar a sobrecarga dos elementos da máquina ou do sistema de acionamento. Como a teoria de desempeno a quente não está bem desenvolvida, vários fatores de correção empíricos, cujo valor deve ser determinado com base na experiência, são necessários no modelo.

Yi *et al.* (2020) explicam que a distribuição das tensões residuais após o desempeno é de grande importância. Se os principais parâmetros da desempenadeira, como força de nivelamento e potência de nivelamento, forem definidos incorretamente, a distribuição da tensão residual poderá ser prejudicial e levar a defeitos de planicidade nos processos de produção subsequentes. Portanto, é importante analisar cuidadosamente o mecanismo de desempeno da onda longitudinal e estabelecer um modelo matemático para calcular o efeito da tensão residual na forma final da chapa.

Portanto, é necessário explorar um modelo eficaz para minimizar com sucesso os defeitos de planicidade, porém, apesar do MEF ter boa consistência com o resultado experimental é difícil usar esse modelo na prática devido ao seu tempo (LIU; WANG; YAN, 2012).

Meng *et al.* (2022) esclarecem que as desempenadeiras de dobra múltipla enfrentam mais desafios na previsão precisa do retorno elástico para metais difíceis de moldar, aços de alta resistência. Isso é atribuído à herança da tensão (o efeito da tensão residual na flexão subsequente), ao efeito Bauschinger, que têm um efeito mais significativo no retorno elástico de metais difíceis de moldar.

David (2023) explica que o efeito Bauschinger é definido pela redução do limite de escoamento de um metal após uma pré-deformação na direção oposta à conformação. Na siderurgia, o efeito Bauschinger é considerado nocivo para maioria dos aços, uma vez que, as mudanças de resistência mecânica e plasticidade ocorrem sem controle de suas grandezas. Santos (2017), por sua vez, ressalta que o efeito Bauschinger tem importantes consequências na conformação de metais, como no dobramento de placas de aço, e resulta em redução de resistência quando metais severamente trabalhados a frio são submetidos a cargas de sinal contrário. Cita como exemplo o desempenho de barras estiradas ou folhas laminadas pela passagem através de rolos que aplicam tensões de dobramento alternadas.

Todos estes autores relatam as dificuldades de prever o resultado da planicidade após o desempeno e consequentemente a necessidade de retrabalho utilizando os modelos tradicionais. Por este motivo este trabalho foi desenvolvido utilizando a técnica MLP, tomando por base a explicação de Larkiola *et al.* (1998) de que uma RNA é adequada para o trabalho de desenvolvimento de processos quando as dependências multidimensionais e sua influência na qualidade são estudadas e o conhecimento detalhado da natureza das dependências das variáveis não é necessário.

Bagheripoor e Bisadi (2013) utilizaram a técnica de RNA no processo de laminação a quente, para a previsão do modelo para força de laminação e torque de laminação, em função de vários parâmetros do processo. E o modelo de RNA proposto para previsão de força e torque de laminação, obteve coeficientes de correlação de 0,99 para ambas variáveis, tanto nos conjuntos de dados de treinamento, quanto para os conjuntos de dados de teste e o erro percentual absoluto médio da previsão da força e torque de laminação foi de cerca de 5.0%.

O processo de desempeno é imediatamente subsequente ao processo de laminação, além disto, muitas variáveis utilizadas como entrada para no modelo de Bagheripoor e Bisadi (2013), também estavam disponíveis para a utilização no modelo proposto para este trabalho. Esta aproximação entre os processos na área de laminação a quente e os resultados obtidos motivaram ainda mais na aplicação de RNA neste trabalho.

Este trabalho apresenta a possibilidade de uso de RNAs para prever o retrabalho na desempenadeira a frio. Desta forma, pode-se buscar uniformidade e diminuir a variabilidade na forma de operação da desempenadeira a quente.

Ademais, este trabalho também permite o aprofundamento do conhecimento dos parâmetros de controle da desempenadeira a quente e posterior utilização do mesmo para o desenvolvimento de um simulador *off-line* ou até mesmo para o *on-line* das aberturas da desempenadeira a quente.

# 1.1 Objetivo geral

Aplicar a técnica de MLP para prever o retrabalho na desempenadeira a frio, utilizando dados históricos armazenados nos bancos de dados dos sistemas de automação.

### 1.1.1 Objetivos específicos

- Disponibilizar a ferramenta desenvolvida para permitir a avaliação e ajuste nas tabelas de *setup* da desempenadeira a quente;
- Utilizar a previsão de retrabalho para reduzir o desvio de material para o processo da desempenadeira a frio;
- Melhorar o desempenho da desempenadeira a quente visando melhorar o acerto de planicidade do material;
- Utilizar técnicas estatísticas para determinar as correlações entre as variáveis e a influência no resultado de previsão de retrabalho.

## 1.2 Organização do trabalho

No Capítulo 1 é apresentada a área e processos da laminação de chapas grossas da USIMINAS, realizando a contextualização do problema a ser resolvido e os objetivos do trabalho. No Capítulo 2 é apresentado o processo siderúrgico da Usiminas desde a chegada da matériaprima até a laminação de chapas grossas. Além disso, os principais equipamentos e suas funções são introduzidos. O Capítulo 3 estabelece os métodos propostos, principais ferramentas e a descrição dos bancos de dados a serem utilizados. O Capítulo 4 descreve os resultados alcançados. Por fim, o Capítulo 5 apresenta as conclusões finais, apresentando as principais contribuições e as perspectivas de trabalhos futuros.

# 2 Processo Siderúrgico

## 2.1 Produção do aço

O aço é uma liga ferro-carbono com teor de carbono entre 0,1% e 2,2% aproximadamente. Além destes elementos, outros podem ser adicionados durante a sua fabricação para alterar características de resistência, dureza, tenacidade e ductilidade. A Usiminas é considerada uma usina integrada por possuir os processos de redução, refino e laminação de produtos planos.

## 2.2 Redução

O Processo de redução possui cinco principais áreas: coqueria, pátio de carvão e minério de ferro, carboquímico, sinterização e alto-forno. Na área de redução as matérias-primas minério de ferro e carvão são utilizadas na sinterização e coqueria para produzir respectivamente o sínter e o coque para alimentação dos altos-fornos. A sinterização, apresentada na Figura 4, é um equipamento que utiliza uma mistura composta de minério de ferro e fundentes como o calcário, que diminui o ponto de fusão e forma escória retirando camadas de oxidação. Além disto, nesta mistura podem ser adicionadas outras matérias-primas como antracito. Como resultado, temos o sínter que é a carga metálica que vai alimentar os altos-fornos (RIZZO, 2005).



Figura 4 – Processo de Sinterização.

Fonte: Adaptado de (RIZZO, 2005).

A coqueria apresentada na Figura 5 é o equipamento responsável por produzir o coque através da destilação do carvão mineral a uma temperatura de aproximadamente 1200°C. O resultado é um composto poroso e resistente que possui entre 85 e 90% de carbono. O coque tem as funções de fornecimento de carbono e energia térmica no processo de combustão para a produção de ferro gusa. O processo de coqueria gera o *Coke Oven gas* (COG) que é um subproduto da destilação do carvão mineral. A planta de Carboquímicos promove a limpeza do gás removendo a amônia, benzeno, dentre outros (RIZZO, 2005).



Figura 5 – Processo de Coqueria.

Fonte: Adaptado de (RIZZO, 2005).

O alto forno apresentado na Figura 6 é o equipamento responsável pela produção do ferro gusa em estado líquido. Para isto, utiliza o sínter (carga metálica), o coque (combustível sólido) e fundentes carregados pelo topo do alto forno. Na parte inferior do alto forno, através das ventaneiras são insuflados ar quente enriquecido de algum combustível (oxigênio, carvão pulverizado, gás natural). Durante a produção do ferro gusa a temperatura em frente as ventaneiras pode ultrapassar 2000°C enquanto no topo atinge aproximadamente 150°C. Um subproduto do processo de altos-fornos é a escória vendida principalmente para a indústria de cimento (RIZZO, 2005).





Fonte: Adaptado de (RIZZO, 2005).

# 2.3 Refino

O processo de refino representado pela Figura 7 é caracterizado pela transformação do ferro gusa em aço, reduzindo parte do carbono, gusa e impurezas, principalmente, os elementos silício, enxofre, fósforo. Isto ocorre através dos seguintes processos: recebimento da carga de ferro gusa através de carro torpedo, dessulfuração do gusa, refino primário, refino secundário e lingotamento contínuo (USIMINAS, 2018).



Figura 7 – Fluxograma do processo de refino do aço na aciaria da Usiminas.

Fonte: (USIMINAS, 2018).

### 2.3.1 Dessulfuração do gusa

Este processo apresentado na Figura 8 visa a redução dos teores de enxofre do ferro gusa e consiste na injeção controlada de agentes dessulfurantes que reagem com o enxofre e o converte em escória. O enxofre pode ser removido do gusa ou do aço fundido, principalmente, pela reação com aditivos metálicos (como magnésio ou elementos de terras raras), pela reação com aditivos compostos (como carbeto de cálcio e carbonato de sódio) ou pela reação com escórias. Segundo Wilson e McLean (1980), o enxofre, com poucas exceções, é um elemento indesejável no aço, pois diminui bruscamente a resistência mecânica. Por essa razão, tanto remover o enxofre quanto globularizar os sulfetos remanescentes são necessários para se obter dureza máxima.

Figura 8 – Desulfuração do gusa líquido em carro torpedo (à esquerda) e em panela de gusa (à direita).



Fonte: Adaptado de (MOURÃO et al., 2007).

## 2.3.2 Refino primário

De acordo com Mourão *et al.* (2007), no processo de refino primário o ferro gusa é transformado em aço líquido e é transferido para panelas onde são adicionadas ferros-ligas que adicionam ao aço propriedades mecânicas especificas. O refino primário é caracterizado pela retirada de impurezas que afetam a qualidade do aço, tais como o fósforo, enxofre, nitrogênio, entre outros.

Basicamente existem seis etapas no refino primário:

- 1. o convertedor recebe a carga sólida (sucata);
- 2. o convertedor recebe a carga de ferro gusa líquido;
- 3. injeção de oxigênio a uma temperatura de 1800°C aproximadamente;
- 4. medição de temperatura e retirada de amostras;
- 5. vazamento do aço líquido;
- vazamento de escória formada no processo de oxidação do carbono, silício, manganês, fosforo e outros elementos químicos.

#### 2.3.3 Refino secundário

Segundo Mourão *et al.* (2007), chama-se refino secundário aquele que é realizado fora do equipamento de fabricação do aço bruto (Forno Elétrico a Arco ou Conversor a Oxigênio). O refino secundário são processos utilizados para fazer controle da temperatura, correções e ajustes na composição química do aço. Na USIMINAS-Ipatinga são utilizados os seguintes equipamentos para o refino secundário:

- Forno Panela;
- Ruhrstahl Heraeus (RH) (Desgaseificador a vácuo);
- *Composition Adjustment by Sealed Argon Bubling* (CAS-OB) (Estação de ajuste químico e de temperatura).

RIZZO (2005) descreve que o Forno Panela, apresentado na Figura 9, é um dos principais equipamentos empregados em uma Aciaria para promover o refino secundário. A sua utilização garante o equilíbrio térmico entre o aço e o revestimento refratário da panela, que é um pontochave para a qualidade. Além disto, o forno panela possibilita a redução de sobreaquecimento do aço líquido no forno primário, permitindo aumento da vida do revestimento refratário. Os principais benefícios do forno panela são:

- maior flexibilidade operacional;
- controle de temperatura do aço líquido;
- ajuste de composição química do aço.



Figura 9 – Processo Forno Panela.

Segundo Silva (2010), o processo RH – *Ruhrstahl Heraeus*, apresentado na Figura 10, consiste em uma câmara com dois tubos refratários, um para entrada e outro para saída de aço. Durante o tratamento, esses tubos são imersos no aço contido na panela. Para realizar a circulação do aço, além do vácuo produzido no sistema, injeta-se um gás inerte, geralmente argônio, por um dos tubos. O gás injetado em um desses tubos é responsável pela elevação do aço nesta região. Na parte superior da câmara de vácuo existe uma saída de gás acoplada ao sistema de vácuo. Esse sistema de produção de vácuo é constituído normalmente de ejetores de vapor e/ou bombas de anel de água, além de condensadores de vapor. Uma anti-câmara para adição sob vácuo permite a introdução de ligas para ajuste de composição química.

Principais benefícios do RH:

- controle de temperatura em algumas configurações (aquecimento químico);
- desgaseificação;
- desoxidação;
- dessulfuração;
- descarburação (em condições específicas no processo RH-OB);
- acerto de composição química (pequenas quantidades de adições de ferro-liga);
- controle da microestrutura e/ou macroestrutura das peças solidificadas.



Figura 10 – Processo RH.

De acordo com Mourão *et al.* (2007), o CAS-OB – *Composition Adjustment by Sealed Argon Bubling*, mostrado na Figura 11, é um processo de aquecimento químico mais conhecido e utilizado em todo o mundo. Um sino refratário é imerso sobre o "olho"de aço, aberto pelo borbulhamento de argônio em alta vazão. Este processo permite a criação de uma região de aço exposto, porém protegido da oxidação, por onde ligas, principalmente alumínio, podem ser adicionadas. Sobre o sino refratário existe uma lança para injeção de oxigênio, cuja reação com o alumínio adicionado gera o calor objetivado.

Principais benefícios do CAS-OB:

- controle de temperatura do aço líquido;
- acerto de composição química do aço.



#### Figura 11 – Processo CAS-OB.

Fonte: (RIZZO, 2006).

#### 2.3.4 Lingotamento contínuo do aço

O processo de lingotamento contínuo do aço e suas ligas é o último estágio em aciaria onde se trabalha com metal ainda em estado líquido. Tem como missão solidificar o aço, em uma forma desejável, de tal maneira que possa ser utilizado nas etapas seguintes da cadeia produtiva (MOURÃO *et al.*, 2007).

No lingotamento contínuo, apresentado na Figura 12, o aço líquido é vazado em um distribuidor que alimenta um molde vertical de cobre que é refrigerado por água que tem a função de solidificar o aço líquido em contato com o molde, formando uma pele solidificada. Um conjunto de rolos é responsável pela extração do veio de aço que é formado. Esse veio segue pelo interior da máquina de lingotamento contínuo até a máquina de corte, onde é cortado em placas de dimensões predeterminadas. Estas placas são transportadas para a área de laminação a quente (RIZZO, 2005).



#### Figura 12 – Processo de Lingotamento.

# 2.4 Linha de produção de laminação de chapas grossas

A linha de produção da Laminação de Chapas Grossas (LCG) da Usiminas recebe placas provenientes da aciaria ou terceiros e as armazena em pátios para posteriormente serem agrupadas de forma a obter melhor produtividade, qualidade e desempenho dos equipamentos da linha de Chapas Grossas.

O layout das chapas grossas é representado pelas Figuras 13 e 14. O objetivo da laminação de chapas grossas da Usimina é produzir chapas de aço com espessura acima de 6mm com largura entre 900mm e 3900mm. As chapas grossas são utilizadas em diversas aplicações, por exemplo:

- industria Naval;
- plataformas off-shore;
- tubulações;
- construção civil, entre outros.



Figura 13 – Layout da Linha de Chapas Grossas - Laminação a Quente (Parte A).

Fonte: (USIMINAS, 2017).

Figura 14 – Layout da Linha de Chapas Grossas - Laminação a Quente (Parte B).

Area do Off Line



Fonte: (USIMINAS, 2017).

Os principais equipamentos que compõe a Laminação de Chapas Grossas são:

- pátio de placas,
- fornos de reaquecimento,
- descarepador Hot Scale Breaker (HSB),
- laminador acabador,
- desempenadeira a quente,
- resfriamento acelerado (CLC),
- leito de resfriamento,
- tesoura de pontas (*Crop Shear* (CS)),
- tesoura de corte lateral (Double Side Shear (DSS)),
- tesoura divisória (Diveded Shear (DS)).

## 2.4.1 Pátio de placas

As Placas recebidas da Aciaria ou de terceiros são armazenadas no pátio, como mostra a Figura 15, e após sequenciadas passam pelo processo de pesagem e medição de largura, comprimento e espessura. Esse processo de coleta de dados reais da placa de aço são fundamentais para permitir a rastreabilidade do material e a exatidão dos cálculos dos modelos matemáticos dos sistemas de automação que controlam todos os equipamentos e processos da área de chapas grossas da Usiminas.



Figura 15 – Pátio de Placas da Usiminas.

Fonte: (USIMINAS, 2017).

## 2.4.2 Forno de reaquecimento

Os materiais são sequenciados e enfornados em fornos de reaquecimento tipo *walking beam* que tem a função de elevar a temperatura das placas de forma uniforme ao longo de suas dimensões utilizando uma estratégia de aquecimento controlada pelo modelo matemático e sistema de automação dos fornos de chapas grossas, como mostram as Figuras 16 e 17. Para cada placa é definida uma curva de aquecimento para que a placa obtenha as propriedades metalúrgicas e a temperatura adequada para a laminação.



Figura 16 – Enformamento de Placas.

Fonte: (USIMINAS, 2017).



## Figura 17 – Desenfornamento de placa.

Fonte: (USIMINAS, 2017).

## 2.4.3 Descarepador - HSB

Tem a função de retirar a camada de óxido de ferro formado na superfície da placa durante o processo de aquecimento nos fornos de reaquecimento. Para isto, é utilizado jatos de água em alta pressão disparados por vários *headers* que disparam nas superfícies superior, inferior e laterais das placas, como mostram as Figuras 18 e 19.



Figura 18 – Descarepador.

(USIMINAS, 2017).

#### Figura 19 – Jatos de descarepação.



Fonte: (RIZZO, 2011).

# 2.5 Laminação a quente

A laminação a quente se caracteriza pelo aquecimento de placas de aço em fornos de reaquecimento com o objetivo principal de tornar o material mais maleável para permitir a redução de suas dimensões através do laminador. Este equipamento possui alguns tipos de configurações, como mostra a Figura 20, mas basicamente consiste em passar a placa de aço aquecida a alta temperatura entre dois cilindros com uma abertura inferior à espessura da placa para que ela obtenha a nova espessura conforme mostra a Figura 21. Este processo deve obedecer às limitações de projeto do equipamento, tais como:

- força máxima;
- torque máximo;
- velocidade máxima;
- diâmetro dos cilindros de trabalho.



Figura 20 – Tipos de Laminadores.

Fonte: Próprio autor.

Figura 21 – Representação de Laminação de uma placa de aço.



Fonte: Próprio autor.
# 2.6 Laminador de chapas grossas

A Figura 22 apresenta o Laminador de Chapas Grossas da Usiminas que é do tipo 4HI Reversível e é composto por diversos componentes como mostrado na Figura 23. O FM tem a função de transformar placas de aço em chapas grossas de aço alcançando dimensões precisas (espessura, largura e comprimentos) e propriedades mecânicas especificadas pelo cliente.



Figura 22 – Laminador de Chapas Grossas 4HI Reversível.

Fonte: (USIMINAS, 2017).



Figura 23 – Representação esquemática de um laminador quádruo.

Fonte: (RIZZO, 2007).

A Figura 24 mostra as placas no processo de reaquecimento dentro dos fornos de reaquecimento, após atingir o tempo de permanência e a temperatura visada para desenfornamento a placa segue até o laminador, sofre as reduções de espessura e o alargamento e depois segue para a desempenadeira a quente para corrigir os defeitos de planicidade.



Figura 24 – Representação dos passes de laminação na chapa de aço.

Fonte: Próprio autor.

O Laminador de Chapas Grossas da Usiminas possui um Sistema de Automação que controla completamente o processo de laminação. Uma escala de passes é definida pelo modelo matemático considerando as características da placa de aço (espessura, largura, comprimento, composição química, temperaturas), especificações para a chapa e especificações do laminador.

A Figura 25 mostra os passes de laminação. Cada passe consiste da passagem do material entre o gap entre os cilindros de trabalho. Após cada passe, o gap entre os cilindros de trabalho diminui, provocando a redução da espessura da chapa de aço. Além disto, para algumas qualidades de aço, os momentos que o material sofre os passes pode ser determinado para serem realizados em uma faixa de temperatura para atingir propriedades mecânicas específicas.



Figura 25 – Representação da escala de passes de laminação.

A Figura 26 representa a abertura entre os cilindros de trabalho GAPs para que a placa possa sofrer uma série de reduções até atingir a espessura visada.



Figura 26 - Representação da abertura entre os cilindros de trabalho - GAP.

Fonte: Próprio autor.

## 2.7 Desempenadeira a quente

A desempenadeira a quente da laminação de chapas grossas mostrada na Figura 27, possui cinco rolos de trabalho superiores e seis rolos trabalho inferiores, todos refrigerados internamente e externamente por água. Estes rolos de trabalho são apoiados pela mesma quantidade de rolos de apoio na parte superior e inferior do equipamento. Uma característica das desempenadeiras é que os rolos superiores e inferiores são dispostos alternadamente. A Abertura entre os cilindros de trabalho (GAP) é ajustada através do posicionamento dos rolos superiores e permite determinar um gap de entrada diferente do gap de saída. A velocidade da desempenadeira pode variar de 0 a 150 metros por minuto. A carga máxima da desempenadeira é de 2400 toneladas e o equipamento possui célula de carga para medição da força de desempeno. A faixa de temperatura de trabalho é entre 650°C e 900°C. A desempenadeira pode processar chapas com as seguintes dimensões:

- Espessura: 4,5 a 70mm
- Largura: 900 a 4100mm
- Comprimento: 2000mm a 53000 milímetros





Fonte: (USIMINAS, 2017).

A desempenadeira a quente é utilizada para corrigir os defeitos de planicidade originados durante a laminação. Os principais defeitos de planicidade, em sua maioria, surgem durante o processo de laminação devido às condições do perfil do laminado e da diferença de gap ao longo da largura durante a laminação. Isto provoca uma redução de espessura não homogênea ao longo da largura e consequentemente defeitos de ondulação central ou de borda. As Figuras 28 e 29 apresentam os defeitos de ondulação de borda. Existem também os defeitos de planicidade que aparecem devido a condições térmicas nos processos de resfriamento subsequentes (LAUGWITZ *et al.*, 2022).



Figura 28 – Representação de defeito de ondulação de borda.

Fonte: (LAUGWITZ et al., 2022).



Figura 29 – Representação de defeito de ondulação central.

Fonte: (LAUGWITZ et al., 2022).

De acordo com Rizzo (2011), as desempenadeiras eliminam as deformações através da aplicação de esforços de dobramentos decrescentes na chapa em sentidos alternados de forma a neutralizar tensões residuais que estão provocando distorções ao longo do comprimento.

Baru *et al.* (2022) explicam que a planicidade é obtida ao submeter as fibras longitudinais da chapa a deformações de compressão de tensão cíclica sob carga de flexão alternada imposta pelos rolos, conforme mostrado na Figura 30b.



#### Figura 30 – Princípio do Desempeno a Quente.

(a) Princípio do desempeno da HL.

(b) Carga cíclica de tensão-compressão experimentada pela chapa no processo de desempeno.

Fonte: (BARU et al., 2022).

Laugwitz et al. (2017) relatam que as forças aplicadas geram deformações plásticas e elásticas de tração e compressão ao longo da seção transversal da chapa que são progressivamente anuladas à medida que a chapa passa pelo conjunto de rolos da desempenadeira, conforme mostra a Figura 31. Isto acontece porque a força exercida na chapa pelos rolos é reduzida progressivamente dos rolos de entrada para os rolos da saída da desempenadeira. Desta forma, ocorre deformação plástica e alongamento das fibras da chapa nos primeiros rolos e nos últimos rolos ocorre a diminuição de força e alívio das tensões, conforme mostra a Figura 32.





Fonte: (LAUGWITZ et al., 2017).



Figura 32 – Chapa submetida a flexão elástico-plástica alternada entre os rolos.

De acordo com Laugwitz *et al.* (2022), existe grande dificuldade em modelar a evolução da planicidade ao longo da sequência de processamento que consiste em resfriamento acelerado após laminação a quente, nivelamento a quente e resfriamento final do ar. Pequenos desvios na condição da superfície da chapa grossa ou no controle do processo, inevitavelmente levarão a condições não homogêneas do material. Isso, por sua vez, normalmente causa gradientes de temperatura que induzem tensões térmicas que, se excederem um valor crítico, podem resultar em defeitos de planicidade após o resfriamento acelerado da chapa. Além disto, Molleda, Usamentiaga e Garcia (2013) destacam alguns dos motivos que podem causar os defeitos de planicidade:

- coroamento negativo ou positivo de cilindros inadequados;
- aquecimento ou refrigeração não uniforme das placas;
- cilindros desnivelados ou desalinhados;
- distribuição de carga de laminação inadequadas nos passes finais.

Devido a esta dificuldade e a necessidade de tentar evitar ou mitigar o retrabalho de desempeno foi desenvolvido este trabalho que busca prever o surgimento destes defeitos de planicidade após o desempeno utilizando os dados históricos de setup e resultados coletados durante os processos de laminação, desempeno a quente e desempeno a frio. Estes dados após os devidos tratamentos foram utilizados para treinamento e validação de uma rede MLP. Com os resultados espera-se antecipar ações e ajustes para mitigar ou evitar o surgimento dos defeitos de planicidade após o processo de desempeno a quente.

# 3 Metodologia

# 3.1 Metodologia de mineração dos dados

A metodologia *Knowledge Discovery in Databases* (KDD) foi utilizada neste trabalho para definir os processos de ajuste do conjunto de dados, com o objetivo de extrair conhecimento útil a partir de grandes quantidades de dados. O processo KDD é uma abordagem não trivial para identificar padrões válidos, novos, potencialmente úteis e compreensíveis (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996). Como afirmado por Goebel e Gruenwald (1999) em seu estudo sobre a importância das ferramentas de análise de dados, a crescente utilização de bancos de dados com enormes quantidades de informações torna a tarefa de utilizá-los para a tomada de decisão cada vez mais desafiadora. A extração automatizada de conhecimento útil desses dados complexos por meio de ferramentas de descoberta e análise de dados é, portanto, fundamental para a obtenção de informações relevantes e decisões embasadas em dados sólidos.

## 3.2 KDD

O KDD consiste em cinco fases, conforme apresenta a Figura 33.





Fonte: Adaptado de (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

 Seleção: caracterizado pela amostragem dos dados, é o processo que define quais serão os dados selecionados baseados nos objetivos do projeto. Atualmente, as principais fontes de dados são os bancos de dados relacionais. Para esta fase é necessário um profundo conhecimento das regras de negócio, especificações, restrições para formular adequadamente o escopo do problema e objetivos que irão nortear a aquisição de dados para utilização no projeto.

- Pré-processamento: Nesta etapa, os dados são extraídos, organizados e realizado o tratamento das inconsistências onde são tomadas ações para limpar, corrigir ou remover dados inconsistentes, verificar dados ausentes ou incompletos e identificar anomalias (*outliers*).
- Transformação: Nesta etapa são aplicadas aos dados técnicas de transformação, por exemplo: padronização, normalização, agregação, criação de novos atributos, redução e sintetização dos dados. Aqui os dados ficam disponíveis agrupados em um mesmo local para a aplicação dos modelos de análise.
- Mineração de dados: Nesta etapa são construídos os modelos para extração do conhecimento (redes neurais, árvores de decisão, entre outras). Essas técnicas têm por objetivo (1) verificar uma hipótese e (2) descobrir novos padrões de forma autônoma.
- Interpretação/Avaliação: Finalmente, nesta etapa, ocorre a interpretação dos resultados obtidos pelo modelo. Ferramentas estatísticas e um especialista do processo são fundamentais para validar os resultados e determinar a sua aplicabilidade como conhecimento.

As próximas seções apresentam as técnicas utilizadas em cada etapa do processo KDD no contexto deste trabalho.

## 3.3 Seleção dos dados

A fim de se investigar os problemas de planicidade e o retrabalho na desempenadeira a frio utilizando a técnica de RNA do tipo MLP, foram realizadas reuniões com os especialistas das áreas de operação, automação e gerência técnica para identificar quais os dados de processo poderiam influenciar no desempenho da desempenadeira a quente quanto ao acerto de planicidade.

Como fonte dos dados foram utilizados os dados do processo de laminação a quente armazenados em banco de dados dos sistemas de automação dos fornos, tracking, *Hot Leveller* - *Continuos On-Line Control* (HL-CLC), laminador de chapas grossas e Linha de Tesouras 1 - Chapas Grossas (LT1CG). Para se obter melhores resultados, foram pesquisados em um banco de dados o histórico dos materiais processados e classificados os acertos da planicidade, considerando as observações de qualidade superficial identificadas na inspeção final, dimensões, temperatura do material e desvio para a desempenadeira a frio.

Um outro critério importante para a seleção dos dados é o ritmo de produção. Portanto, uma das restrições utilizadas foi o tempo de desempeno, então o conjunto de dados selecionados se referem aos *setups* utilizados onde somente um passe foi necessário para atingir os resultados esperados.

30

Analisando os dados disponíveis, foram selecionadas 58 variáveis de processo para serem extraídas dos bancos de dados. As 58 variáveis estão descritas no dicionário de dados conforme a Tabela 1. Foi definido que a pesquisa de seis meses de produção (entre 01/07/2021 e 31/07/2021) resultaria em uma quantidade de dados suficientes. Estes dados foram salvos em planilhas para utilização nos modelos de previsão.

Item	Código da variável	Descrição	Domínio	Unidade	Tipo de Variável
1	SLAB_ID	Identificação do material		CHAR(10)	Qualitat. Nominal
2	Thick	Espessura da Placa	6 - 70	mm	Quantit. Contínua
3	Width	Largura da Placa	900 - 4000	mm	Quantit. Contínua
4	Weigth	Peso da Placa	2 - 16	t	Quantit. Contínua
5	DT_ENT_CLC	Data de Entrada do material no CLC	-	Data/Hora	Quantit. Contínua
6	DT_LAM	Data de laminação	-	Data/Hora	Quantit. Contínua
7	Qualidade	Código de qualidade da chapa	-	CHAR(12)	Qualitat. ordinal
8	COD_TEMP	Código de temperatura da chapa	-	CHAR(8)	Qualitat. ordinal
9	TEMPO_PERM_FORNO	Tempo permanência da placa no Forno	150 - 1400	minutos	Quantit. Contínua
10	TEMPE_FORNO	Temperatura de desenfornamento	1050 - 1250	°C	Quantit. Contínua
11	ALA	Ala do forno	A - D	CHAR	Qualitat. Nominal
12	TEMPO_ESP_UP	Tempo de espera entre Forno e FM	5 - 95	segundos	Quantit. Contínua
13	TOTAL_PASS	Total de passes no Laminador	11 - 45	-	Quantit. discreta
14	TEMP_ACABA	Temperatura de acabamento no FM	600 - 1084	°C	Quantit. Contínua
15 I	FORCA_PREV_FM_U_PASS	Força prevista no último passe	300 - 6000	t	Quantit. Contínua
16	FOR_OBT_FM_U_PASS	Força obtida no último passe	300 - 6000	t	Quantit. Contínua
17	DIF_FORCA	Força real - força prevista último passe FM	-1500 a 1500	t	Quantit. Contínua
18	TON_CIL	Tonelagem do cilindro de trabalho	0 - 5000	t	Quantit. Contínua
19	TEMP_ENTRADA	Temperatura do material na entrada da HL	500 - 1100	°C	Quantit. Contínua
20	BORDA	Tipo de borda	NAP, AP	CHAR	Qualitat. Nominal
21	GRADE	Grau do Aço	CHAR(3)	CHAR	Qualitat. ordinal
22	PRC_CODE	Código do Processo	0 - 6	CHAR	Qualitat. ordinal
23	SGC	Steel Grade Code	0 - 500	CHAR	Qualitat. ordinal
24	SGF	Steel Grade Familly	1 - 25	CHAR	Qualitat. ordinal
25	GRT	Grupo de espessura	1 - 25	CHAR	Qualitat. ordinal
26	GRW	Grupo de largura	1 - 10	CHAR	Qualitat. ordinal
27	MATERIAL_CODE	Código do Material	1 - 25	CHAR	Qualitat. ordinal
28	TCR_CODE	Código de TCR	0 - 4	CHAR	Qualitat. ordinal
29	ALUMINUM	Teor de Alumínio	0 - 99999	0,01%	Quantit. Contínua
30	ARSENIC	Teor de Arsenico	0 - 9999	0,01%	Quantit. Contínua
31	BORON	Teor de Boro	0 - 2500	0,01%	Quantit. Contínua
32	BISMUTH	Teor de bismútio	0 - 9999	0,01%	Quantit. Continua
33	CARBON	Teor de Carbono	30000 - 600000	0,01%	Quantit. Continua
34	CALCIUM	Teor de Calcio	0 - 4500	0,01%	Quantit. Continua
35	CUBALI	Teor de Cobalto	0 - 8500	0,01%	Quantit. Continua
30 27	COPPER	Teor de Cromo	0 - 999999	0,01%	Quantit. Continua
20	LANDROCEN	Teor de Hidrogânie	0 - 400000	0,01%	Quantit. Continua
30 20	MANGANESE	Teor de Magnácia	0 - 9999	0,01%	Quantit. Continua
39 40	MOLVEDENIUM	Teor de Melibidêrie	0 - 1999999	0,01%	Quantit. Continua
40	NITROGEN	Teor de Nitrogânio	0 - 12000	0,01%	Quantit. Continua
41	NIORIUM	Teor de Niúbio	0 - 12000	0,01%	Quantit. Contínua
42	NICKEI	Teor de Níckel	0 - 05000	0,01%	Quantit. Contínua
43 44	OYYGEN	Teor de Ovugânio	0 7000	0,01%	Quantit. Contínua
45	PHOSPHORUS	Teor de Eósforo	0 - 80000	0,01%	Quantit. Contínua
46	IFAD	Teor de Chumbo	0 - 16000	0,01%	Quantit. Contínua
47	SULFUR	Teor de Enxofre	0 - 20000	0.01%	Quantit Contínua
48	ANTIMONY	Teor de Antimônio	0 - 55000	0.01%	Quantit. Contínua
49	SILICON	Teor de Silício	0 - 1999999	0.01%	Quantit. Contínua
50	TIN	Teor de Estanho	0 - 12000	0.01%	Quantit. Contínua
51	TITANIUM	Teor de Titânio	0 - 130000	0.01%	Quantit. Contínua
52	VANADIUM	Teor de Vanádio	0 - 80000	0.01%	Quantit. Contínua
53	ZIRCONIUM	Teor de Zircônio	0 - 7000	0,01%	Quantit. Contínua
54	GAP ENT HL x 0,1	Abertura dos rolos de entrada da HL	-14 a 709	0,1 mm	Quantit. Contínua
55	GAP SAI HL x 0.1	Abertura dos rolos de saída da HL	0 - 729	0,1 mm	Quantit. Contínua
56	FORCA_DESEMP	Força da HL	0 - 860	t	Quantit. Contínua
57	RETRABALHO	Retrabalho na CL	0 - 8	-	Qualitat. Nominal
58	DIFF Esp - Gap Ent HL	Diferença espessura/gap de entrada HL	-0,9 a 36,4	mm	Ouantit. Contínua
	rr	3 1 61			C

Tabela 1 – Dicionário de dados.

## 3.4 Pré-processamento dos dados

Os dados reais do processo são coletados por meio dos *Distributed Control System* (DCS) e dos equipamentos de nível 1 através dos *Programmable Logic Controller* (PLC). Estes dados foram tratados pelos sistemas de nível 2, que processam estes dados e armazenam em bancos de dados para serem utilizados, juntamente com os dados de *Process Data Input* (PDI) provenientes do nível 3 e pelos modelos matemáticos instalados no sistema de automação. O Fluxo de dados e os bancos de dados onde os dados foram armazenados podem ser vistos na Figura 34.



Figura 34 – Sistemas de Automação e armazenamento de dados.

Fonte: Próprio autor.

O processo de coleta de dados automatizado através dos sistemas de automação possui a característica de produzir dados confiáveis e consistentes devido, principalmente, ao software de aquisição de dados que faz uma verificação da validade dos dados lidos. Para extrair os dados dos bancos de dados dos sistemas de automação, foram desenvolvidas consultas para buscas nas tabelas dos bancos de dados relacionais Oracle, e o resultado da consulta produziu uma base de dados com 35897 registros, cada registro com 58 variáveis de processo. Do conjunto original de dados, foi gerado um sub-conjunto retirando três variáveis catergoricas (SLAB\_ID, DT\_LAM, DT\_ENT\_CLC) que não mais seriam necessárias para a utilização nos treinamentos das RNAs, embora tenham importância para a rastreabilidade das informações coletadas. Permanecendo um subconjunto de 41 variáveis numéricas (Thick, Width, Weigth, TEMPO\_PERM\_FORNO, TEMPE\_FORNO, TEMPO\_ESP\_UP, TOTAL\_PASS, TEMP\_ACABA, FORCA\_PREV\_FM\_U\_PASS, FOR\_OBT\_FM\_U\_PASS, DIF\_FORCA, TON\_CIL, TEMP\_ENTRADA, ALUMINUM, ARSENIC, BORON, BISMUTH, CARBON, CALCIUM, COBALT, CHROMIUM, COPPER, HYDROGEN, MANGANESE, MOLYBDENUM, NITROGEN, NIOBIUM, NICKEL, OXYGEN, PHOSPHORUS, LEAD, SULFUR, ANTIMONY, SILICON, TIN, TITANIUM, VANADIUM, ZIRCONIUM, GAP ENT HL x 0,1, GAPnSAI HLx 0,1, FORCA\_DESEMP)

#### 3.4.1 Distribuição dos dados

A Figura 35 apresenta a distribuição dos dados com relação aos níveis de retrabalho, onde o "nível 0" está relacionado aos produtos sem retrabalho (34749 dados) e o "nível 1" à ocorrência de retrabalho (1148 dados). Observa-se que a distribuição está extremamente desbalanceada, com 96,8% dos dados pertencendo à classe sem retrabalho e 3,2% dos dados pertencendo à classe com retrabalho. Esse fator pode atrapalhar extensivamente na previsão de retrabalho, uma vez que o sistema treinado tenderá à classe com maior presença, nesse caso, sem retrabalho. Para solucionar este problema, técnicas de balanceamento de classes foram necessárias. A seção 3.5.5 apresenta as técnicas utilizadas.



Figura 35 – Distribuição dos dados com relação aos níveis de retrabalho.

#### 3.4.2 Estatística descritiva

A Tabela 2 apresenta a estatística descritiva da base de dados, constituída pelos valores de contagem, média, desvio padrão, e dos valores interquartílicos, respectivamente. Os dados apresentam consistência com os valores considerados usuais aos processos de laminação de chapas grossas, onde os dados foram extraídos.

Ν	Dados	Média	Desv. pad.	Coef. Var.	Moda	Mediana	1º Quartil	2º Quartil	3° Quartil	Máximo	Mínimo
1	Thick	19,8	12,9	0,7	8,0	16,0	9,5	16,0	25,0	70,0	6,0
2	Width	2371,8	301,3	0,1	2440,0	2440,0	2300,0	2440,0	2500,0	3900,0	900,0
3	Weigth	9,4	2,6	0,3	10,0	9,6	7,6	9,6	11,7	15,1	2,1
4	TEMPO_PERM_FORNO	298,7	106,2	0,4	217,0	280,0	228,0	280,0	343,0	1223,0	152,0
5	TEMPE_FORNO	1130,5	63,0	0,1	1060,0	1150,0	1060,0	1150,0	1200,0	1240,0	1050,0
6	TEMPO_ESP_UP	6,5	2,2	0,3	6,0	6,0	6,0	6,0	7,0	95,0	5,0
7	TOTAL_PASS	21,7	4,7	0,2	19,0	21,0	19,0	21,0	25,0	43,0	11,0
8	TEMP_ACABA	806,0	75,8	0,1	784,0	789,0	749,0	789,0	854,0	1084,0	630,0
9	FORCA_PREV_FM_U_PASS	2692,2	512,1	0,2	2916,4	2729,8	2379,0	2729,8	2978,6	5056,8	613,9
10	FOR_OBT_FM_U_PASS	2655,2	556,9	0,2	2725,4	2696,9	2299,8	2696,9	2990,9	4953,6	347,4
11	DIF_FORCA	-37,0	190,2	-5,1	27,0	-11,3	-136,7	-11,3	66,2	1485,2	-1273,3
12	TON_CIL	960,5	614,9	0,6	12,5	888,2	453,8	888,2	1397,2	3336,5	5,2
13	TEMP_ENTRADA	760,7	63,0	0,1	730,0	750,0	720,0	750,0	789,0	1011,0	540,0
14	ALUMINUM	31226,0	7191,1	0,2	35000,0	30325,0	26600,0	30325,0	35000,0	99041,0	1100,0
15	ARSENIC	1812,5	935,4	0,5	1000,0	1800,0	1170,0	1800,0	2375,0	8055,0	0,0
16	BORON	284,1	414,9	1,5	200,0	150,0	100,0	150,0	200,0	2315,0	0,0
17	BISMUTH	1918,9	1306,8	0,7	2500,0	2013,0	775,0	2013,0	2500,0	8900,0	0,0
18	CARBON	158473,8	66452,4	0,4	160000,0	149900,0	136200,0	149900,0	164020,0	503800,0	33725,0
19	CALCIUM	1443,5	673,9	0,5	1600,0	1400,0	1025,0	1400,0	1850,0	4100,0	0,0
20	COBALT	1665,7	1104,0	0,7	0,0	1715,0	800,0	1715,0	2483,0	8100,0	0,0
21	CHROMIUM	62481,9	98891,1	1,6	20000,0	22042,0	18525,0	22042,0	32237,5	958250,0	0,0
22	COPPER	9763,0	21042,1	2,2	5300,0	5300,0	3120,0	5300,0	8050,0	353365,0	500,0
23	HYDROGEN	259,0	426,4	1,6	0,0	230,0	111,0	230,0	370,0	9900,0	0,0
24	MANGANESE	1073454,9	329068,4	0,3	1330000,0	1098420,0	707250,0	1098420,0	1348790,0	1999950,0	162675,0
25	MOLYBDENUM	10286,9	43553,1	4,2	1000,0	2010,0	1000,0	2010,0	4715,0	603150,0	0,0
26	NITROGEN	3696,1	1024,6	0,3	2900,0	3565,0	3000,0	3565,0	4210,0	11750,0	1350,0
27	NIOBIUM	11759,3	15315,0	1,3	1000,0	1600,0	867,0	1600,0	17300,0	64300,0	0,0
28	NICKEL	13522,5	30301,1	2,2	10000,0	10048,0	9025,0	10048,0	11800,0	714900,0	0,0
29	OXYGEN	310,8	784,1	2,5	0,0	0,0	0,0	0,0	0,0	6730,0	0,0
30	PHOSPHORUS	19145,1	5670,1	0,3	15000,0	18150,0	15500,0	18150,0	21700,0	79710,0	8000,0
31	LEAD	3550,8	2528,6	0,7	0,0	3300,0	1650,0	3300,0	4800,0	15300,0	0,0
32	SULFUR	5632,7	3528,4	0,6	1000,0	5150,0	2440,0	5150,0	8325,0	18345,0	0,0
33	ANTIMONY	1363,5	1031,9	0,8	950,0	1050,0	900,0	1050,0	1802,0	54200,0	0,0
34	SILICON	264389,1	162061,6	0,6	200000,0	214697,0	188600,0	214697,0	290000,0	1391700,0	2370,0
35	TIN	922,4	457,5	0,5	1000,0	1000,0	733,0	1000,0	1100,0	10300,0	0,0
36	TITANIUM	8680,2	10109,3	1,2	2000,0	1937,0	1025,0	1937,0	16100,0	116800,0	100,0
37	VANADIUM	6257,2	13424,1	2,1	2300,0	2250,0	1400,0	2250,0	3150,0	75900,0	450,0
38	ZIRCONIUM	1113,6	890,5	0,8	600,0	725,0	600,0	725,0	1667,0	6733,0	0,0
39	GAP ENT HL x 0,1	145,9	140,0	1,0	13,0	108,0	29,0	108,0	212,0	709,0	-14,0
40	GAP SAI HL x 0,1	185,7	131,7	0,7	68,0	153,0	78,0	153,0	245,0	729,0	0,0
41	FORCA_DESEMP	182,1	92,2	0,5	0,0	181,7	105,3	181,7	249,7	852,1	0,0
	Fonte: Próprio autor.										

Tabela 2 – Tabela com estatísticas das variáveis.

## 3.4.3 Análise de correlação

A Figura 36 apresenta o mapa de calor (*Heatmap*), que traduz o índice de correlação de *Pearson* para um mapa de cores. Quanto mais próximos à unidade, maiores as relações lineares entre as variáveis.



Figura 36 – Mapa de calor obtido pelas correlações de Pearson.

Fonte: Próprio autor.

Nota-se que existem poucos valores correlacionados, o que sugere baixa intercorrelação entre as variáveis. Nesse sentido, não foi necessária a aplicação de técnicas para eliminação de variáveis linearmente correlacionadas, que podem interferir no processo de aprendizagem. Pode-se observar, também, que as variáveis que compõe as informações de GAP de Saída e Entrada (GAP\_SAI\_HL e GAP\_ENT\_HL), são respectivamente influenciadas pela espessura, uma vez que para maiores valores de espessura, maiores são as aberturas dos rolos de entrada e saída. Ademais, observa-se a relação entre Força da Desempenadeira (FORCA\_DESEMP) e a variável Temperatura de Forno (TEMPE\_FORNO) de forma inversamente proporcional, indicando que quanto maiores os valores de temperatura, menores são os esforços necessários para a laminação.

### 3.4.4 Análise de dados faltantes

Assunção (2012) esclarece que é comum existirem em bases de dados registros com dados não preenchidos (*missings*), sendo necessário adotar algum procedimento para tratamento destas variáveis. Além disto, um dos primeiros tratamentos que a técnica KDD determina para validação do conjunto de dados é a verificação de dados faltantes para determinar a necessidade de tratamento para esta situação. Através do método .isna() da biblioteca Pandas, foram verificados se nos registros armazenados algum dos dados deixou de ser registrados com valores e, conforme a Figura 37, podemos perceber que em nenhum registro haviam dados faltantes.

Figura 37 – Saída de resultado do colab notebook mostrando quantidade de dados faltantes.

SLAB TD	0	ALUMINUM	6
Thick	õ	ARSENIC	e
Width	ă	BORON	6
Weigth	ă	BISMUTH	6
NETROI CLC	0	CARBON	6
DI_ENI_CLC	0	CALCIUM	6
DI_LAM	0	COBALT	6
Qualidade	0	CHROMIUM	6
COD_TEMP	0	COPPER	6
TEMPO_PERM_FORNO	0	HYDROGEN	6
TEMPE_FORNO	0	MANGANESE	e
ALA	0	MOLYBDENUM	6
TEMPO ESP UP	0	NITROGEN	6
TOTAL PASS	0	NIOBIUM	6
TEMP ACABA	6	NICKEL	6
FORCA DREV EM IL DASS	ă	OXYGEN	6
FOR ORT EN IL DASS	å	PHOSPHORUS	6
	å	LEAD	6
DIF_FORCA	0	SULFUR	6
TON_CIL	0	ANTIMONY	6
TEMP_ENTRADA	0	SILICON	6
BORDA	0	TTTANTIN	6
GRADE	0	TITANIUM	6
PRC_CODE	0	VANADIUM	6
SGC	0	ZIRCONIUM	6
SGF	0	GAP_ENT_HL	6
GRT	0	GAP_SAI_HL	6
GBW	0	PORCA_DESEMP	6
MATERIAL CODE	Ä	DIEL EED CAD	0
TCR CODE	ă	DIFF_CSP_GAP	0
TER CODE	0	RETRADALHU Z	6

Fonte: Próprio autor.

## 3.5 Transformação dos dados

### 3.5.1 Padronização dos dados

Os dados foram padronizados seguindo a estrutura Z-score. O Z-score representa a diferença entre um valor e a média do conjunto de dados, dividido pelo desvio padrão. Isso ajuda a destacar valores que são muito diferentes da média e a tornar os dados comparáveis. De acordo com Urbano, Lima e Hanjalic (2019), por meio do z-score os dados são mapeados em uma distribuição cuja média seja 0 e o desvio padrão seja 1, conforme a Equação 3.1.

$$Z = \frac{x - \mu}{\sigma} \tag{3.1}$$

## 3.5.2 Eliminação de dados *outliers*

A base de dados apresentou, por meio da avaliação de estatística descritiva utilizando a ferramenta gráfica *Box Plot*, a presença de pontos destoantes (*outliers*), como pode ser observado de forma gráfica na Figura 38.



Figura 38 – Boxplot relacionando o nível de retrabalho com a distribuição da variável.

Fonte: Próprio autor.

Os dados destoantes foram eliminados através do corte (*trimm*) dos dados que apresentaram distância maior que três vezes o desvio padrão (3  $\sigma$ ) da variável em questão.

#### 3.5.3 Normalização dos dados

A normalização tem a função de alterar os valores das variáveis numéricas de um conjunto de dados para uma escala comum, sem distorcer as diferenças nos intervalos de valores Liu *et al.* (2011). A normalização é principalmente aplicável quando as variáveis tiverem intervalos muito diferentes pois podem distorcer ou tornar tendenciosos os resultados.

Neste trabalho foi utilizado o método Min-Max Normalization da biblioteca sklearn, que realiza uma transformação linear nos dados originais, mapeando as entradas no intervalo de 0 a 1, conforme a Equação 3.2, preservando todas as relações dos valores de dados Ogasawara *et al.* (2010).

$$MinMaxScaler(x) = \frac{x - x_{min}}{x_{max} - x_{min}}$$
(3.2)

onde, x é o valor a ser padronizado em função dos valores máximo e mínimo por atributo, substituindo-os por uma escala de valores entre 0 e 1.

#### 3.5.4 Transformação de variáveis categóricas para numéricos

A transformação de variáveis categóricas em núméricas é realizada devido a limitações de alguns modelos em utilizar variáveis em forma de texto. Também não se pode atribuir um valor numérico para cada categoria, uma vez que esse processo, conhecido como ponderação arbitrária, pode criar uma ordenação e pesos para as categorias que não refletem a realidade. Segundo Hedström e Wang (2021), o método *get dummies* do Pandas é uma forma de pré-processamento não numérico que transforma todas as variáveis não numéricas utilizando *one-hot encoding*.

O *one-hot encoding* é uma técnica comumente utilizada na área de aprendizado de máquina e processamento de linguagem natural para representar categorias ou classes como vetores binários. Nesse método, cada categoria é atribuída a uma posição em um vetor de tamanho igual ao número total de categorias possíveis. A categoria de interesse é marcada com o valor 1 e todas as outras posições recebem o valor 0. Essa representação garante que cada categoria seja independente e não relacionada às outras, o que facilita o processamento por algoritmos de aprendizado de máquina. O *one-hot encoding* é particularmente útil quando as categorias não possuem uma ordem específica e não possuem uma relação numérica entre si.

Portanto, de forma a adequar as categorias das variáveis ao modelo, as 12 variáveis categóricas foram transformadas em 166 variáveis do tipo "*one hot enconding*", utilizando a função get\_dummies() da biblioteca Pandas . Logo após esta conversão, foi criado um conjunto composto das 41 variáveis numéricas iniciais somadas as novas 166 variáveis numéricas. Portanto, o novo conjunto de dados ficou com um total de 207 variáveis.

### 3.5.5 Balanceamento da base de dados

Comumente uma base de dados pode apresentar classes desbalanceadas. Esta distribuição desigual cria um conjunto de classe majoritária e outro conjunto de classe minoritária. No problema de determinação de existência ou não de retrabalho, o conjunto de dados que representa os materiais que não sofrem retrabalho é muito maior que as ocorrências de retrabalho. Este desequilíbrio poderia enviesar o aprendizado do modelo ou até mesmo impossibilitar a rede neural de aprender com o conjunto de dados minoritários (MOURÃO *et al.*, 2007; STOLFO *et al.*, 1997).

Diante disso, foram utilizadas técnicas de balanceamento com os métodos *undersampling* e *oversampling*, com o objetivo de balancear as classes e maximizar a capacidade de generalização da rede neural.

Foram empregadas as técnicas de imputação sintética (*Synthetic Minority Oversampling Technique* (SMOTE)) e a técnica de remoção aleatória (*Near MISS*). A técnica de *oversampling* via SMOTE-Tomek é guiada à repetição da classe com menor percentual, como mostrado na Figura 39a. Por sua vez, a técnica de *undersamping via Near MISS*, é guiada a remover ou buscar de forma aleatória, os dados da classe de maior percentual, como mostrado na Figura 39b, de forma que os dados removidos estejam em menor distância com os dados da outra classe. Cada uma dessas técnicas foi avaliada quanto ao desempenho final do modelo de classificação.



#### Figura 39 – Distribuição após oversampling e undersampling.

Fonte: (MOHAMMED; RAWASHDEH; ABDULLAH, 2020a).

Segundo Satpathy (2020), SMOTE-Tomek é uma técnica híbrida que visa limpar pontos de dados sobrepostos para cada uma das classes distribuídas no espaço amostral. Após o *oversampling* ser feito pelo SMOTE-Tomek, os *clusters* de classes podem estar invadindo o espaço uns dos outros. Como resultado, o modelo do classificador sofrerá *overfitting*. Agora, os *links Tomek* são as amostras emparelhadas de classes opostas que são os vizinhos mais próximos um do outro. Portanto, a maioria das observações de classe desses *links* é removida, pois se acredita que isso aumente a separação de classes perto dos limites de decisão. Agora, para obter melhores *clusters* de classe, os *links Tomek* são aplicados a amostras de classes minoritárias superamostradas feitas pelo SMOTE. Assim, em vez de remover as observações apenas da classe majoritária, geralmente removemos ambas as observações de classe dos links *Tomek*. Como resultado teremos algo similar a Figura 40. (SATPATHY, 2020).





Fonte: (LEMAîTRE; NOGUEIRA; ARIDAS, 2017).

Após a aplicação das técnicas de balanceamento de classes, a base de dados deu origem a três novas bases, como segue:

conjunto de dados desbalanceado, sendo 97% referentes a chapas sem retrabalho e 3% referentes a chapas com retrabalho, Figura 41.

- conjunto de dados balanceado com a técnica de oversampling, Figura 42.
- conjunto de dados balanceado com a técnica de undersampling, Figura 43.



Figura 41 – Balanceamento da Classe Retrabalho após a aplicação das técnicas undersampling.

Fonte: Próprio autor.





Fonte: Próprio autor.



#### Figura 43 – Balanceamento da Classe Retrabalho após a aplicação das técnicas undersampling.

#### 3.5.6 Base de dados de treinamento e testes

As bases de dados foram estratificadas em duas partes independentes e sem sobreposição na proporção 70:30 (treinamento:teste) por meio da função *traintestsplit()* do módulo *scikit-learn*, formando um conjunto de treinamento com 17458 registros e outro conjunto de teste com 7483 registros.

Dados de treinamento são um conjunto de exemplos usados para treinar uma rede neural. Eles são compostos por dados de entrada e saída esperada, onde a entrada é apresentada à rede e a saída esperada é a resposta correta correspondente. O objetivo do treinamento é ajustar os pesos e os parâmetros da rede neural de forma a minimizar a diferença entre as saídas previstas e as saídas esperadas. Os dados de treinamento devem ser representativos e abranger a variabilidade dos possíveis dados de entrada que a rede irá encontrar na prática.

Dados de teste são usados para avaliar o desempenho da rede neural após o treinamento. Eles são usados para medir a capacidade da rede de generalizar o conhecimento adquirido durante o treinamento para dados não vistos anteriormente. Os dados de teste são independentes dos dados de treinamento e devem ser representativos do mundo real. Eles são usados para avaliar métricas de desempenho, como acurácia, precisão, recall, entre outras, e determinar como a rede neural se comporta em novos dados. É importante que os dados de teste não sejam usados durante o treinamento, pois isso pode resultar em uma avaliação enviesada do desempenho da rede.

## 3.6 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são sistemas que tentam emular o funcionamento do cérebro humano. Jha *et al.* (2019) descreve que nas interconexões das redes neurais biológicas, ilustrada na Figura 44, os sinais elétricos atravessam os neurônios com a ajuda de axônios (JHA *et al.*, 2019). As sinapses que estão no final de cada neurônio passam o sinal à frente. Esta propagação dos sinais de entrada entre os neurônios produz como resultado o aprendizado.



Figura 44 – Neurônios e suas conexões.

Fonte: (CASTILHO, acessado em maio de 2023).

O neurônio artificial, apresentado na Figura 45, é descrito por Tafner (1998) como uma estrutura lógico-matemática que tenta simular a forma, o comportamento e as funções de um neurônio biológico. Desta forma, os dendritos foram substituídos por entradas, cujas ligações com o corpo celular artificial são realizadas mediante elementos chamados de peso, simulando as sinapses. Os estímulos captados pelas entradas são processados pela função de soma, e o limiar de disparo do neurônio biológico foi substituído pela função de transferência.

Figura 45 – Neurônio artificial.



Fonte: (TAFNER, 1998).

Conforme enfatizado por Desai e Shah (2021), o cérebro humano é capaz de realizar a autoaprendizagem assim como o sistema de rede neural artificial. Ele executa milhares de iterações sendo capaz de prever resultados e aprender baseado nestes resultados. Os vários nós da RNA são análogos aos neurônios no cérebro humano. Cada saída de um neurônio é conectada a entrada do próximo neurônio após ser adicionada uma função de peso.

Existe na literatura acadêmica uma série de artigos que incentivam a utilização de RNAs para resolução de problemas. De acordo com Bishop (1994), as redes neurais oferecem um poderoso conjunto de ferramentas para resolver problemas de reconhecimento de padrões, processamento de dados e controle não-linear, que podem ser consideradas complementares às abordagens mais convencionais. Spörl, Castro e Luchiari (2011) relata que as RNAs são utilizadas na solução de problemas complexos, onde o comportamento das variáveis não é rigorosamente conhecido, além de serem utilizadas em diversas áreas do conhecimento (SPÖRL; CASTRO; LUCHIARI, 2011). A capacidade da RNA em reconhecer padrões, ou seja, possuir a capacidade de aprender por meio de exemplos e de generalizar a informação aprendida, gerando um modelo não-linear, torna a sua aplicação na análise espacial bastante eficiente.

## 3.7 Rede Neural Artificial do tipo MLP

Uma RNA do tipo Multilayer Perceptron, é um tipo de rede neural artificial composta por várias camadas de neurônios interconectados. É uma das arquiteturas mais populares e amplamente utilizadas no campo do aprendizado de máquina. A MLP consiste em uma camada de entrada, uma ou mais camadas intermediárias chamadas de camadas ocultas, e uma camada de saída. Cada neurônio em uma camada está conectado a todos os neurônios da camada seguinte, formando um padrão de conexões em forma de rede. Cada conexão entre neurônios tem um peso associado que ajusta a força e a importância da influência de um neurônio em relação aos outros. A MLP é caracterizada por sua capacidade de aprender e mapear relações não lineares entre entradas e saídas. Durante o treinamento, os pesos das conexões são ajustados iterativamente com base em um algoritmo de aprendizado, como o backpropagation, a fim de minimizar a diferença entre as saídas previstas e as saídas esperadas.

Ainda conforme Delashmit, Manry *et al.* (2005), os neurônios de entrada podem possuir funções de ativação lineares e não-lineares. Cada neurônio da camada intermediária e da camada de saída têm limites e pesos associados. Normalmente os neurônios das camadas intermediárias possuem funções de ativação não-lineares e as saídas possuem funções de ativação lineares. Um modelo típico de MLP é demonstrado na Figura 46, (LEMAITRE, 2016).



Figura 46 – Topologia de uma MLP com duas camadas intermediárias.

Fonte: Adaptado de (LEMAITRE, 2016).

#### 3.7.1 Desenvolvimento da RNA do tipo MLP

A rede neural do tipo MLP foi implementada utilizando a biblioteca Keras e treinada no ambiente do Colab. Keras é uma biblioteca de alto nível que oferece uma interface simples e intuitiva para a construção e treinamento de redes neurais. Ela é amplamente utilizada devido à sua flexibilidade e eficiência na implementação de diferentes arquiteturas de redes neurais. O'Malley *et al.* (2019), ressalta que o*KerasTuner* é uma estrutura de otimização de hiperparâmetros escalável e fácil de usar que resolve os pontos problemáticos da pesquisa de hiperparâmetros. Configura facilmente o espaço de pesquisa com uma sintaxe definida por execução e aproveita um dos algoritmos de pesquisa disponíveis para encontrar os melhores valores de hiperparâmetros para seus modelos. O *KerasTuner* vem com algoritmos de otimização bayesiana, hiperbanda e pesquisa aleatória integrados e também foi projetado para ser fácil para os pesquisadores estenderem a fim de experimentar novos algoritmos de pesquisa.

O Colab, por sua vez, é um ambiente de desenvolvimento baseado na nuvem que permite executar código Python, fornecendo recursos computacionais poderosos para treinar modelos de aprendizado de máquina. A combinação da biblioteca Keras e o ambiente Colab oferece uma solução conveniente e eficaz para o desenvolvimento e treinamento de redes MLP, permitindo a exploração e experimentação de maneira fácil e acessível.

De modo inicial, foi construído o seguinte modelo de MLP:

• camada de entrada com 207 variáveis;

- primeira camada intermediária com 128 neurônios em função de ativação "relu";
- segunda camada intermediária com 64 neurônios em função de ativação "relu";
- camada de saída constituída de 2 neurônios, com função de ativação "softmax".

A função de perda empregada foi a "*sparse\_categorical\_crossentropy*" e a métrica de saída a "*accuracy*". O modelo é ilustrado na Figura 47.



Figura 47 – Configuração da MLP.

Esta configuração foi utilizada para o treinamento nas três situações abaixo:

- Conjunto de dados desbalanceado, sendo 97% referentes a chapas sem retrabalho e 3% referentes a chapas com retrabalho.
- Conjunto de dados balanceado com a técnica de oversampling.
- Conjunto de dados balanceado com a técnica de undersampling.

Além da construção das RNA MLPs para as situações acima, ainda foi realizado o ajuste dos hiperparâmetros da rede MLP através de um sistema de busca automático do pacote *Keras*, o *Keras-Tuner*. Este framework é capaz de otimizar a rede e seus hiperparâmetros de forma automatizada, estabelecendo a melhor configuração dentro das estabelecidas. As configurações de busca para a melhor configuração de rede MLP para a previsão de retrabalho estão descritas na Tabela 3. Foram obtidas 94 combinações diferentes de rede para serem testadas.

Tabela 3 – Tabela de configuração de busca de hiperparâmetros utilizada para previsão de retrabalho.

Números de	Números de	Funções de		Total de
camadas	neurônios por	ativação por	Otimizadores	combinações
ocultas	camada	camada		buscadas
1 a 3	0 a 128	'relu' 'sigmoid' 'tanh'	'adam' 'adamax' 'nadam' 'BMSprop'	94

Fonte: Próprio autor.

## 3.8 Avaliação da MLP

A matriz de confusão, como descrito por Beauxis-Aussalet e Hardman (2014), é o principal meio para avaliar erros em problemas de classificação (classificação de itens em classes, ou seja, categorias ou tipos de itens).

A matriz de confusão é uma ferramenta amplamente utilizada na área de aprendizado de máquina para avaliar o desempenho de um modelo de classificação. Ela é uma matriz que mostra a contagem de diferentes tipos de resultados obtidos pelo modelo em relação às classes verdadeiras. Na matriz, cada linha representa a classe verdadeira e cada coluna representa a classe prevista pelo modelo. Os elementos da matriz mostram o número de instâncias classificadas corretamente (verdadeiros positivos) e incorretamente (falsos positivos) para cada classe, como mostra a Figura 48.



Figura 48 - Matriz de Confusão.

Fonte: Próprio autor.

A matriz de confusão apresenta as frequências de classificação para cada classe, sendo elas:

• Verdadeiro Positivo (VP) ou *True Positive* (TP):

Os valores reais e previstos são os mesmos. O valor previsto pelo modelo é positivo, juntamente com um valor positivo real.

• Verdadeiro Negativo (VN) ou *True Negative* (TN):

Os valores reais e previstos são os mesmos. O valor previsto pelo modelo é negativo, juntamente com um valor negativo real.

• Falso Positivo (FP) (Erro de Tipo 1):

Os valores reais e previstos não são os mesmos. O valor previsto pelo modelo é positivo e falsamente previsto. No entanto, o valor real é negativo. Pode referir-se a isto como um erro de Tipo 1.

• Falso Negativo (FN) (Erro de Tipo 2):

Os valores reais e previstos não são os mesmos. O valor previsto pelo modelo é negativo e falsamente previsto. No entanto, o valor real é positivo. Pode referir-se a este erro como um erro de Tipo 2.

Com base na matriz de confusão, várias métricas de desempenho podem ser calculadas, como mostra a Figura 49. Essas métricas fornecem informações importantes sobre o desempenho do modelo, permitindo a avaliação de quais classes são mais facilmente reconhecidas e quais podem apresentar maiores dificuldades de classificação.



Figura 49 – Matriz de Confusão.

Fonte: (MOHAMMED; RAWASHDEH; ABDULLAH, 2020b).

As métricas de desempenho utilizadas nesse trabalho são:

 Acurácia: indica o desempenho modelo. Ou seja, o total de acertos/total de classificações. A curácia é calculada de acordo com a Equação 3.3.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN}$$
(3.3)

 Precisão: mede quanto o modelo acertou a previsão da classe positiva dentro de todas as classificações da classe positiva. Ou seja, respostas positivas corretas/Total de positivos previstos. Para esta métrica os Falsos Positivos são considerados mais prejudiciais que os Falsos Negativos. A precisão é calculada de acordo com a Equação 3.4.

$$\operatorname{Precisão} = \frac{TP}{TP + FP}$$
(3.4)

 Sensibilidade / Recall: mede quanto o modelo acertou a previsão das classes positivas do total de classes Positivas. Esta métrica é utilizada nas situações em que os Falsos Negativos são considerados mais prejudiciais que os Falsos Positivos. A sensibilidade/recall é calculado de acordo com a Equação 3.5

Sensibilidade = 
$$\frac{TP}{TP + FN}$$
 (3.5)

• *F1-Score*: média harmônica entre precisão e recall. O *F1-Score* é calculado de acordo com a Equação 3.6.

$$F1-Score = \frac{2 * Sensibilidade * Precisão}{Sensibilidade + Precisão}$$
(3.6)

Para o processo de avaliação de retrabalho dos materiais processados na desempenadeira a quente, fazer a previsão que uma chapa não precisa de retrabalho, porém, a mesma apresenta defeito de planicidade e portanto precisaria de retrabalho é a situação (falso negativo) mais crítica porque isto poderia ocasionar o envio de material defeituoso para o cliente. Portanto, além das métricas de acurácia e precisão as principais métricas para avaliação dos resultados deste trabalho serão o *recall* e o *F1-Score*.

# 4 Resultados

O modelo inicial da RNA, projetada manualmente sem o uso do Keras-Tuner, foi treinada com a base de dados constituída de 207 variáveis de entrada. A taxa de aprendizagem foi fixada em 0.001 e o processo de trienamento ocorreu ao longo de 60 épocas. A Tabela 4 resume a topologia da rede.

Camada	Tipo da camada	Número de neurônios	Função de Ativação			
Oculta	Dense	128	Relu			
Oculta	Dense	64	Relu			
Saída	Dense	2	Softmax			
Fonte: Próprio autor.						

Tabela 4 – Configuração da rede neural MLP.

A acurácia obtida foi de 97%, porém, devido à base de dados altamente desbalanceada, era esperado esse resultado, o que não indica necessariamente que o modelo esteja classificando corretamente.

Com o objetivo de obter uma métrica mais acertiva para o classificador, a técnica f1-score foi aplicada. Conforme pode-se verificar na Figura 50, para o conjunto de dados sem retrabalho o f1-score foi de 0,99, já para o conjunto de dados com retrabalho o f1-score obtido foi de somente 0,22.

Como o número de chapas sem retrabalho é muito maior que o número de chapas com retrabalho o modelo encontrou facilidade em prever que a chapa não teria retrabalho, todavia, apresentou dificuldade para prever a ocorrência de chapas com retrabalho. Figura 50 – Matriz de Confusão e valores de precisão (precision), recuperação (recall) e *f1-score* obtidos após o treinamento da rede MLP - base de dados sem tratamento.



Base sem tratamento

Fonte: Próprio autor.

Um segundo experimento foi realizado, com o mesmo modelo da RNA, substituindo a base de dados desbalanceada por uma base de dados balanceada utilizando a técnica SMOTE-Tomek *oversampling*, e pode-se observar uma acurácia de 93%.

Conforme pode-se ver na Figura 51,0 *f1-score* foi de 0,93, para os conjuntos sem retrabalho e com retrabalho. Portanto, o resultado do *f1-score* diminuiu em relação a base desbanlaceada para prever que a chapa não teria retrabalho (de 97% para 93%), porém, apresentou uma melhoria significativa para prever a ocorrência de chapas com retrabalho (de 22% para 93%).

Figura 51 – Matriz de Confusão e valores de precisão (precision), recuperação (recall) e f1-score obtidos após o treinamento da rede MLP - base de dados com oversampling.



**Base Over Sampling** 

Fonte: Próprio autor.

Um terceiro experimento foi realizado, com o mesmo modelo da RNA, substituindo a base desbalanceada por uma base de dados balanceada utilizando a técnica smote undersampling, e pode-se observar uma acurácia de 93%.

Conforme pode-se verificar na Figura 52, o f1-score foi de 0,80 para o conjunto de dados sem retrabalho e 0,81 para a classe com retrabalho. Portanto, pode-se observar que o uso da técnica de smote undersampling foi inferior ao SMOTE-Tomek oversampling que alcançou 0,93





Fonte: Próprio autor.

Observa-se que apesar do nível de acurácia da matriz de confusão da base sem tratamento apresentar valor elevado (97%), o nível de *recall* (relacionado com a minimização dos falsos negativos) e o nível de *precision* (relacionado com a capacidade de acertar o valor positivo quando este for realmente positivo), para a variável com retrabalho (nível 1), não obteve desempenho satisfatório. Isso está relacionado com o poder de previsão de retrabalho. Este comportamento é esperado para classes com alto grau de desbalanceamento, pois o sistema tende a prever que não há retrabalho. Por sua vez, o balanceamento da base de dados permitiu o ajuste desses níveis de *recall* e *precision*, permitindo que o modelo pudesse trabalhar adequadamente eliminando a distorção de quantidade muito diferentes de dados entre as classes. Analisando os resultados obtidos pelas classes ajustadas podemos observar que o modelo com *oversampling* obteve o melhor desempenho.

Na tentativa de melhor ainda mais o desempenho da rede neural, foi utilizada a biblioteca Keras-tuner para encontrar a melhor configuração de modelo para a rede neural. Nesta etapa, somente as bases de dados com *over* e *under sampling* foram empregadas. Para a base balanceada por meio de *oversampling*, o Keras-tuner sugeriu o modelo apresentado na Tabela:5. A função de perda utilizada foi sparse\_categorical\_crossentropy, otimizador NADAM, taxa de aprendizagem de 0.001, 200 épocas e a métrica de avaliação foi a *accuracy*.

Tabela 5 – Modelo de RNA do tipo MLP para base oversampling sugerido pelo Keras Tuner.

Camada	Tipo da camada	Número de neurônios	Função de Ativação			
Oculta	Dense	96	Relu			
Oculta	Dense	96	Relu			
Oculta	Dense	32	Relu			
Saída	Dense	2	Softmax			
Fonte: Próprio autor.						

A evolução do treinamento, validação e o resultado do Keras Tuner podem ser vistos na Figura 53. Observa-se que o modelo indicado pelo Keras Tuner apresenta maior complexidade em número de camadas e número de neurônios quando comparado ao modelo definido manualmente.

Figura 53 – Resultados de desempenho e valores de acurácia para treinamento e validação considerando as bases de dados com *oversampling*.

## **Oversampling**

```
Results summary
Results in keras_tuner_dir/melhor_modelo_ov4
Showing 1 best trials
Objective(name='val_accuracy', direction='max')
Trial summary
Hyperparameters:
neurons_camada1: 96
neurons_camada2: 96
neurons_camada2: 96
neurons_camada3: 32
ativacao_camada1: relu
ativacao_camada2: relu
otimizador: nadam
```



Fonte: Próprio autor.
Após os ajustes dos hiperparâmetros da MLP pode-se notar, através da análise das métricas da matriz de confusão, apresentado na Figura 54, melhora significativa nos valores de *precision* e *recall* tanto para a previsão de chapas com retrabalho quanto para as chapas sem retrabalho. O *f1-score* e a acurácia alcançaram 97%.

Figura 54 – Matriz de confusão e valores de precisão (*precision*), Sensibilidade (*recall*) e *f1-score* obtidos após o treinamento da rede MLP com ajuste de hiperparâmetros a partir das bases com *oversampling*.



Fonte: Próprio autor.

Considerando o modelo para a base com *underSampling*, O Keras Tuner sugeriu o modelo apresentado na Tabela:6 A função de perda utilizada foi a sparse\_categorical\_crossentropy, otimizador RMSprop, taxa de aprendizagem de 0.001, 200 épocas e a métrica de avaliação utilizada foi a *accuracy*.

Camada	Tipo da camada	Número de neurônios	Função de Ativação
Oculta	Dense	80	Relu
Oculta	Dense	112	Relu
Oculta	Dense	80	sigmoid
Saída	Dense	2	Softmax
	F	onte: Próprio autor.	

Tabela 6 – Configuração e hiniperparâmetros para base undersampling utilizando o Keras Tuner.

A evolução do treinamento, validação e o resultado do Keras Tuner podem ser vistos na figura na Figura 55. Pode-se notar que o modelo apresenta complexidade semelhante ao obtido para o cenário considerando *oversampling*, com o total de neurônios para ambos os modelos igual, variando somente a sua distribuição entre as camadas.

Figura 55 – Resultados de desempenho e valores de acurácia para treinamento e validação considerando as bases de dados com *undersampling*.

### Undersampling

```
Results summary
Results in keras_tuner_dir/melhor_modelo_under4
Showing 1 best trials
Objective(name='val_accuracy', direction='max')
Trial summary
Hyperparameters:
neurons_camada1: 80
neurons_camada2: 112
neurons_camada2: 112
neurons_camada3: 80
ativacao_camada1: sigmoid
ativacao_camada2: relu
otimizador: RMSprop
```



Fonte: Próprio autor.

Após os ajustes dos hiperparâmetros da MLP com a base de dados *undersampling* podese notar, através da análise das métricas da matriz de confusão, 56, que os valores *precision* e *recall* não obtiveram melhorias significativas tanto para a previsão de chapas com retrabalho quanto para as chapas sem retrabalho. O *f1-score* também manteve resultados próximos a 80%.

Figura 56 – Matriz de confusão e valores de precisão (*precision*), Sensibilidade (*recall*) e *f1-score* obtidos após o treinamento da rede MLP com ajuste de hiperparâmetros a partir da base com *undersampling*.



**Base Under Sampling** 

Fonte: Próprio autor.

Observa-se que a base com *oversampling* apresentou valores de *recall*, *precision* e *accuracy* de melhor desempenho que a rede inicial 50. Entretanto, a rede com *undersampling* não apresentou melhora no desempenho com relação à rede inicial.

A fim de se verificar o desempenho médio via *Cross Validation*, foram realizadas por 10 vezes a estratificação aleatória nas bases de treinamento e teste, o treinamento do modelo e avaliação do desempenho através dos valores de acurácia para as duas bases (*oversampling* e *undersampling*). Os resultados foram comparados, como mostra a Figura 57. Para a base balanceada com *oversampling* foi obtido uma média da acurácia do modelo de: 98.15% e desvio padrão de 0.30%. Para a base balanceada com *undersampling* foi obtido uma média da acurácia a métrica acurácia, uma superioridade do modelo para a base balanceada com *oversampling*.





Fonte: Próprio autor.

## 5 Considerações Finais

O processo KDD foi aplicado em uma base de dados com o objetivo de desenvolver um modelo de RNA do tipo MLP para a predição do nível de retrabalho da desempenadeira a quente.

Pode-se observar na Tabela 7 que os melhores resultados de acurácia e *f1-score* foram obtidos pelo modelo com ajuste de hiperparâmetros utilizando a base balanceada pelo método *oversampling*. Já os piores resultados foram encontrados no modelo que utilizou a base de dados desbalanceada.

basa mátrica	Acurácia	Precisão	Precisão	Recall	Recall	F1-Score	F1-Score		
Dase-metrica		sem Retrab.	com Retrab.	sem Retrab.	com Retrab.	sem Retrab.	com Retrab.		
Base	0.07	0,97	0,6	1	0,13	0,99	0,22		
desbalanceada	0,97								
Base									
balanceada	0,93	0,94	0,92	0,92	0,94	0,93	0,93		
Oversampling									
Base									
balanceada	0,81	0,81	0,8	0,79	0,82	0,8	0,81		
Undersampling									
Base									
balanceada	0,97	1	0,95	0,95	1	0,97	0,97		
Oversampling - Keras									
Base									
balanceada	0,8	0,76	0,84	0,86	0,74	0,81	0,78		
Undersampling - Keras									
Fonte: Próprio autor.									

Tabela 7 – Resumo dos resultados obtidos para as bases de dados não balanceadas e balanceadas.

A Figura 58 mostra que a base desbalanceada e a base balanceada pelo método *oversam-pling* alcançaram os melhores resultados de acurácia. Porém, para esse cenário, o aprendizado de máquina tende a sempre responder a "classe majoritária". Portanto, apesar da acurácia ser uma medida importante, a medida mais importante é a f1-score.



Figura 58 – Gráfico com os resultados de acurácia dos modelos MLP.

A Figura 59 mostra que a base balanceada pelo método *oversampling* com ajuste dos hiperparâmetros alcançou os melhores resultados *f1-score*. Portanto é o modelo selecionado como o mais adequado do trabalho. Pode-se perceber que atingiu *f1-score* de 0,97 tanto para a classe sem retrabalho quanto para a classe com retrabalho.



Figura 59 – Gráfico com os resultados de *f1-score* dos modelos MLP.

Os valores de correlação através do Mapa de Calor não indicaram, de forma geral, tendências de relações lineares fortes entre as variáveis, com exceção das relações entre a "Espessura e os GAPs de Entrada e Saída", além da "Temperatura do Forno e a Força da Desempenadeira". Entretanto, o estudo de relações não lineares ou de interação entre as variáveis não foi avaliado e serão melhor explorados em estudos futuros.

Observou-se que a maior parte dos retrabalhos ocorre para a faixa de espessura abaixo de 50mm, o que pode indicar possibilidades de melhores ajustes no equipamento para essa faixa de trabalho.

Empregando-se a base de dados expandida, por meio da técnica SMOTE-Tomek (*over-sampling*), o modelo de previsão de retrabalho obteve desempenho acima de 97% de acurácia e f1-score, tanto para a predição de chapas com retrabalho quanto para a predição de chapas sem retrabalho.

Nesse sentido, o uso do sistema desenvolvido nesse trabalho será indicado aos especialistas da área na tratativa da previsão e ajustes para se evitar o retrabalho na desempenadeira a frio.

#### 5.1 Sugestão de trabalhos futuros

Como principal sugestão, implantar um modelo *off-line* para simulação de resultados e correção das tabelas existentes. Isto porque a identificação de valores atuais da tabela que tem oportunidade de melhoria poderia provocar redução de envio de materias para retrabalho economizando recursos e agilizando o fluxo de produção. Este trabalho também explorou os assuntos referentes a previsão de outras variáveis do processo de desempeno e a análise de correlação entre algumas variáveis e a necessidade de retrabalho. Sugere-se que sejam aprofundados os seguintes temas:

- A relação entre as variáveis "Espessura" e "Teor de Níquel" com a necessidade de retrabalho;
- Previsão da força da desempenadeira a quente;
- Previsão das aberturas de entrada e saída dos rolos da desempenadeira a quente.

#### 5.1.1 Influência da espessura e níquel no retrabalho

A relação entre as variáveis "Espessura" e "Teor de Níquel" com o nível de retrabalho pode ser observada nas Figuras 60 e 61. Apesar de estarem dentro do mesmo intervalo de abrangência, pode ser visto que a ocorrência de retrabalho está associada aos menores valores dessas variáveis. Este tipo de verificação foi indicado aos especialistas da área e podem ser melhor investigados em estudos futuros.







Figura 61 – Retrabalho x Níquel.

# 5.1.2 Previsão da força da desempenadeira a quente e dos valores de aberturas de entrada e saída

Uma vez que a base de dados fornece diferentes variáveis de saída, foram verificados os desempenhos em regressão de redes MLP com ajuste de hiperparâmetros por meio de busca automatizada na previsão dos valores de força de desempenadeira e dos valores de GAPs de entrada e saída da desempenadeira. Estas variáveis ainda não possuem modelos específicos e são úteis no ajuste dos parâmetros de processo e ganho de desempenho da desempenadeira a quente. O resultado dos gráficos de dispersão entre os valores reais e previstos com as diferentes MLPs são mostrados nas Figuras 62, 63 e 64.

Figura 62 – Gráficos de dispersão entre valores previstos e reais para a força de desempenadeira obtido após treinamento e ajuste de hiperparâmetros de uma rede MLP.

Força desempenadeira



Fonte: Próprio autor.

Figura 63 – Gráficos de dispersão entre valores previstos e reais para o GAP de entrada obtido após treinamento e ajuste de hiperparâmetros de uma rede MLP.

GAP de entrada



Fonte: Próprio autor.

Figura 64 – Gráficos de dispersão entre valores previstos e reais para o GAP de saída obtido após treinamento e ajuste de hiperparâmetros de uma rede MLP.





Observa-se, na Figura 62, uma dispersão entre os valores previstos e reais para a força de desempenadeira. Por sua vez, nas Figuras 63 e 64 os valores previstos de GAPs de entrada e saída apresentaram respostas satisfatórias com relação aos dados reais, destacando-se a presença de alguns *outliers* de previsão, que podem ser melhor investigados em estudos futuros.

## Referências

ASSUNÇÃO, F. Estratégias para tratamento de variáveis com dados faltantes durante o desenvolvimento de modelos preditivos. Tese (Doutorado) — Universidade de São Paulo, 2012.

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**, v. 37, n. 7, p. 4593–4607, 2013. ISSN 0307-904X. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0307904X12006014">https://www.sciencedirect.com/science/article/pii/S0307904X12006014</a>>.

BARU, N. K.; LAUGWITZ, M.; JOCHUM, M.; LOHMAR, J. On considering the influence of kinematic hardening in finite element simulation of hot levelling of structural steel heavy plates. In: TRANS TECH PUBL. **Key Engineering Materials**. [S.1.], 2022. v. 926, p. 1993–2003.

BEAUXIS-AUSSALET, E.; HARDMAN, L. Visualization of confusion matrix for non-expert users. In: **IEEE Conference on Visual Analytics Science and Technology (VAST)-Poster Proceedings**. [S.l.: s.n.], 2014. p. 1–2.

BISHOP, C. M. Neural networks and their applications. **Review of scientific instruments**, American Institute of Physics, v. 65, n. 6, p. 1803–1832, 1994.

CASTILHO, R. **Tecido nervoso**. acessado em maio de 2023. Disponível em: <a href="https://www.todamateria.com.br/tecido-nervoso/">https://www.todamateria.com.br/tecido-nervoso/</a>>.

DAVID, F. F. Controle da magnitude do efeito bauschinger em arame de aço ultra baixo carbono. 2023.

DELASHMIT, W. H.; MANRY, M. T. *et al.* Recent developments in multilayer perceptron neural networks. In: **Proceedings of the seventh Annual Memphis Area Engineering and Science Conference, MAESC**. [S.l.: s.n.], 2005.

DESAI, M.; SHAH, M. An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (mlp) and convolutional neural network (cnn). **Clinical eHealth**, Elsevier, v. 4, p. 1–11, 2021.

EDWARDS, W. J.; JOHN, R.; ROZMUS, G.; THOMAS, P. J.; THOMPSON, N. E. Automation of a plate mill hot leveller: A predictive levelling model in operation producing excellent results. p. 1–10, 1987.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI magazine**, v. 17, n. 3, p. 37–37, 1996.

GOEBEL, M.; GRUENWALD, L. A survey of data mining and knowledge discovery software tools. **ACM SIGKDD explorations newsletter**, ACM New York, NY, USA, v. 1, n. 1, p. 20–33, 1999.

HEDSTRÖM, E.; WANG, P. Anomaly Detection using a Deep Learning Multi-layer Perceptron to Mitigate the Risk of Rogue Trading. 2021.

JHA, K.; DOSHI, A.; PATEL, P.; SHAH, M. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, Elsevier, v. 2, p. 1–12, 2019.

LARKIOLA, J.; MYLLYKOSKI, P.; KORHONEN, A.; CSER, L. The role of neural networks in the optimisation of rolling processes. **Journal of Materials Processing Technology**, v. 80-81, p. 16–23, 1998. ISSN 0924-0136. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0924013698002064">https://www.sciencedirect.com/science/article/pii/S0924013698002064</a>>.

LAUGWITZ, M.; JOCHUM, M.; SCHEFFER, T.; LOHMAR, J. Towards hot levelling strategies for steel heavy plates: analysis of flatness evolution in accelerated cooling, hot levelling, and final air cooling via thermo-mechanical fe modelling. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 120, n. 3-4, p. 2469–2488, 2022.

LAUGWITZ, M.; SEUREN, S.; JOCHUM, M.; HOJDA, S.; LOHMAR, J.; HIRT, G. Development of levelling strategies for heavy plates via controlled fe models. **Procedia Engineering**, v. 207, p. 1349–1354, 2017. ISSN 1877-7058. International Conference on the Technology of Plasticity, ICTP 2017, 17-22 September 2017, Cambridge, United Kingdom. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S1877705817356722">https://www.sciencedirect.com/science/article/pii/S1877705817356722</a>>.

LEMAITRE, G. **Computer-aided diagnosis for prostate cancer using multi-parametric magnetic resonance imaging**. Tese (Doutorado) — Universitat de Girona. Escola Politècnica Superior, 2016.

LEMAîTRE, G.; NOGUEIRA, F.; ARIDAS, C. K. Imbalanced-learn: A python toolbox to tackle the curse of imbalanced datasets in machine learning. **Journal of Machine Learning Research**, v. 18, n. 17, p. 1–5, 2017. Disponível em: <a href="http://jmlr.org/papers/v18/16-365.html">http://jmlr.org/papers/v18/16-365.html</a>.

LIU, Z. *et al.* A method of svm with normalization in intrusion detection. **Procedia Environmental Sciences**, Elsevier, v. 11, p. 256–262, 2011.

LIU, Z.; WANG, Y.; YAN, X. A new model for the plate leveling process based on curvature integration method. **International Journal of Mechanical Sciences**, Elsevier, v. 54, n. 1, p. 213–224, 2012.

MENG, Q.; ZHAI, R.; ZHANG, Y.; FU, P.; ZHAO, J. Analysis of springback for multiple bending considering nonlinear unloading-reloading behavior, stress inheritance and bauschinger effect. **Journal of Materials Processing Technology**, v. 307, p. 117657, 2022. ISSN 0924-0136. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0924013622001698">https://www.sciencedirect.com/science/article/pii/S0924013622001698</a>>.

MOHAMMED, R.; RAWASHDEH, J.; ABDULLAH, M. Machine learning with oversampling and undersampling techniques: overview study and experimental results. In: IEEE. **2020 11th international conference on information and communication systems (ICICS)**. [S.1.], 2020. p. 243–248.

MOHAMMED, R.; RAWASHDEH, J.; ABDULLAH, M. Machine learning with oversampling and undersampling techniques: Overview study and experimental results. In: . [S.l.: s.n.], 2020. p. 243–248.

MOLLEDA, J.; USAMENTIAGA, R.; GARCIA, D. F. On-line flatness measurement in the steelmaking industry. **Sensors**, Molecular Diversity Preservation International (MDPI), v. 13, n. 8, p. 10245–10272, 2013. Disponível em: <a href="https://www.mdpi.com/1424-8220/13/8/10245">https://www.mdpi.com/1424-8220/13/8/10245</a>>.

MOURÃO, M. B.; YOKOJI, A.; MALYNOWSKYJ, A.; LEANDRO, C. A. d. S.; TAKANO, C.; QUITES, E. E. C.; GENTILE, E. F.; SILVA, G. F. B. L.; BOLOTA, J. R.; GONÇALVES, M. *et al.* Introdução à siderurgia. 2007.

OGASAWARA, E.; MARTINEZ, L. C.; OLIVEIRA, D. D.; ZIMBRÃO, G.; PAPPA, G. L.; MATTOSO, M. Adaptive normalization: A novel data normalization approach for non-stationary time series. In: IEEE. **The 2010 International Joint Conference on Neural Networks** (IJCNN). [S.1.], 2010. p. 1–8.

O'MALLEY, T.; BURSZTEIN, E.; LONG, J.; CHOLLET, F.; JIN, H.; INVERNIZZI, L. *et al.* **KerasTuner**. 2019. <a href="https://github.com/keras-team/keras-tuner">https://github.com/keras-team/keras-tuner</a>.

RIZZO, E. d. S. Introdução aos processos de refino secundário dos aços. Associação Brasileira de Metalurgia e Materiais. São Paulo, v. 99, 2006.

RIZZO, E. M. D. S. Introdução aos processos siderúrgicos. São Paulo, 2005.

RIZZO, E. M. d. S. Processos de laminação a quente de produtos planos de aço. São Paulo: Associação Brasileira de Metalurgia, Materiais e Mineração, 2011.

RIZZO, E. M. da S. Processos de laminação dos aços: uma introdução. [S.l.]: ABM, 2007.

SANTOS, F. A. d. **Estudo do efeito Bauschinger em cobre e latão**. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2017.

SATPATHY, S. Overcoming class imbalance using smote techniques. 2020. Disponível em: <a href="https://www.analyticsvidhya.com/blog/2020/10/">https://www.analyticsvidhya.com/blog/2020/10/</a> overcoming-class-imbalance-using-smote-techniques/>.

SILVA, M. J. dos A. Variação da taxa de descarburação para vários padrões de injeção de argônio na perna de subida do desgaseificador a vácuo rh. Universidade Federal de Minas Gerais, 2010.

SPÖRL, C.; CASTRO, E.; LUCHIARI, A. Aplicação de redes neurais artificiais na construção de modelos de fragilidade ambiental. **Revista do Departamento de Geografia**, v. 21, p. 113–135, 2011.

STOLFO, S. J.; PRODROMIDIS, A. L.; TSELEPIS, S.; LEE, W.; FAN, D. W.; CHAN, P. K. Jam: Java agents for meta-learning over distributed databases. In: **KDD**. [S.l.: s.n.], 1997. v. 97, p. 74–81.

TAFNER, M. A. Redes neurais artificiais: aprendizado e plasticidade. **Cérebro & Mente**, v. 2, n. 5, 1998.

URBANO, J.; LIMA, H.; HANJALIC, A. A new perspective on score standardization. In: **Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval**. [S.l.: s.n.], 2019. p. 1061–1064.

USIMINAS. Apostila de Treinamento da Laminação a Quente da Usiminas. [S.l.: s.n.], 2017.

USIMINAS. Apostila de Treinamento da Aciaria da Usiminas. [S.l.: s.n.], 2018.

WILSON, W. G.; MCLEAN, A. **Desulfurization of iron and steel and sulfide shape control**. [S.l.]: Iron & Steel Society, 1980. YI, G.; GU, Y.; QIU, L.; WANG, C. Multi-roll levelling method for longitudinal waves in metal sheet based on a coupled curvature integration model. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 106, p. 2721–2734, 2020.