



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



**Predição do teor de carbono na descarbonetação de aços
elétricos de grão orientado utilizando técnicas de aprendizado
de máquina**

**Felipe Caetano Cordeiro De Souza
Fernanda Maria Nunes Moreira
Mário Sérgio Mourão**

João Monlevade, MG
2023

Felipe Caetano Cordeiro De Souza
Fernanda Maria Nunes Moreira
Mário Sérgio Mourão

**Predição do teor de carbono na descarbonetação de aços
elétricos de grão orientado utilizando técnicas de aprendizado
de máquina**

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: Profa. Dra. Sarah Negreiros de Carvalho Leite

João Monlevade, MG

2023

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

S729p Souza, Felipe Caetano Cordeiro de.

Predição do teor de carbono na descarbonetação de aços elétricos de grão orientado utilizando técnicas de aprendizado de máquina.

[manuscrito] / Felipe Caetano Cordeiro de Souza. Arsênio Fernanda Maria Nunes Moreira. Mário Sérgio Mourão. - 2024.

40 f.: il.: color., gráf., tab..

Orientadora: Profa. Dra. Sarah Negreiros de Carvalho Leite.

Produção Científica (Especialização). Universidade Federal de Ouro Preto. Departamento de Engenharia de Produção.

1. Aço - Metalurgia. 2. Análise de regressão. 3. Aprendizado do computador. 4. Inteligência artificial. 5. Previsão. 6. Redes neurais (Computação). I. Fernanda Maria Nunes Moreira, Arsênio. II. Mourão, Mário Sérgio. III. Leite, Sarah Negreiros de Carvalho. IV. Universidade Federal de Ouro Preto. V. Título.

CDU 519.2:004.8

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



FOLHA DE APROVAÇÃO

Felipe Caetano Cordeiro De Souza

Fernanda Maria Nunes Moreira

Mário Sérgio Mourão

Predição do teor de carbono na descarbonetação de aços elétricos de grão orientado utilizando técnicas de aprendizado de máquina

Trabalho de conclusão de curso apresentado 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 28 de fevereiro de 2024

Membros da banca

Dra. Sarah Negreiros de Carvalho Leite - Orientadora - Instituto Tecnológico de Aeronáutica
Me. Alexandre Magno de Souza - Universidade Federal de Ouro Preto
Dr. Adriano Alex de Almeida - Aperam South America

Sarah Negreiros de Carvalho Leite, orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 01/04/2024



Documento assinado eletronicamente por **Thiago Augusto de Oliveira Silva, PROFESSOR DE MAGISTERIO SUPERIOR**, em 03/04/2024, às 15:17, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0680692** e o código CRC **D418B675**.

Dedicamos este trabalho à empresa Aperam, que ao incentivar o aprendizado, fornece conhecimento e desenvolvimento aos seus colaboradores.

Agradecimentos

Agradecemos à Professora Sarah N. C. Leite, por acreditar no nosso trabalho, pela orientação e por abrir os horizontes de possibilidades.

“No que diz respeito ao empenho, ao compromisso, ao esforço e à dedicação, não existe meio termo: ou você faz uma coisa bem feita ou não faz.” Ayrton Senna

Resumo

Uma das etapas finais na produção de aço elétrico de grão orientado é a descarbonetação, que evita o envelhecimento magnético. O processo em si é o recozimento primário do material laminado em um forno horizontal, sob controle de temperatura, pressão, tração e umidade, de modo que a quantidade de carbono seja reduzida e o tamanho de grãos sejam otimizados. O equipamento funciona com parâmetros pré-estabelecidos que resultam em um valor médio final. Isto dificulta o controle para um resultado de descarbonetação ótimo. Neste trabalho foram desenvolvidos modelos de predição de teor de carbono pré-processo na linha de descarbonetação do aço GO, visando mitigar a produção de produtos não conformes. A metodologia adotada neste estudo envolveu a utilização de um banco de dados exportado do sistema integrado de produção como fonte primária de informações. Os dados foram submetidos a um processo de tratamento e análise por meio de técnicas avançadas, incluindo árvores de decisão e redes neurais. Essas abordagens permitiram a identificação de padrões complexos e a modelagem preditiva necessária para entender e otimizar os processos de produção. Os resultados alcançados, especialmente com a utilização da rede neural MLP, demonstraram um desempenho promissor, com um MAE de 1,81 ppm, que está abaixo da margem de erro do equipamento de análise de carbono. Contudo, é importante destacar que este trabalho concentrou-se exclusivamente na previsão do teor de carbono com base na matéria-prima e nos parâmetros de processo, sendo necessário avançar nas análises de modo a tornar o modelo efetivamente integrável à linha de produção. A MLP apresentou resultados promissores, atendendo às necessidades do processo. Isso é evidenciado pelo fato de que o erro médio absoluto (MAE) do modelo é inferior à margem de erro de medição da análise de carbono, estabelecida em 2,00 ppm.

Palavras-chaves: Predição do teor de carbono. Redes Neurais Artificiais. Árvore de Regressão. Produção de aço elétrico.

Abstract

One of the final stages in the production of grain-oriented electrical steel is decarburization, which involves reducing carbon levels to decrease the material's magnetic loss. The process itself entails annealing the rolled material in a horizontal furnace, under controlled temperature, pressure, tension, and humidity, aiming to decrease the quantity and size of carbon precipitates. The equipment operates with pre-established parameters resulting in a final average value, making it challenging to control for optimal decarburization results. In this study, prediction models for pre-process carbon content in the GO steel decarburization line were developed to mitigate the production of non-conforming products. The achieved results, particularly with the use of the MLP neural network, showed promising performance, with an MAE of 1.81 ppm, below the carbon analysis equipment's margin of error. However, it's essential to highlight that this work focused solely on predicting carbon content based on raw materials and process parameters, necessitating further analysis to integrate the model into the production line effectively.

Keywords: *Carbon content prediction. Artificial Neural Networks. Regression Tree. Electric steel production.*

Lista de ilustrações

Figura 1 – Construção de transformador elétrico.	2
Figura 2 – Etapas do processo de descarbonetação.	2
Figura 3 – Transformador e sua aplicação no circuito energético.	6
Figura 4 – Aspectos de grão em aço elétrico GO após linha de descarbonetação.	7
Figura 5 – Exemplo de geração de amostragem sintética através do SMOTE, onde as bolas vermelhas são dados originais e a bolas verdes são amostras sintéticas plotadas pelo "vizinho mais próximo".	9
Figura 6 – Exemplo de um modelo de Árvore de Regressão.	10
Figura 7 – Exemplo de rede neural com camadas ocultas.	12
Figura 8 – Diagrama da metodologia adotada.	14
Figura 9 – Análise estatística Seaborn.	17
Figura 10 – Correlação entre as variáveis e o carbono de saída.	18
Figura 11 – Resultados da variação explicada para cada componente principal.	19
Figura 12 – Algoritmo para separação das faixas de ppm de Carbono.	19
Figura 13 – Distribuição da faixa de carbono de saída no banco de dados original.	20
Figura 14 – Algoritmo de implementação da técnica SMOTE.	20
Figura 15 – Banco de dados descarbonização.	21
Figura 16 – Banco de dados pré-processado.	21
Figura 17 – Boxplot das variáveis com dados originais.	22
Figura 18 – Boxplot das variáveis após normalização de dados.	22
Figura 19 – Algoritmo da etapa de análise de componentes principais.	23
Figura 20 – Exemplo de rede neural com camadas ocultas.	24
Figura 21 – Distribuição da faixa de carbono de saída no banco de dados balanceado.	25
Figura 22 – Comparação entre o valor real e o predito usando Árvore de Regressão.	26
Figura 23 – Comparação entre o valor real e o predito usando rede MLP.	27
Figura 24 – Comparação entre os valores de Erro Médio Absoluto da Árvore de Regressão para as profundidas testadas e os modelos da Rede Neural MLP em cada número de épocas treinadas.	27

Sumário

1	INTRODUÇÃO	1
1.1	Objetivos	4
1.2	Organização do trabalho	4
2	CONTEXTUALIZAÇÃO TEÓRICA	5
2.1	Aços elétricos	5
2.2	Envelhecimento magnético	6
2.3	PCA	8
2.4	SMOTE	8
2.5	Árvore de regressão	9
2.6	Redes neurais artificiais	10
2.6.1	Histórico	10
2.6.2	Perceptron	11
2.6.3	MLP	12
3	METODOLOGIA	14
3.1	Base de dados	15
3.2	Análise exploratória dos dados	16
3.3	Pré-processamento	20
3.4	Árvore de regressão	23
3.5	Redes neurais artificiais	23
4	RESULTADOS	25
4.1	Árvore de regressão	25
4.2	Redes neurais MLP	26
5	CONCLUSÃO	29
	REFERÊNCIAS	30

1 Introdução

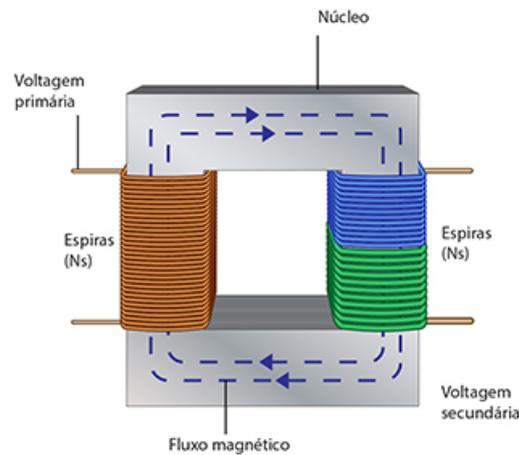
Com o aumento da emissão de gases que colaboram para o efeito estufa, a energia elétrica tem se tornado um dos insumos mais importantes para substituição dos combustíveis fósseis. A sua escassez provoca impactos significativos no desenvolvimento econômico mundial. O consumo de eletricidade é cada vez maior, estudos na área de demanda de energia no setor elétrico apontam um crescimento de 5,3% ao ano (TOLMASQUIM, 2012), exigindo crescentes investimentos para suprir a demanda. Desta forma, evitar desperdícios de energia elétrica é uma questão de elevada importância para a sociedade em geral.

Os aços elétricos de grão orientado (GO) desempenham um papel de extrema importância nos setores de geração, distribuição e utilização de eletricidade, destacando-se pelas suas propriedades de alta indução magnética e baixas perdas magnéticas no sentido de laminação. Essas características fazem do aço elétrico GO uma escolha ideal na construção de núcleos de transformadores. A notável propriedade magnética desse material resulta da adição estratégica de elementos, como o silício (Si), que aumentam a resistividade, e do desenvolvimento de uma orientação cristalográfica preferencial. Alcântara e Cunha (2013) destaca que o produto comercial destaca-se por apresentar excelentes propriedades magnéticas na direção de laminação, graças a uma robusta orientação preferencial denominada "orientação de Goss".

Os transformadores elétricos são dispositivos fundamentais no campo da engenharia elétrica, projetados para transferir energia elétrica entre circuitos por meio do princípio da indução eletromagnética. Compostos por dois enrolamentos de fios condutores, conhecidos como primário e secundário, os transformadores operam com base na variação do campo magnético que ocorre quando uma corrente alternada passa pelo enrolamento primário. Esse campo magnético, por sua vez, induz uma corrente elétrica no enrolamento secundário, permitindo a transferência de energia de um circuito para outro. A relação entre o número de espiras nos enrolamentos determina a tensão e a corrente elétrica em cada lado do transformador, possibilitando a adaptação eficiente de níveis de voltagem para atender às necessidades específicas de sistemas de distribuição elétrica. Durante a operação, parte da energia é dissipada na forma de calor devido às características físicas do transformador e às correntes que fluem através de seus enrolamentos. Uma eficiência mais elevada implica em menores perdas de energia, resultando em um desempenho mais econômico e sustentável.

Os transformadores desempenham um papel crucial na eficiência do transporte e distribuição de eletricidade em diversas aplicações, incluindo redes de energia, sistemas industriais e dispositivos eletrônicos. A otimização da eficiência dos transformadores é crucial para promover a eficiência energética em sistemas elétricos, contribuindo para a redução de custos operacionais e para a preservação dos recursos energéticos.

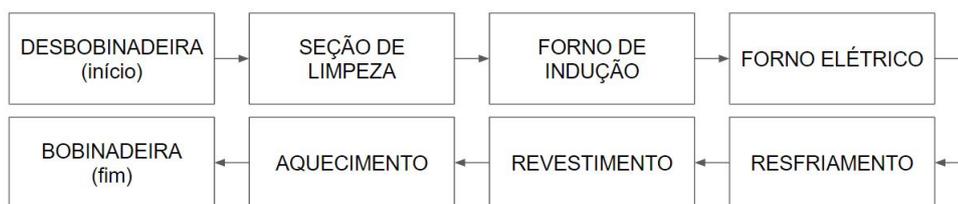
Figura 1 – Construção de transformador elétrico.



Fonte: Museu WEG de Ciência e Tecnologia.

As características eletromagnéticas dos aços elétricos começam a ser desenvolvidas a partir do controle dos processos durante a sua fabricação (NEGRI, 2012), e uma das etapas da produção de GO é o processo de descarbonetação do aço, que consiste na redução do carbono de entrada, com uma faixa entre 480 à 650 ppm, para um valor de saída menor que 30 ppm. O processo em si consiste em remover o carbono do aço através de tratamento térmico e controle de umidade no forno elétrico. O carbono é o principal elemento que leva a diminuição das propriedades magnéticas do material, devido à formação de precipitados.

Figura 2 – Etapas do processo de descarbonetação.



Fonte: Dos autores.

As etapas do processo de descarbonetação podem ser vistas no diagrama da Figura 2. O equipamento denominado Decarb, consiste em uma linha de produção contínua onde o material em forma de bobina (chapa de aço em espiral) é introduzido em uma desbobinadeira, responsável por desenrolar o material e o submeter à uma sequência de etapas para alterar suas propriedades físicas e químicas. Ao final do processo, o material é enrolado novamente através da bobinadeira.

A redução nas propriedades magnéticas de um material desempenha um papel crucial em seu desempenho global. A presença de precipitados exerce uma influência significativa, contribuindo para o aumento da força coercitiva. Esses precipitados interferem diretamente no movimento das paredes dos domínios magnéticos, resultando em um acréscimo na parcela histerética das perdas magnéticas (NEGRI, 2012). Assim, a compreensão desses mecanismos é fundamental para otimizar as propriedades magnéticas dos materiais, especialmente em contextos onde a eficiência magnética é crítica, como em aplicações industriais e na fabricação de componentes eletrônicos.

Falhas durante a retirada do carbono podem resultar em perdas magnéticas maiores, que diminuem o rendimento e a eficiência (MELQUIADES, 2006). A redução da eficiência (aumento na perda magnética) se dá devido ao fenômeno de envelhecimento magnético no produto final. O envelhecimento magnético é um termo utilizado para abordar a deterioração das prioridades magnéticas do aço elétrico. Negri *et al.* (2011) comenta que essa deterioração está associado à precipitação de carbeto e/ou nitretos, que afetam a movimentação de paredes de domínios magnéticos, aumentando a coercividade e a energia dissipada em forma de calor.

O envelhecimento magnético em aços elétricos é um fenômeno que impacta diretamente as suas propriedades magnéticas. Este processo é caracterizado pela alteração das características microestruturais do aço, resultando em alterações na orientação dos grãos magnéticos e na distribuição de defeitos cristalinos. Conforme o material envelhece, a presença de precipitados e o rearranjo dos átomos influenciam a mobilidade dos domínios magnéticos, afetando a coercitividade e a permeabilidade magnética. Essas mudanças podem resultar em perdas adicionais nas propriedades magnéticas, impactando a eficiência do material em aplicações como transformadores elétricos. O entendimento do envelhecimento magnético é crucial para otimizar a durabilidade e o desempenho dos aços elétricos e componentes dos transformadores em sistemas elétricos, garantindo a confiabilidade a longo prazo desses materiais na condução eficiente de energia.

Os valores aceitáveis de carbono após a linha de descarbonetação de GO é abaixo de 30 ppm, sendo desejável a produção de aço elétrico com valores inferiores, inibindo a formação de precipitados que deterioram as propriedades magnéticas.

Exportando os dados de processo de descarbonetação, é possível entender o comportamento de cada um dos elementos químicos presentes no material. Dessa forma, pode-se comparar a melhor composição do material, ou seja, o melhor ajuste de parâmetros de processo para obter o menor teor de carbono final.

O uso de inteligência artificial pode ser benéfico para encontrar soluções computacionais que permitam aumentar o desempenho e a qualidade dos processos industriais. Técnicas de modelagem de processo, regressão estatística e métodos de predição requerem conhecimentos específicos do processo, bem como a relação entre as variáveis de entrada e saída (BARCELOS, 2013).

O desvio por qualidade magnética na produção de GO devido ao excesso de carbono na composição, causam baixo rendimento e em alguns casos sucateamento de material. Logo a busca por métodos de otimização dos processos está diretamente ligada à qualidade do aço, isto impacta também diretamente no uso do material na fase de utilização final.

1.1 Objetivos

Este trabalho tem como objetivo principal propor um modelo de predição dos valores de carbono a partir das variáveis envolvidas no processo de descarbonetação da empresa produtora de Aços Elétricos, APERAM. Esta predição permitirá otimizar o processo de empresas siderúrgicas de aços elétricos e melhorar a qualidade da produção do aço.

Para isto, foram avaliados dois modelos de predição: (1) Redes neurais do tipo MultiLayer Perceptron (MLP) e (2) Árvores de Regressão.

O segundo objetivo deste trabalho é servir como base para outros tipos de processos industriais siderúrgicos, uma vez que a base teórica de predição pode ser replicada e as técnicas de otimização podem ser espelhadas como referência. Dessa forma, em um mesmo contexto de produção industrial a metodologia e otimização proposta ficam disponíveis podem estimular a otimização de outros processos.

1.2 Organização do trabalho

Para facilitar o entendimento a escrita deste trabalho está organizada em cinco capítulos. No Capítulo 1 e 2 é contextualizado o tipo de produção e material e sua importância no cenário mundial. Também são apresentados os objetivos deste estudo. No Capítulo 3 é descrita a base de dados e os métodos de pesquisa utilizados para o desenvolvimento dos modelos de predição. O Capítulo 4 apresenta e discute os resultados de validação do modelo proposto e sua aplicação prática. No Capítulo 5 apresentam-se as considerações finais referentes ao estudo realizado e propostas de trabalhos futuros.

2 Contextualização teórica

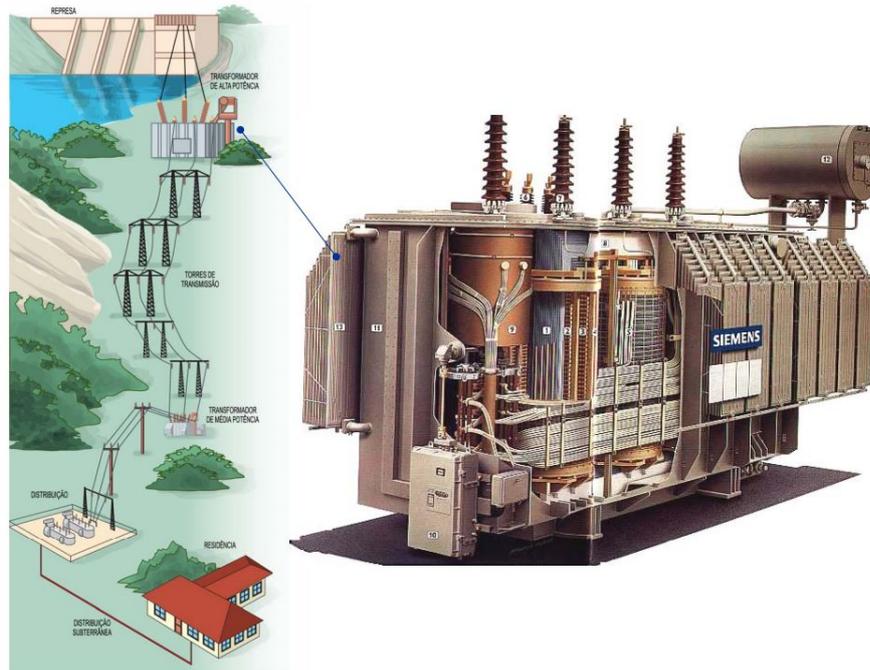
2.1 Aços elétricos

Os aços elétricos, também conhecidos como aços siliciosos devido ao principal elemento Silício (Si) presente em sua composição química, são um tipo de liga de ferro magneticamente macio, isto é, possui boa permeabilidade magnética e baixo teor de Carbono (C). A sua aplicação está diretamente relacionada ao ramo energético, indo de transformadores, motores e máquinas elétricas em geral. O aço elétrico também está presente em diversos dispositivos eletrônicos atualmente utilizados em todo o mundo, e possui a qualidade singular de concentrar linhas de campo magnético (NEGRI *et al.*, 2011).

Este aço possui a característica de não conduzir corrente elétrica, mas sim fluxo magnético, essencial para sua aplicação (BOHN *et al.*, 2004). Sua baixa permeabilidade magnética favorece a passagem do fluxo com baixas perdas, motivo pelo qual se relaciona com a eficiência dos dispositivos finais. Segundo (RODRIGUES; FREITAS,), este material possui a capacidade de amplificar em milhares de vezes o campo magnético externamente aplicado. A sua propriedade por sua vez, está relacionada com a magnetização e desmagnetização, sendo que cada vez que há essa ação, os materiais perdem energia em forma de calor.

Basicamente há duas famílias de aço elétrico denominadas "Grãos Orientados"(GO) e "Grãos Não-Orientados"(GNO). Cada uma possui uma característica fundamental para sua aplicação e funcionamento. O aço GO possui a capacidade de favorecer a passagem do fluxo magnético devido à sua acentuada anisotropia, ou seja, sua estrutura cristalográfica está alinhada em direção de laminação. Devida sua particularidade, o aço GO possui vasta utilização em núcleo de transformadores elétricos, reatores de potência, hidrogeradores e turbogeradores. Já o aço do tipo Grãos Não-Orientados (GNO), é amplamente utilizado em motores elétricos, uma vez que estes componentes possuem campo magnético girantes, que requer um material com propriedade magnética homogênea em todas as direções (AÇOS. . . ,). Para a classe do GNO, a dimensão real dos grãos na microestrutura é um fator que atua na diminuição das perdas magnéticas por histerese. Quanto menor essas perdas, mais eficiente é o material do ponto de vista eletromagnético, o que vai influenciar diretamente no melhor aproveitamento energético. O aço GNO é amplamente utilizado na fabricação de máquinas elétricas, indo de geradores hidroelétricos a compressores (RODRIGUES; FREITAS,).

Figura 3 – Transformador e sua aplicação no circuito energético.



Fonte: Arquivo Técnico ACESITA

O aço GO, preferencialmente abordado neste trabalho por se tratar do material de produção da linha de descarbonetação, apresenta uma textura pronunciada, cujos cristais estão alinhados em uma direção paralela a de laminação e ao plano de laminação, termo intitulado "Textura Goss" (SILVA, 2007). A composição química do aço GO alinhada à um controle de processo preciso nas etapas de produção, assegura excelentes propriedades magnéticas, capazes de garantir melhores resultados se tratando eficiência e economia de energia. O produto final está diretamente relacionado com a perfeita combinação de todas as etapas no processo de fabricação (CAMPOS, 2009).

2.2 Envelhecimento magnético

Apesar das características convenientes do aço elétrico que o torna amplamente utilizado, ainda existem alguns fatores ligados principalmente ao seu processo de fabricação que podem afetar suas propriedades magnéticas, influenciando na sua eficiência. Silva (2007) comenta que alguns fatores como composição, espessura de tira, tamanho do grão, tensões residuais, textura cristalográfica, precipitados e defeitos superficiais podem influenciar diretamente nas propriedades do aço.

O principal elemento presente no aço elétrico é o Silício com concentração aproximada de 3,5%. Seu papel na composição inclui o aumento da resistividade e a redução de correntes parasitas. Porém, ainda existem outros elementos que o compõe que interferem diretamente em suas propriedades, como o Carbono, Manganês, Cromo, Enxofre, entre outros. O carbono especificadamente, afeta diretamente o rendimento do aço GO devido a formação de precipitados. [Negri et al. \(2011\)](#) comentam que a presença dos precipitados de Carbono aumenta a força coerciva ao interferirem no movimento dos domínios magnéticos, aumentando a parcela histerética das perdas magnéticas.

Figura 4 – Aspectos de grão em aço elétrico GO após linha de descarbonetação.



Fonte: Dos autores.

O processo de descarbonetação, alvo deste trabalho, possui como objetivo principal a diminuição do teor de carbono através do controle das variáveis de processo: temperatura, ponto de orvalho e gases do forno. O equipamento em si é uma linha de produção contínua denominado DC1 (Decarb 1), onde o material laminado é processado e enviado posteriormente a outros processos até a entrega final para o cliente.

2.3 PCA

Os bancos de dados utilizados para otimização de processos possuem em sua maioria um grande volume de dados, muitas vezes relacionados à sua característica ou ao intervalo necessário para a análise. Este grande volume de dados mesmo pré-processados podem conter excesso de informações e variáveis correlacionáveis prejudicando a otimização, seja por dificuldade de processamento ou até erros por falta de agrupamento e identificação.

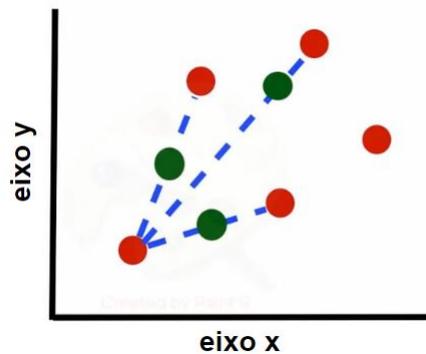
Este tipo de problema normalmente é tratado utilizando uma técnica de estatística multivariada chamada Análise de Componentes Principais. A PCA realiza uma transformação linear do espaço de variáveis, partindo de um conjunto de variáveis que inicialmente são correlacionadas entre si, para um conjunto de menor dimensão em que as variáveis não são correlacionadas entre si, mantendo a maior parte da informação do conjunto original (HONGYU; SANDANIELO; JUNIOR, 2016). A técnica da PCA procura redistribuir a variação observada nos eixos originais de forma a se obter um conjunto de eixos ortogonais não correlacionados (VARELLA, 2008). A PCA também permite detectar a existência de amostras anômalas e compreender melhor as relações entre as variáveis medidas e as relações ou agrupamentos existentes entre as amostras (LYRA *et al.*, 2010).

2.4 SMOTE

Uma base de dados se encontra desequilibrada quando os conjuntos de dados com mesma características se apresentam em proporções bem distintas. O desempenho dos algoritmos de aprendizado de máquina normalmente é avaliado usando precisão preditiva. Em uma base de dados desequilibrados, isto não é apropriado. Como exemplo, considere uma base de dados com 97 bolinhas vermelhas e 3 bolinhas rosas. Um classificador padrão adivinha a classe majoritária com uma precisão preditiva de 97%. No entanto, para a classe minoritária a aplicação exige uma taxa bastante elevada de detecção correta e exige uma taxa de erro bem menor que a classe majoritária.

Para melhorar o desempenho dos algoritmos de aprendizado de máquina, uma das técnicas utilizadas é a sobreamostragem minoritária sintética (SMOTE, do inglês *Synthetic Minority Over-sampling Technique*). Trata-se de uma técnica de pré-processamento usada para resolver um desequilíbrio de classe em um conjunto de dados. As amostras sintéticas são geradas calculando a diferença entre o vetor de características (amostra) em consideração e seu vizinho mais próximo, multiplicando essa diferença por um número aleatório entre 0 e 1 e adicionando isto ao vetor de características em consideração. Isso causa a seleção de um ponto aleatório ao longo do segmento de linha entre dois recursos específicos, conforme mostra a Figura 5, tornando a classe minoritária mais geral (CHAWLA *et al.*, 2002).

Figura 5 – Exemplo de geração de amostragem sintética através do SMOTE, onde as bolas vermelhas são dados originais e as bolas verdes são amostras sintéticas plotadas pelo "vizinho mais próximo".



Fonte: Maklin (2022).

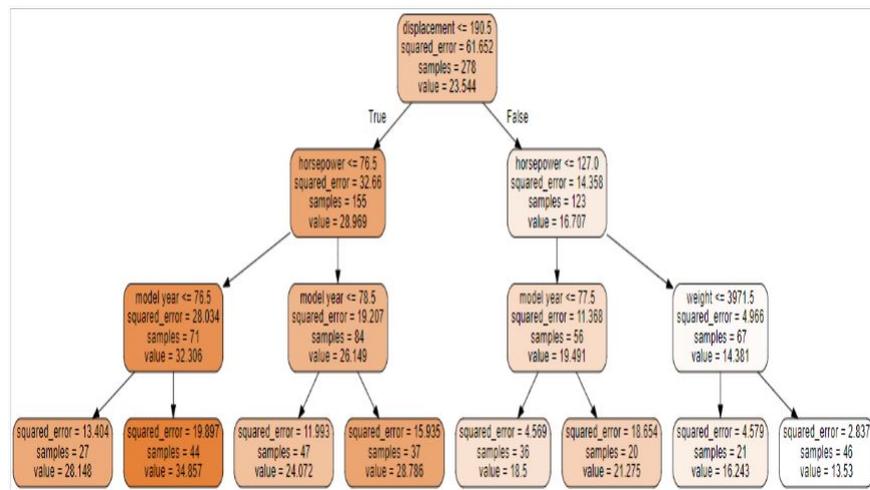
2.5 Árvore de regressão

Uma árvore de decisão é uma estrutura de dados hierárquica implementada a partir de uma estratégia de dividir para conquistar. Uma árvore de decisão é representada por grafos, que através de uma estrutura hierárquica é capaz de apontar a importância dos atributos para predição. A técnica se baseia na estrutura de uma árvore, partindo da raiz (dados de entrada) até chegar em uma folha (resultado final). Cada nó divide uma característica em duas, o objeto é confrontado com o teste associado àquele nó e o resultado do teste determina o próximo nó da travessia. Finalmente, ao chegar em uma folha, o objeto recebe um valor de acordo com uma função associada à mesma.

Regressão é um modelo de predição em que o atributo alvo é contínuo. Essa é a tarefa de aprender uma função alvo f que mapeia cada conjunto de atributos X para uma saída de valores contínuos y . Uma Árvore de regressão, utiliza uma função f para mapeada cada nó folha que contém a média dos valores de y . O objetivo é a redução do erro em cada nó até chegar a uma classe na qual o erro é mínimo, finalizando na folha da árvore, onde as classes da predição são armazenados (WINCK, 2012), conforme ilustra a Figura 6.

A vantagem em utilizar a estrutura de uma árvore de decisão é que ela não assume nenhuma distribuição particular para os dados, as características ou os atributos podem ser categóricos (qualitativos) ou numéricos (quantitativos) (LEMOS; STEINER; NIEVOLA, 2005).

Figura 6 – Exemplo de um modelo de Árvore de Regressão.



Fonte: Dos autores.

2.6 Redes neurais artificiais

2.6.1 Histórico

O ser humano ao longo de sua jornada de desenvolvimento nos processos que desencadeiam ante a atualidade, tem promovido diversas invenções, transformações e possibilidades nas quais utiliza-se do mais avançado método de registro e conexões os já existentes, o cérebro.

Moreira (2017) acredita que o termo “*homo sapiens*” deveria ser modificado para “*homo faber*”, uma vez que esta segunda opção se refere a habilidade do ser humano em produzir ou transformar matérias em outras ferramentas.

As Redes Neurais Artificiais (RNAs) são um modelo matemático não linear que se baseiam no comportamento do cérebro humano (PAIVA GABRIEL, 2016). Elas são adequadas para tratar sistemas não lineares, bem como suas indeterminações e imprevisibilidades.

A correlação do homem com as máquinas, podem ser observadas em cada parte da história, mas, existe um período em que esse avanço pode ser expandido e notado com assustadora complexidade, esse período é intitulado como revolução industrial, que teve início na Inglaterra no século XVIII, modificando drasticamente as relações sociais e expandindo a real intenção com a alta produtividade.

Avançando um pouco mais na história, percebemos que o homem sempre esteve em busca de uma máquina “perfeita”, que pudesse resolver problemas e oferecer soluções rápidas com base em múltiplas conexões como o cérebro humano é capaz de fazer. A terceira revolução industrial como é denominada a revolução da tecnologia, inclui os processos de redes neurais e suas capacidades de conexões baseadas nos neurônios humanos. O grande desafio é estabelecer conexões paralelas e superar as adversidades que possam ser encontradas durante o processamento dos dados, para isso a teoria das redes neurais criada por McCulloch e Pitts na década de 1940 foi um divisor de águas no que podemos conhecer pelas sinapses artificiais.

Por outro lado, a etimologia da palavra *Rede*, do latim *rete*, utilizada para definir uma estrutura que tem um padrão característico e *Neural*, do grego *nêuron*, que é relativo aos nervos, ou sistema nervoso central, reúne em um único significado, muito peculiar. No cenário atual da Ciência de Dados, as Redes Neurais Artificiais emergiram como uma ferramenta essencial para a resolução de problemas complexos. Inspiradas pelo funcionamento do cérebro humano, essas redes têm a capacidade de aprender a partir de dados e realizar tarefas que variam desde classificação até previsão.

O modelo de uma RNA é composto por camadas interconectadas de neurônios artificiais, que por sua vez são inspirados nos neurônios biológicos do cérebro humano. O modelo do neurônio artificial foi proposto no trabalho de McCulloch e Pitts (1943), como um sistema que realiza a soma ponderada das entradas e aplica uma não linearidade, correspondente ao disparo ou não do neurônio, para gerar a saída (CHRISTIANO; HERNÁNDEZ; CHRISTIANO, 2011). Desta forma, as redes são capazes de aprender padrões e relações complexas a partir de dados de entrada, tornando-as especialmente adequadas para tarefas como reconhecimento de padrões, classificação, regressão e processamento de linguagem natural.

Quanto aos principais autores na área de redes neurais, nomes como Geoffrey Hinton, Yann LeCun e Yoshua Bengio se destacam. Eles foram pioneiros na revitalização das redes neurais profundas com a introdução de arquiteturas como as redes neurais convolucionais (CNNs) e as redes neurais recorrentes (RNNs), que revolucionaram a área de aprendizado profundo.

2.6.2 Perceptron

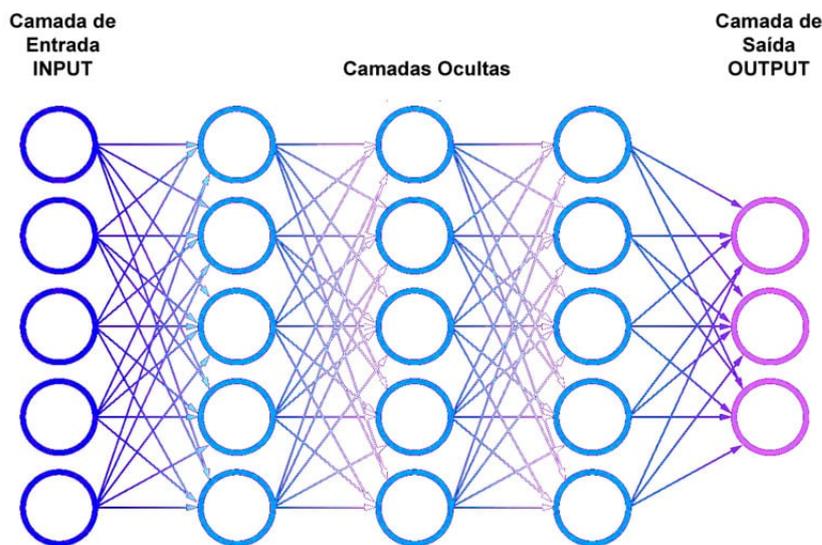
O Perceptron pode ser entendido como a rede neural mais básica, desempenhando um papel crucial. O Perceptron é capaz de realizar tarefas de classificação binária. Ele foi concebido pelo psicólogo e cientista da computação Frank Rosenblatt, na década de 1950. O Perceptron consiste em uma ou mais entradas, pesos associados a essas entradas, uma função de ativação e uma saída. Sua operação é inspirada na forma como um neurônio biológico funciona. Em seu núcleo, um Perceptron recebe entradas ponderadas, soma essas entradas e aplica uma função de ativação para gerar uma saída binária (geralmente 0 ou 1). Para que funcione corretamente, as redes neurais possuem características específicas, sendo assim cada ligação tem um peso, um valor numérico, associado a ela. O processo de aprendizado é associado à alteração desses pesos.

Enquanto o Perceptron é limitado a resolver problemas linearmente separáveis, as MLPs podem lidar com problemas não lineares, graças às suas múltiplas camadas e capacidade de aprendizado de características hierárquicas. Elas se tornaram uma das arquiteturas de rede neural mais amplamente utilizadas em aprendizado de máquina e ciência de dados devido à sua flexibilidade e poder de representação (RAUBER, 2005).

2.6.3 MLP

A rede neural do tipo MLP (Multi-Layer Perceptron) é composta por várias camadas de neurônios. A estrutura clássica de uma MLP consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada neurônio em uma camada está conectado a todos os neurônios da camada seguinte, formando assim uma rede densamente conectada. Os parâmetros de uma MLP incluem os pesos das conexões entre os neurônios, os vieses de cada neurônio, a função de ativação utilizada em cada camada e o número de neurônios em cada camada oculta, juntamente com outros hiperparâmetros como a taxa de aprendizado e o número de épocas de treinamento. O ajuste dos parâmetros irá determinar o desempenho da MLP em tarefas de aprendizado supervisionado.

Figura 7 – Exemplo de rede neural com camadas ocultas.



Fonte: HostMídia (2024)

A função de ativação é uma função matemática aplicada a cada neurônio em uma rede neural artificial. Ela determina se um neurônio deve ser ativado com base no cálculo da soma ponderada das entradas (AGUIAR; MESTRANDO, 2010). Em outras palavras, a função de ativação controla se um neurônio deve transmitir seu sinal de entrada para a próxima camada da rede neural.

A função de ativação é crucial para introduzir não linearidades nas operações da rede, permitindo que ela aprenda e modele relações complexas e não lineares nos dados (LAWRENCE, 1993).

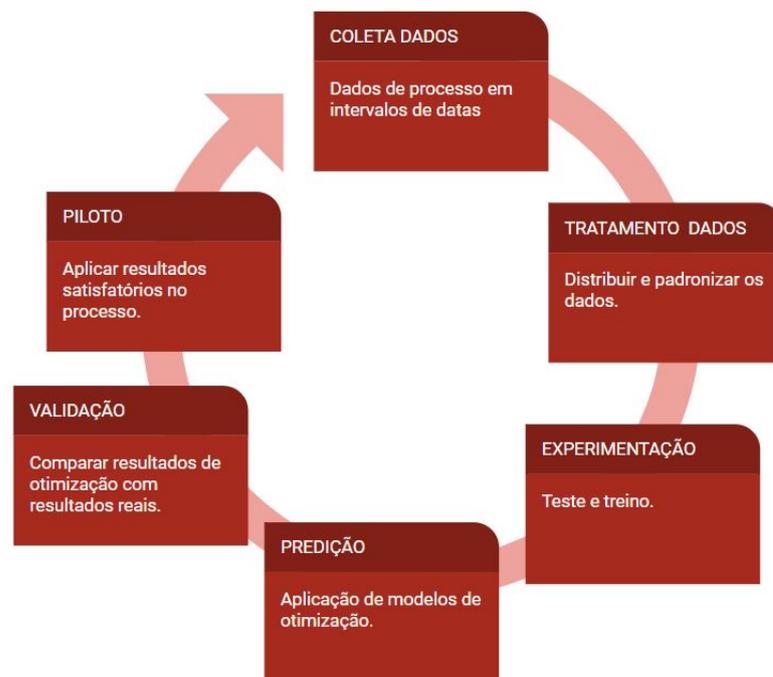
A definição da arquitetura é crucial na aplicação de redes MLP, uma vez que a topologia tem um impacto significativo na capacidade de processamento da rede. Dependendo do ajuste dos parâmetros, uma rede com poucas conexões pode não ser capaz de resolver a tarefa (YAMAZAKI, 2004). Desta forma, como a função de ativação, o método de otimização utilizado teve grande influência no modelo proposto. A otimização é responsável por ajustar os pesos da rede neural durante o processo de treinamento, de modo a minimizar uma função de custo definida. Durante cada época de treinamento, o método de otimização calcula o gradiente da função de custo em relação aos pesos da rede. Esse gradiente indica a direção e a magnitude da mudança necessária nos pesos para reduzir a função de custo. A partir daí, o método de otimização atualiza os pesos da rede usando uma forma de gradiente descendente, que pode ser estocástica (SGD), adaptativa (Adam, RMSprop) ou baseada em momentos (momentum). A taxa de aprendizado, que determina a magnitude das atualizações dos pesos, é um hiperparâmetro crítico que pode ser fixo ou adaptado dinamicamente pelo método de otimização ao longo do treinamento. A escolha do método de otimização e da taxa de aprendizado pode influenciar significativamente a convergência do treinamento, a estabilidade da rede e a qualidade dos modelos resultantes (AZEVEDO *et al.*, 2020).

3 Metodologia

Neste Capítulo é abordado o método utilizado durante o trabalho, bem como os instrumentos de coleta de dados e suas particularidades relacionadas ao processo siderúrgico ao qual este trabalho quer otimizar.

Os dados primários da linha de produção, conforme já citado anteriormente, foram utilizados com o objetivo de prever o resultado de carbono da saída no equipamento com base nas variáveis de processo coletadas por unidade de processamento na linha de descarbonetação, onde será verificado em cada bobina processada as variáveis de processo co-relacionadas com as variáveis de processo de cada bobina, de forma a prever os resultados na saída.

Figura 8 – Diagrama da metodologia adotada.



Fonte: Dos autores.

A metodologia utilizada se inicia com a coleta de dados (1) no sistema integrado de produção (SIP). Em seguida, é realizado o processamento dos dados, isto é, tratamento dos dados coletados (2), permitindo que posteriormente sejam experimentados em treinamento e teste (3). A otimização (4) é aplicada com a utilização de duas técnicas, sendo Árvore de Regressão e Redes Neurais. Em seguida, realizada a validação para verificar a técnica de melhor performance (5). Após a conclusão, o modelos pode ser testado (6) fisicamente no processo. A Figura ?? ilustra o ciclo da metodologia adotada para este trabalho.

3.1 Base de dados

Os dados utilizados para este trabalho foram coletados utilizando um sistema integrado de produção, que armazena histórico detalhado de cada material processado. Com a intenção de obter um resultado mais preciso, considerando várias bobinas processadas na linha de descarbonetação da produção de aços elétricos GO na espessura de 0,27 mm. Os dados foram exportados em um período de 2 anos, iniciando-se em dezembro de 2020 e fechando em janeiro de 2023. Considera-se também que neste espaço de tempo, não foram realizadas nenhuma alteração consideráveis no equipamento, garantindo a confiança nos resultados de processo.

Para formulação do modelo de previsão do carbono de saída, é necessário um tratamento dos dados coletados ao longo de 2 anos na linha de descarbonetação, separados por classe de espessura, onde é utilizado um sistema de tratamento de dados (predição, normalização, etc) em um software com linguagem Python. O banco de dados é composto de 126 variáveis do tipo contínuo, sendo vinte e duas referente a composição química conforme mostrado na Tabela 1, doze referente a parâmetros de entrada conforme mostrado na Tabela 2, trinta e cinco referente ao processo de aquecimento da tira conforme mostrado na Tabela 3 e cinquenta e seis referente a a atmosfera do forno conforme mostrado na Tabela 4, esses dados foram utilizados para a predição do carbono de saída.

Tabela 1 – Dados da composição química.

Nº	Variável	Tipo de dados	Nº	Variável	Tipo de dados
1	Carbono Entrada (C)	Contínuo	12	Nióbio (NB)	Contínuo
2	Manganês (MN)	Contínuo	13	Boro (B)	Contínuo
3	Silício (SI)	Contínuo	14	Titânio (TI)	Contínuo
4	Fósforo (P)	Contínuo	15	Estanho (SN)	Contínuo
5	Enxofre (S)	Contínuo	16	Cálcio (CA)	Contínuo
6	Cromo (CR)	Contínuo	17	Al+Ti	Contínuo
7	Níquel (NI)	Contínuo	18	MN/S	Contínuo
8	Molibdênio (MO)	Contínuo	19	Cr+Ni+Mo	Contínuo
9	Alumínio (AL)	Contínuo	20	Nitrogênio Aciaria (N2)	Contínuo
10	Cobre (CU)	Contínuo	21	Nitrogênio Entrada (N2_entr)	Contínuo
11	Vanádio (V)	Contínuo	22	Nitrogênio Estequiométrico (N(esteq.))	Contínuo

Tabela 2 – Dados de entrada da linha de descarbonetação (DC1).

Nº	Variável	Tipo de dados	Nº	Variável	Tipo de dados
1	Velocidade (VEL MIN)	Contínuo	7	Ampareagem da escova 4 (A_ESC4)	Contínuo
2	Tempo Estoque	Contínuo	8	Ampareagem da escova 5 (A_ESC5)	Contínuo
3	Ampareagem da escova 1 (A_ESC1)	Contínuo	9	Ampareagem da escova 6 (A_ESC6)	Contínuo
4	Ampareagem da escova 2 (A_ESC2)	Contínuo	10	Pressão bomba escovamento 2 (P_SEC14)	Contínuo
5	Ampareagem da escova 3 (A_ESC3)	Contínuo	11	Ampareagem da escova 7 (A_ESC7)	Contínuo
6	Pressão bomba escovamento 2 (P_SEC1)	Contínuo	12	Ampareagem da escova 8 (A_ESC8)	Contínuo

Os dados amostrados foram exportados inicialmente em formato Excel (.csv), e depois tratados utilizando técnicas de tratamento de dados no Python através do Google Colab. A quantidade total de amostras foi de 5918 para 131 variáveis, reduzindo-se para 61 variáveis após o tratamento de dados utilizando PCA (análise de componentes principais), uma vez que algumas dessas variáveis não eram relevantes para a otimização proposta.

Tabela 3 – Variáveis de aquecimento da linha de descarbonetação (DC1).

Nº	Variável	Tipo de dados	Nº	Variável	Tipo de dados
1	Potencia do Forno de Indução (P_FI)	Contínuo	19	Descarbonetação MV da Zona 5 (MV_Z5)	Contínuo
2	Temperatura da Descarbonetação Zona 1 (DZ1)	Contínuo	20	Descarbonetação MV da Zona 6 (MV_Z6)	Contínuo
3	Temperatura da Descarbonetação Zona 2 (DZ2)	Contínuo	21	Descarbonetação MV da Zona 7 (MV_Z7)	Contínuo
4	Temperatura da Descarbonetação Zona 3 (DZ3)	Contínuo	22	Descarbonetação MV da Zona 8 (MV_Z8)	Contínuo
5	Temperatura da Descarbonetação Zona 4 (DZ4)	Contínuo	23	Descarbonetação MV da Zona 9 (MV_Z9)	Contínuo
6	Temperatura da Descarbonetação Zona 5 (DZ5)	Contínuo	24	Nitretação MV da Zona 1 (MV_Z1N)	Contínuo
7	Temperatura da Descarbonetação Zona 6 (DZ6)	Contínuo	25	Nitretação MV da Zona 2 (MV_Z2N)	Contínuo
8	Temperatura da Descarbonetação Zona 7 (DZ7)	Contínuo	26	Nitretação MV da Zona 3 (MV_Z3N)	Contínuo
9	Temperatura da Descarbonetação Zona 8 (DZ8)	Contínuo	27	Nitretação MV da Zona 4 (MV_Z4N)	Contínuo
10	Temperatura da Descarbonetação Zona 9 (DZ9)	Contínuo	28	Temperatura 1 Ref. Lento(LFS_DC1_TE4911_1)	Contínuo
11	Temperatura Pirômetro Zona 1 (PR DZ1)	Contínuo	29	Temperatura 2 Resf. Lento(LFS_DC1_TE4911_2)	Contínuo
12	Temperatura Pirômetro Zona 4 (PR DZ4)	Contínuo	30	Temperatura 1 Resf. Rápido(LFS_DC1_TE5611_1)	Contínuo
13	Temperatura Pirômetro Zona 6 (PR DZ6)	Contínuo	31	Temperatura 2 Resf. Rápido(LFS_DC1_TE5612_1)	Contínuo
14	Temperatura Pirômetro Zona 9 (PR DZ9)	Contínuo	32	Temperatura 1 Turbina 1(LFS_DC1_TE5690_1_1)	Contínuo
15	Descarbonetação MV da Zona 1 (MV_Z1)	Contínuo	33	Temperatura 2 Turbina 1 (LFS_DC1_TE5690_3_1)	Contínuo
16	Descarbonetação MV da Zona 2 (MV_Z2)	Contínuo	34	Temperatura 1 Turbina 2(LFS_DC1_TE5690_1_2)	Contínuo
17	Descarbonetação MV da Zona 3 (MV_Z3)	Contínuo	35	Temperatura 2 Turbina 2(LFS_DC1_TE5690_3_2)	Contínuo
18	Descarbonetação MV da Zona 4 (MV_Z4)	Contínuo	<i>Temperatura 1 = Entrada, Temperatura 2 = Saída</i>		

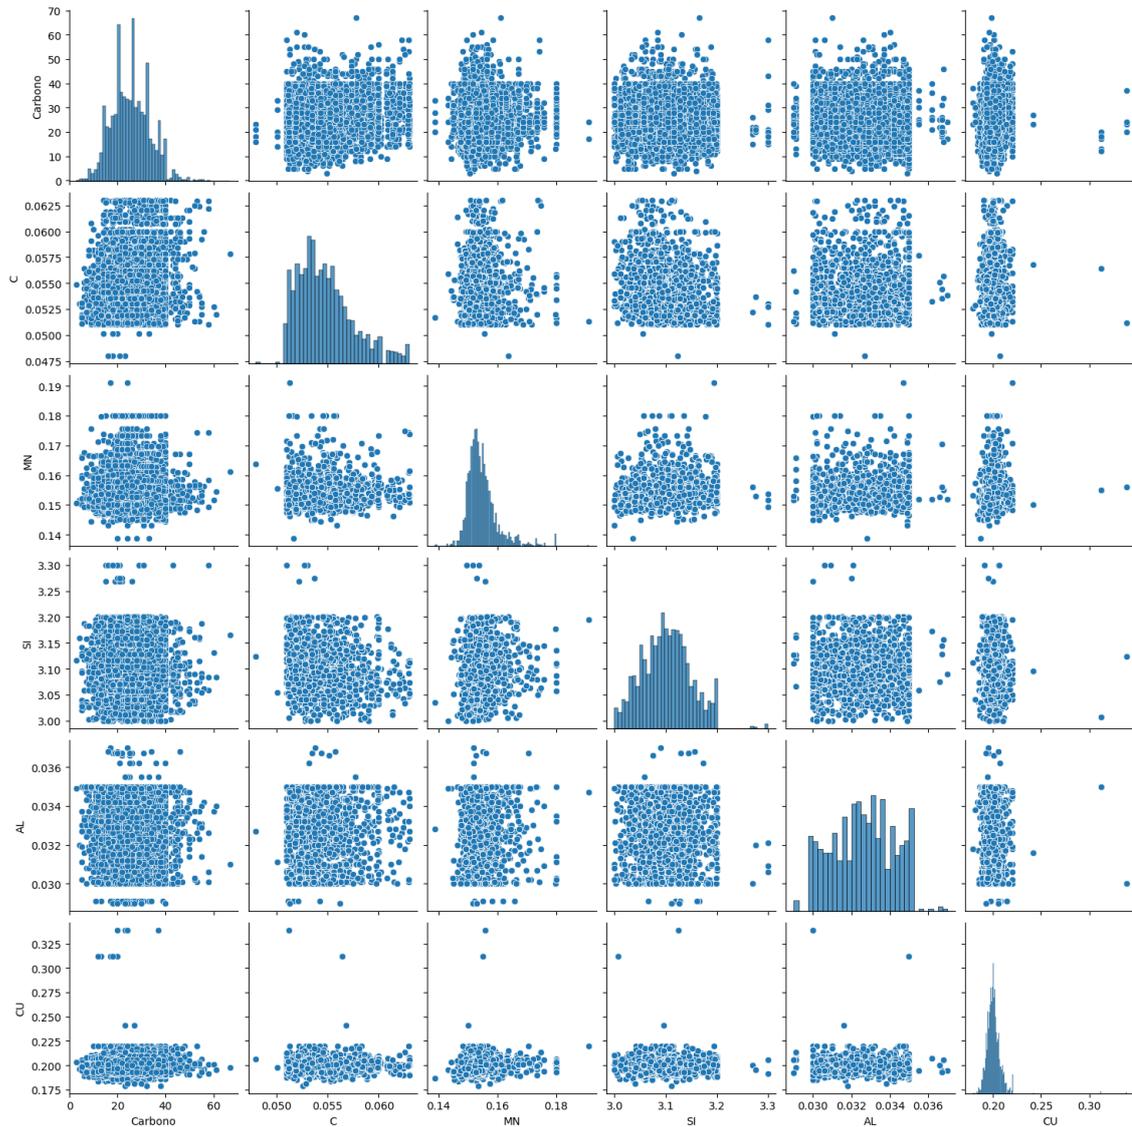
Tabela 4 – Variáveis da atmosfera da linha de descarbonetação (DC1).

Nº	Variável	Tipo de dados	Nº	Variável	Tipo de dados
1	Pressão Zona 2 (PV P Z2)	Contínuo	29	Temperatura do Umificador 3 (T UM03)	Contínuo
2	Pressão Selo 1 (PV P S1)	Contínuo	30	Vazão de Hidrogênio Umificador 1(V H2 1)	Contínuo
3	MV do Selo 1 (MV P S1)	Contínuo	31	Vazão de Hidrogênio Umificador 2(V H2 2)	Contínuo
4	Pressão da Nitretação (PN)	Contínuo	32	Vazão de Hidrogênio Umificador 3(V H2 3)	Contínuo
5	Pressão do Selo 2 (PV P S2)	Contínuo	33	Vazão de Hidrogênio do Resfriamento (V H2 R)	Contínuo
6	MV do Selo 2 (MV P S2)	Contínuo	34	Vazão de Nitrogênio Umificador 1(V N2 1)	Contínuo
7	Pressão da Zona Seca (P ZS)	Contínuo	35	Vazão de Nitrogênio Umificador 2(V N2 2)	Contínuo
8	Pressão do Selo 3(PV P S3)	Contínuo	36	Vazão de Nitrogênio Umificador 3(V N2 3)	Contínuo
9	MV do Selo 3 (MV P S3)	Contínuo	37	Vazão de Nitrogênio do Resfriamento (V N2 R)	Contínuo
10	Pressão do Resfriamento Lento (PRL)	Contínuo	38	Vazão de Hidrogênio Nitretação (V H2 FN)	Contínuo
11	Pressão do Resfriamento Rápido (PR RR)	Contínuo	39	Vazão de Nitrogênio Nitretação(V N2 FN)	Contínuo
12	Pressão do Selo de Saída (PS)	Contínuo	40	Vazão de Amonia (V NH3 FN)	Contínuo
13	Teor de Hidrogênio da Zona 4 (H2 DZ4)	Contínuo	41	Vazão de Hidrogênio Zona Seca (V H2 ZS)	Contínuo
14	Teor de Hidrogênio da Zona 6(H2 DZ6)	Contínuo	42	Vazão de Nitrogênio Zona Seca (V N2 ZS)	Contínuo
15	Teor de Hidrogênio da Zona 8 (H2 DZ8)	Contínuo	43	Vazão de Nitrogênio Portão de Saída (V N2 P)	Contínuo
16	Teor de Hidrogênio da Nitretação(H2N)	Contínuo	44	Vazão de Nitrogênio Resfriamento (V N2 JCS)	Contínuo
17	Teor de Hidrogênio da Zona Seca (H2 ZS)	Contínuo	45	Pressão de H20 Descarbonetação Zona 4 (A1)	Contínuo
18	Teor de Hidrogênio Resfriamento Lento (H2 RL)	Contínuo	46	Pressão de H20 Descarbonetação Zona 6 (A2)	Contínuo
19	Teor de Hidrogênio Resfriamento Rápido (H2 RR)	Contínuo	47	Pressão de H20 Descarbonetação Zona 8 (A3)	Contínuo
20	Ponto de Orvalho da Zona 4 (PO DZ4)	Contínuo	48	Pressão de H20 Nitretação Zona 1 (A4)	Contínuo
21	Ponto de Orvalho da Zona 6 (PO DZ6)	Contínuo	49	Pressão de H20 Nitretação Zona 4 (A5)	Contínuo
22	Ponto de Orvalho da Zona 8 (PO DZ8)	Contínuo	50	pH20/pH2 Descarbonetação Zona 4 (A6)	Contínuo
23	Ponto de Orvalho da Nitretação Zona 1 (PO NZ1)	Contínuo	51	pH20/pH2 Descarbonetação Zona 6 (A7)	Contínuo
24	Pontode Orvalho da Nitretação Zona 4 (PO NZ4)	Contínuo	52	pH20/pH2 Descarbonetação Zona 8 (A8)	Contínuo
25	Ponto de Orvalho da Zona Seca (PO ZS)	Contínuo	53	pH20/pH2 Nitretação Zona 1 (A9)	Contínuo
26	Pontode Orvalho do Resfriamento Lento (PO RL)	Contínuo	54	pH20/pH2 Nitretação Zona 4 (A10)	Contínuo
27	Temperatura do Umificador 1 (T UM01)	Contínuo	55	Pressão Turbina 1(LFS_DC1_PI5690_6_1)	Contínuo
28	Temperatura do Umificador 2 (T UM02)	Contínuo	56	Pressão Turbina 2(LFS_DC1_PI5690_6_2)	Contínuo

3.2 Análise exploratória dos dados

Esses dados coletados foram tratados estatisticamente, de forma a avaliar quais são os melhores parâmetros de processamento para cada material. São dados primários extraídos *in-loco* no sistema produtivo de aços elétricos de grão orientados no equipamento de descarbonetação, juntamente com as variáveis de composição química do produto.

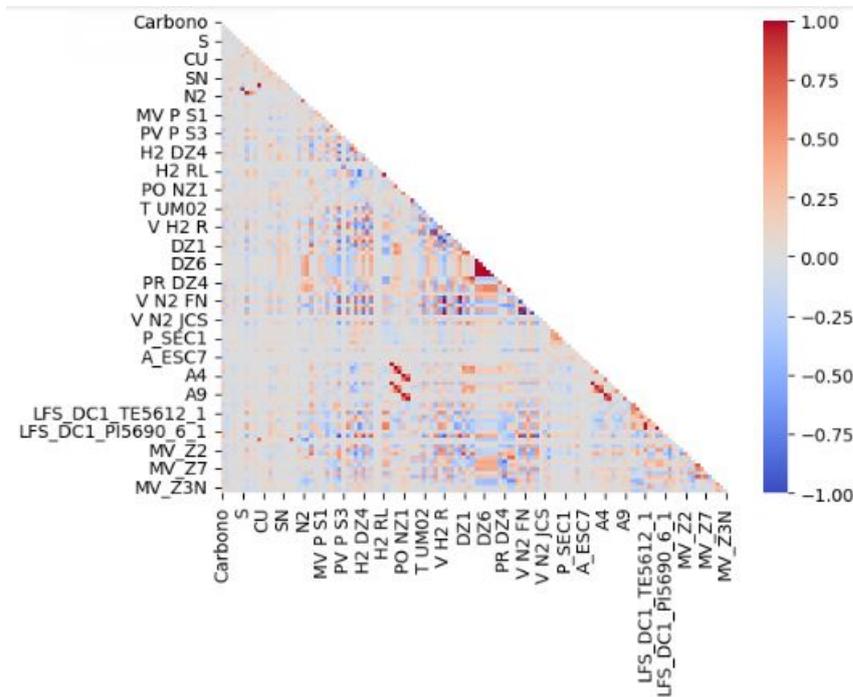
Figura 9 – Análise estatística Seaborn.



Fonte: Dos autores.

Na Figura 9 é apresentada a análise estatística realizada utilizando a ferramenta de visualização de dados estatísticos Seaborn. É possível avaliar a correlação entre os elementos e o resultado final. Ao examinar os dados, torna-se evidente a ausência de uma relação significativa entre o carbono e os outros elementos, destacando a necessidade de um tratamento mais aprofundado dos dados. Na Figura 10 foi realizado a correlação entre as variáveis de entrada e o resultado de carbono de saída, bem como se havia correlação entre as variáveis de entrada. Foi identificado a ocorrência de correlação positiva e negativa entre algumas variáveis, sendo aplicado a técnica de redução de dimensão PCA.

Figura 10 – Correlação entre as variáveis e o carbono de saída.



Fonte: Dos autores.

Após uma análise minuciosa dos dados apresentados no gráfico estatístico da Figura 9 e no banco foi constatada uma considerável variação nos valores de "ppm"(partes por milhão). Com o propósito de compreender e categorizar esses valores, visando um posterior balanceamento ideal, adotamos um algoritmo simples para classificar os valores de ppm de Carbono em faixas percentuais conforme Figura 12. Esse procedimento possibilitou uma melhor observação da variância presente nos dados. A Figura 13 mostra as diversas faixas de valores percentuais identificadas, destacando que a faixa mais frequente compreendia os valores entre 20 e 30 ppm, os quais representavam 46,01% do total. Esse detalhamento das faixas percentuais foi crucial para uma compreensão da distribuição dos valores.

Após a identificação das faixas de distribuição dos valores de ppm do Carbono, adotamos a técnica SMOTE (*Synthetic Minority Over-sampling Technique*) como parte do processo de análise. A SMOTE é uma abordagem que visa aumentar a amostragem das classes minoritárias em conjuntos de dados desbalanceados, mitigando o risco de sobreajuste nos modelos de aprendizado de máquina (CHAWLA *et al.*, 2002). Esta técnica gera exemplos sintéticos próximos aos pontos existentes pertencentes à classe minoritária no espaço de características, promovendo assim um melhor equilíbrio dos dados e possibilitando uma análise mais precisa e representativa. A Figura 14, demonstra o código adotado para implementação.

Figura 11 – Resultados da variação explicada para cada componente principal.

Componente principal	Variação explicada (%)
C1	32.24
C2	14.05
C3	12.01
C4	6.72
C5	4.63
C6	2.94
C7	2.59
C8	2.12
C9	1.88
C10	1.34
C11	1.30
C12	1.19
C13	1.08
C14	0.98
TOTAL	85.07

Fonte: Dos autores.

Figura 12 – Algoritmo para separação das faixas de ppm de Carbono.

```
# Criando uma função para gerar uma faixa de carbono no banco de dados

def Faixa_C(DadosDC1):
    obs = []

    if DadosDC1['Carbono'] <= 10:
        obs = "F01"
    elif DadosDC1['Carbono'] > 10 and DadosDC1['Carbono'] <=20:
        obs = "F02"
    elif DadosDC1['Carbono'] > 20 and DadosDC1['Carbono'] <=30:
        obs = "F03"
    elif DadosDC1['Carbono'] > 30 and DadosDC1['Carbono'] <=40:
        obs = "F04"
    else:
        obs = "F05"
    return obs

# Acrescentado a faixa de carbono no banco
DadosDC1['Faixa_C']=DadosDC1.apply(Faixa_C, axis=1)
```

Fonte: Dos autores.

Para o modelo de MLP proposto, a estratégia de validação foi estabelecida em 30%, o que significa que 30% dos dados foram reservados para avaliar o desempenho do modelo após o treinamento. No entanto, os parâmetros de treinamento e teste não foram especificamente definidos. Isso sugere que os dados não foram divididos em conjuntos de treinamento e teste distintos ou que a validação cruzada não foi empregada.

Figura 13 – Distribuição da faixa de carbono de saída no banco de dados original.

```
F01: 1.61% - Carbono menor ou igual a 10 ppm
F02: 25.87% - Carbono entre 10 e 20 ppm
F03: 46.01% - Carbono entre 20 e 30 ppm
F04: 24.21% - Carbono entre 30 e 40 ppm
F05: 2.30% - Carbono maior que 40 ppm

Total de amostra da base (5918,)
```

Fonte: Dos autores.

Figura 14 – Algoritmo de implementação da técnica SMOTE.

```
[ ] # Separando as variavel de entrada e saída do banco
X = DadosDC1
X = X.drop(["Faixa_C"],axis=1)
Y = DadosDC1["Faixa_C"]

[ ] from imblearn.combine import SMOTETomek
X2 = X
Y2 = Y
X_resampled, y_resampled = SMOTETomek().fit_resample(X2, Y2)
X_resampled.shape

(12969, 127)

[ ] Y3 = pd.DataFrame(y_resampled)
X3 = pd.DataFrame(X_resampled, columns = X2.columns)
```

Fonte: Dos autores.

3.3 Pré-processamento

A produção de aço em uma indústria siderúrgica envolve diversos processos até a conclusão e entrega final do material para o cliente. Estes processos em muitos casos são extremamente complexos e envolvem o controle de muitas variáveis em equipamentos diferentes. Com o tempo, estes processos foram evoluindo, buscando cada vez mais a integração de todas as variáveis e a busca por qualidade, agilidade e sustentabilidade, o que levou a implementação de sistemas de controle de processo, possibilitando o domínio e gestão da produção como um todo. Estes sistemas de controle de processos não são necessariamente estruturados para permitir que os dados possam ser utilizados em outros modos, portanto, muitas vezes os arquivos extraídos possuem excesso de informação, formatação inadequada, erros de codificação, grande número de casas decimais, entre muitos outros aspectos. Deve-se comentar também que nem todos os sistemas possuem possibilidades configuráveis para extração, não permitindo a opção de filtro das informações pertinentes.

Num estudo específico a respeito de dados em aprendizado de máquinas, o autor (BATISTA, 2003) comenta que “*dados extraídos diretamente de sistemas de gerenciamento de dados frequentemente apresentam diversos problemas, tais como: grande quantidade de ruído e inconsistências; excesso de valores desconhecidos; classes desbalanceadas, ou seja, uma grande desproporção entre as distribuições das classes; entre outros.*” Portanto, entende-se que o pré-processamento de dados é uma das etapas mais importantes na busca de soluções para a indústria utilizando a ciência de dados, crucial para garantir uma mineração adequada que mantenha as informações úteis para o resultado final esperado. Deve ser considerado, portanto, que uma boa representação de documentos tem uma influência fundamental no desempenho dos algoritmos de aprendizado (MARTINS,2003).

Figura 15 – Banco de dados descarbonização.

	DTH_F	UM	Carbono	C	MN	SI	P	S	CR	NI	...	MV_Z4	MV_Z5	MV_Z6	MV_Z7	MV_Z8	MV_Z9	MV_Z1N	MV_Z2N	MV_Z3N	MV_Z4N	
0	02/07/2021 17:03	NXZCY1	16	0.0589	0.1644	31.019	0.0068	0.0066	0.0190	0.0024	...	37.29	32.87	38.98	43.08	44.38	41.65	14.42	15.26	19.22	15.65	
1	02/07/2021 19:50	NYBUF1	17	0.0528	0.1496	30.644	0.0065	0.0064	0.0169	0.0012	...	37.36	33.26	39.07	43.46	45.05	41.88	13.95	14.36	19.33	14.71	
2	03/07/2021 07:05	NYBXX2	22	0.0531	0.1506	30.816	0.0078	0.0078	0.0160	0.0021	...	39.02	33.25	38.35	43.49	44.20	40.80	15.02	14.50	20.86	16.10	
3	03/07/2021 09:30	NYBY11	16	0.0545	0.1504	30.614	0.0095	0.0089	0.0206	0.0025	...	38.82	33.55	38.92	44.00	44.21	41.82	15.11	15.56	20.43	15.20	
4	03/07/2021 14:00	NYCRB1	30	0.0589	0.1507	31.149	0.0063	0.0074	0.0139	0.0013	...	38.74	32.92	38.29	43.23	44.54	41.00	15.40	16.74	18.03	14.14	
...
4391	30/05/2022 11:33	PDQSF2	40	0.0620	0.1527	30.725	0.0070	0.0074	0.0212	0.0039	...	33.62	31.30	36.95	43.02	41.56	42.21	13.23	17.41	18.76	15.69	
4392	30/05/2022 13:30	PDRSB1	45	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	...	34.03	31.28	37.51	43.03	41.07	41.71	14.09	17.90	18.10	16.38	
4393	30/05/2022 14:45	PDRSB2	39	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	...	34.99	32.07	38.61	43.37	41.39	42.61	13.90	17.78	17.38	17.04	
4394	30/05/2022 16:09	PDSYC1	44	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	...	34.59	32.16	38.76	43.59	41.98	43.09	13.73	17.43	17.25	17.07	
4395	30/05/2022 17:22	PDSYC2	39	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	...	36.89	33.59	40.41	45.51	43.83	44.88	13.32	17.58	17.32	15.72	

4396 rows x 113 columns

Fonte: Dos autores.

Abordando especificamente este trabalho, o banco de dados proposto em formato “.csv”, possui em cada linha o código de um material de produção (bobina em aço) que passou em um determinado dia e horário no equipamento de descarbonização, conforme representado na Figura 16. As colunas, por sua vez, representam a composição química detalhada do material, representadas em forma quantificada. O trabalho de pré-processamento dos dados foi então organizado basicamente em duas etapas: limpeza (remoção de dados não úteis para a otimização) e a normalização.

Figura 16 – Banco de dados pré-processado.

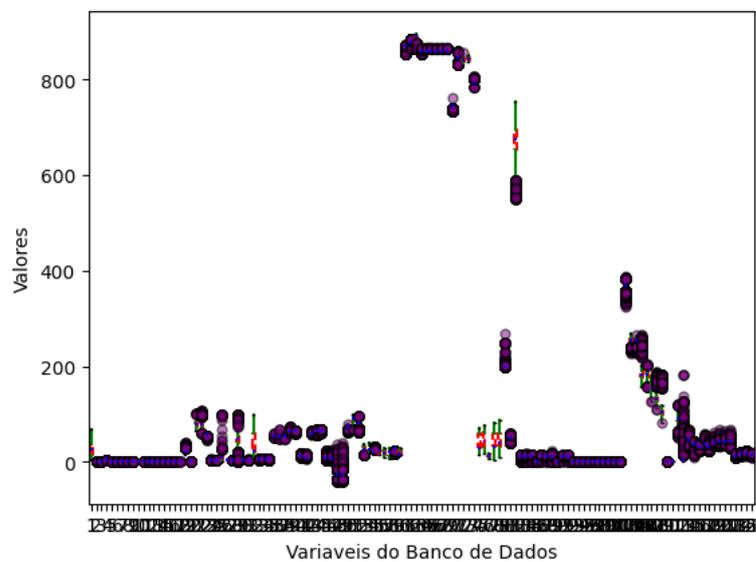
	C	MN	SI	P	S	CR	NI	MO	AL	CU	...	MV_Z4	MV_Z5	MV_Z6	MV_Z7	MV_Z8	MV_Z9	MV_Z1N	MV_Z2N	MV_Z3N	MV_Z4N	
0	0.0589	0.1644	31.019	0.0068	0.0066	0.0190	0.0024	0.0090	0.0303	0.2031	...	37.29	32.87	38.98	43.08	44.38	41.65	14.42	15.26	19.22	15.65	
1	0.0528	0.1496	30.644	0.0065	0.0064	0.0169	0.0012	0.0085	0.0319	0.2108	...	37.36	33.26	39.07	43.46	45.05	41.88	13.95	14.36	19.33	14.71	
2	0.0531	0.1506	30.816	0.0078	0.0078	0.0160	0.0021	0.0087	0.0340	0.1946	...	39.02	33.25	38.35	43.49	44.20	40.80	15.02	14.50	20.86	16.10	
3	0.0545	0.1504	30.614	0.0095	0.0089	0.0206	0.0025	0.0089	0.0324	0.1986	...	38.82	33.55	38.92	44.00	44.21	41.82	15.11	15.56	20.43	15.20	
4	0.0589	0.1507	31.149	0.0063	0.0074	0.0139	0.0013	0.0085	0.0335	0.1979	...	38.74	32.92	38.29	43.23	44.54	41.00	15.40	16.74	18.03	14.14	
...
4391	0.0620	0.1527	30.725	0.0070	0.0074	0.0212	0.0039	0.0090	0.0324	0.2105	...	33.62	31.30	36.95	43.02	41.56	42.21	13.23	17.41	18.76	15.69	
4392	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	0.0090	0.0345	0.2004	...	34.03	31.28	37.51	43.03	41.07	41.71	14.09	17.90	18.10	16.38	
4393	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	0.0090	0.0345	0.2004	...	34.99	32.07	38.61	43.37	41.39	42.61	13.90	17.78	17.38	17.04	
4394	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	0.0090	0.0345	0.2004	...	34.59	32.16	38.76	43.59	41.98	43.09	13.73	17.43	17.25	17.07	
4395	0.0607	0.1544	30.737	0.0062	0.0075	0.0178	0.0031	0.0090	0.0345	0.2004	...	36.89	33.59	40.41	45.51	43.83	44.88	13.32	17.58	17.32	15.72	

4396 rows x 110 columns

Fonte: Dos autores.

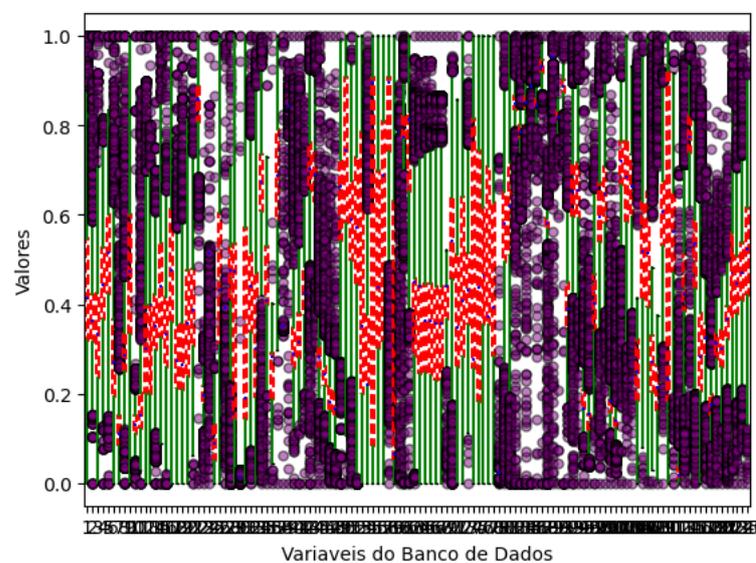
Uma das primeiras tarefas na etapa de limpeza do pré-processamento de dados identificada ao iniciar o trabalho, foi a identificação das colunas que não necessariamente seriam úteis para a otimização, como código de bobina, data e horário. Da mesma forma, foram identificados e removidos todos os dados vazios (em branco). Utilizando as bibliotecas “*numpy*”, “*scipy*”, os dados foram normalizados na etapa 2, (Método de transformação linear que busca mapear o conjunto de observações de cada uma das variáveis no intervalo [0,1]) e os resultados antes e depois podem ser visualizados através das figuras 17 e 18, que nos mostra o box plot de cada variável utilizada, cujo o objetivo é trazer a variabilidade das variáveis para uma mesma escala.

Figura 17 – Boxplot das variáveis com dados originais.



Fonte: Dos autores.

Figura 18 – Boxplot das variáveis após normalização de dados.



Fonte: Dos autores.

O pré-processamento de dados é, como comentado anteriormente, uma das principais fases para otimização de processos através de ciência de dados.

Figura 19 – Algoritmo da etapa de análise de componentes principais.

```
from sklearn.decomposition import PCA
pca=PCA()
X=df_std.to_numpy()
pca.fit(X)
X_pca=pca.transform(X)

for i, pve in enumerate (pca.explained_variance_ratio_):
    print(f'c_{i +1} : {pve*100:.2f}')
```

Fonte: Dos autores.

3.4 Árvore de regressão

A árvore de regressão foi escolhida devido à sua facilidade de implementação computacional. Este modelo oferece uma abordagem intuitiva e simples para prever valores numéricos com base em variáveis de entrada. Sua estrutura de árvore divide o conjunto de dados em subconjuntos menores, tomando decisões com base em características específicas, o que facilita a interpretação dos resultados. Além disso, a capacidade da árvore de lidar com dados tanto quantitativos quanto qualitativos a torna uma escolha versátil em diversas áreas.

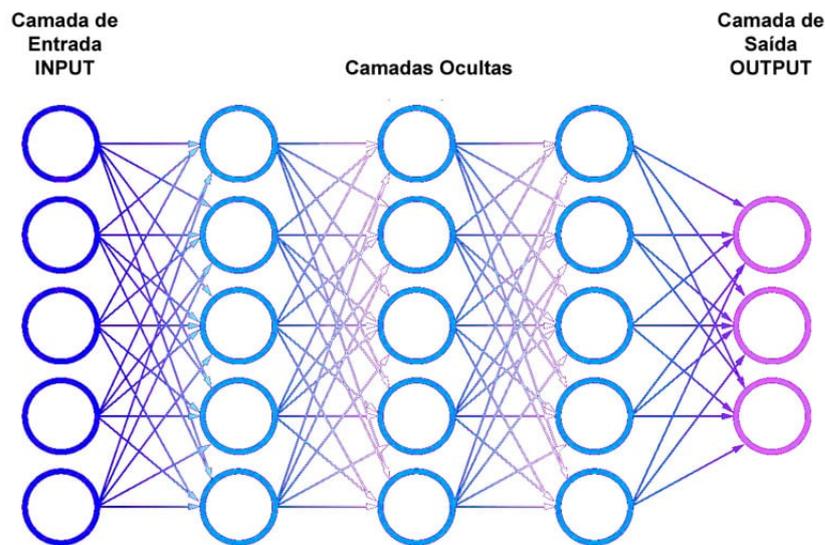
Para o modelo proposto em árvore de regressão linear, foram fixadas as condições de número de amostras por folha em 5 e variada a profundidade da árvore, aumentando gradualmente em incrementos de 20 até atingir uma profundidade de 160. Essa estratégia de ajuste de hiperparâmetros permitiu explorar diferentes níveis de complexidade do modelo, desde estruturas mais rasas até modelos mais profundos e intrincados. Ao fixar o número de amostras por folha, garantiu-se que cada folha da árvore contivesse um número mínimo de observações, o que ajudou a controlar a complexidade do modelo e mitigar problemas de sobreajuste. Essa abordagem sistemática possibilitou uma exploração abrangente do espaço de hiperparâmetros, resultando em compreensões significativas sobre o desempenho do modelo em relação à sua capacidade de generalização e interpretabilidade.

3.5 Redes neurais artificiais

As Redes Neurais Artificiais (RNAs) são um modelo matemático não linear que se baseiam no comportamento do cérebro humano (PAIVA GABRIEL, 2016). Elas são adequadas para tratar sistemas não lineares, bem como suas indeterminações e imprevisibilidades.

A função de ativação é crucial para introduzir não linearidades nas operações da rede, permitindo que ela aprenda e modele relações complexas e não lineares nos dados (LAWRENCE, 1993).

Figura 20 – Exemplo de rede neural com camadas ocultas.



Fonte: [HostMídia \(2024\)](#)

Para este trabalho, foram testadas as funções de ativação do tipo: Elu (*Exponential Linear Unit*), Linear, Tanh (Tangente Hiperbólica) e Sigmoid (Função Logística).

A definição da arquitetura é crucial na aplicação de redes MLP, uma vez que a topologia tem um impacto significativo na capacidade de processamento da rede. Dependendo do ajuste dos parâmetros, uma rede com poucas conexões pode não ser capaz de resolver a tarefa ([YAMAZAKI, 2004](#)). Desta forma, como a função de ativação, o método de otimização utilizado teve grande influência no modelo proposto. A otimização é responsável por ajustar os pesos da rede neural durante o processo de treinamento, de modo a minimizar uma função de custo definida. Durante cada época de treinamento, o método de otimização calcula o gradiente da função de custo em relação aos pesos da rede. Esse gradiente indica a direção e a magnitude da mudança necessária nos pesos para reduzir a função de custo. A partir daí, o método de otimização atualiza os pesos da rede usando uma forma de gradiente descendente, que pode ser estocástica (SGD), adaptativa (Adam, RMSprop) ou baseada em momentos (momentum). A taxa de aprendizado, que determina a magnitude das atualizações dos pesos, é um hiperparâmetro crítico que pode ser fixo ou adaptado dinamicamente pelo método de otimização ao longo do treinamento. A escolha do método de otimização e da taxa de aprendizado pode influenciar significativamente a convergência do treinamento, a estabilidade da rede e a qualidade dos modelos resultantes ([AZEVEDO et al., 2020](#)).

4 Resultados

Para realizar o modelo preditivo de carbono na saída da linha de descarbonetação do aço GO, foram projetados duas técnicas de predição: Árvore de Regressão e Rede Neural MLP. Para ambas as técnicas a base de dados foi balanceada através da técnica SMOTE, considerando os valores por faixas de concentração de carbono, conforme mostra a Figura 21. A base de dados foi particionada aleatoriamente em dois conjuntos, sendo 70% das amostras para treinamento (9066 amostras) e 30% para teste (3891 amostras). A métrica adotada foi o Erro Médio Absoluto (MAE), que retorna o valor absoluto médio da diferença entre o valor predito e o valor real.

Figura 21 – Distribuição da faixa de carbono de saída no banco de dados balanceado.

```

F01: 21.02% - Carbono menor ou igual a 10 ppm
F02: 19.70% - Carbono entre 10 e 20 ppm
F03: 18.49% - Carbono entre 20 e 30 ppm
F04: 19.77% - Carbono entre 30 e 40 ppm
F05: 21.02% - Carbono maior que 40 ppm

Total de amostra da base (12957, 1)

```

Fonte: Dos autores.

4.1 Árvore de regressão

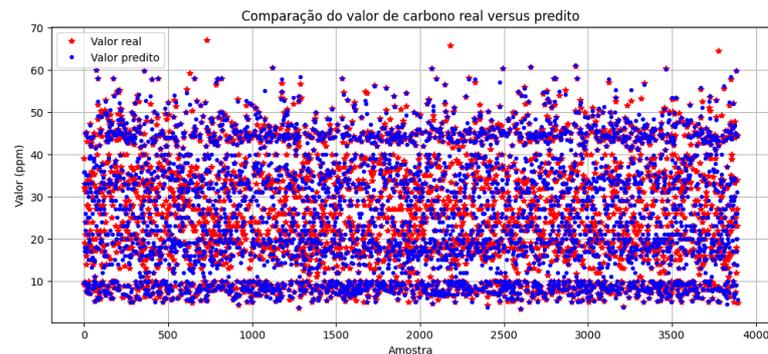
Na implementação da técnica de Árvore de Regressão utilizou-se o banco de dados com os 126 parâmetros originais. Foram realizados 4 conjuntos de testes, conforme mostrado na Tabela 5. O sistema foi processado por 10 vezes considerando partições aleatórias, em cada condição foi calculado o erro médio absoluto, sendo o resultado final a média das 10 repetições.

Tabela 5 – Resultados obtidos com Árvore de Regressão.

Modelo	Parâmetros			MAE
	Nº Amostras	Profundidade		
1	5	20		3.66
2	5	40		3.50
3	5	80		3.52
4	5	160		3.54
5	-	-		3.34

Da Tabela 5 se observa que as profundidades aplicadas na AR deste trabalho não aprimorou o desempenho da predição, ao retirar os limites do número de amostras por folha e a profundidade da AR o desempenho melhorou em aproximadamente 4%, reduzindo o MAE de 3,47 pra 3,32. Na Figura 22 é apresentado o resultado obtido aplicando a técnica de predição por Árvore de Regressão, apesar de apresentar um MAE considerado satisfatório pelos especialistas da área, observam-se alguns pontos que apresentam erros relevantes, que seriam intoleráveis para o processo.

Figura 22 – Comparação entre o valor real e o predito usando Árvore de Regressão.



Fonte: Dos autores.

4.2 Redes neurais MLP

Na implementação da técnica de redes neurais do tipo MLP, foi reduzida a dimensão do banco de variáveis através do PCA, passando de 126 parâmetros para 61 parâmetros. Foram construídos 4 modelos de testes conforme apresentado na Tabela 6.

Tabela 6 – Modelo de teste.

Modelo	Parâmetros da RNA		
	Cam. Entr.	Nº Cam. Oculta	Nº Parâmetros
1	150	2	29501
2	150	3	52151
3	300	4	104001
4	300	8	195946

A rede MLP utilizada neste trabalho utilizou o otimizador Adam (*Adaptive Moment Estimation*) e foi aplicado o Erro Quadrático Médio (MSE) como função de perda para medir a diferença entre a resposta correta e a retornada pelo algoritmo.

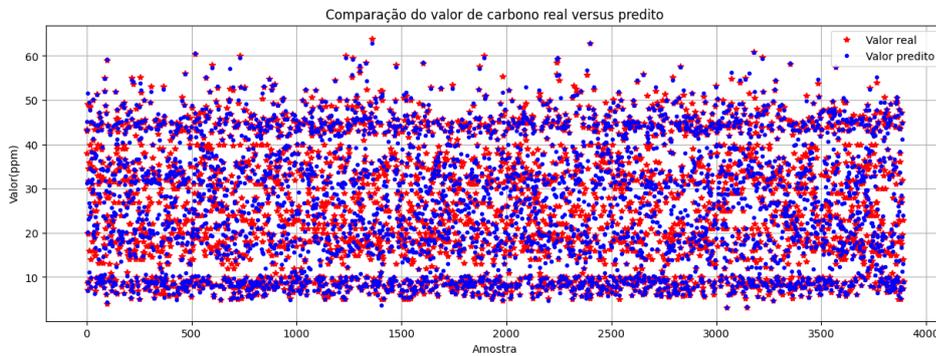
Os resultados de teste dos modelos são apresentados na Tabela 7. Observa-se que o modelo 3 se estabilizou com 800 épocas e os modelos 1, 2 e 4 obtiveram melhores resultados com 1600 épocas. Na comparação de desempenho entre os 4 modelos observa-se que para os modelos 2, 3 e 4 não há diferença significativa após 1600 épocas.

Tabela 7 – MSE observado para cada modelo preditivo usando MLP.

Interações	Modelo 1	Modelo 2	Modelo 3	Modelo 4
100	2,66	2,40	2,33	2,19
200	2,47	2,22	2,12	2,03
400	2,19	1,93	1,88	1,98
800	2,14	1,91	1,84	2,11
1600	1,96	1,81	1,84	1,82

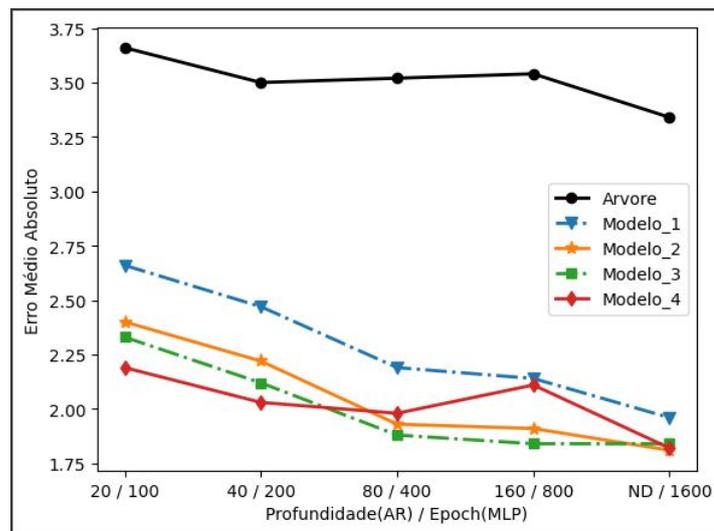
Os resultados obtidos pela técnica de Redes Neurais foi melhor que os obtidos com a Árvore de Regressão, mesmo o modelo mais simples apresentou desempenho melhor. Comparando a Figura 23, referente ao modelo 2 com 1600 épocas, com a Figura 22 observa-se uma menor variação no erro de predição.

Figura 23 – Comparação entre o valor real e o predito usando rede MLP.



Fonte: Dos autores.

Figura 24 – Comparação entre os valores de Erro Médio Absoluto da Árvore de Regressão para as profundidades testadas e os modelos da Rede Neural MLP em cada número de épocas treinadas.



Fonte: Dos autores.

Levando-se em conta que o objetivo do trabalho é desenvolver um modelo que minimize o desvio de produto, desta forma a técnica de Redes Neurais apresentou a melhor solução, dentre as técnicas testadas, para predição de carbono final do aço GO na linha de descarbonetação e modelo 2 apresentou melhor desempenho conforme Figura 24, com erro 1,81 ppm.

5 Conclusão

Este trabalho teve como meta desenvolver um modelo de previsão do teor de carbono pré-processamento na linha de descarbonetação do aço GO, visando reduzir a produção de produtos não conformes. Um dos desafios significativos na produção de aço GO é assegurar um baixo teor de carbono na saída da linha de descarbonetação. Para alcançar esse objetivo, foram aplicadas técnicas de redes neurais MLP, permitindo uma abordagem mais precisa e eficaz na previsão do teor de carbono antes do processo de descarbonetação.

Foram avaliados diversos parâmetros utilizando tanto a abordagem de árvore de regressão quanto redes neurais do tipo MLP. Entre as várias configurações testadas, o melhor desempenho alcançado foi de um Erro Médio Absoluto (MAE) de 3,34 ppm utilizando a Árvore de Regressão, enquanto a rede MLP obteve um MAE de 1,81 ppm.

O resultado apresentado pela MLP é promissor e atende as necessidades do processo, uma vez que o MAE do modelo é inferior ao erro de medição do aparelho de análise carbono que é de 2,00 ppm. Vale ressaltar que este trabalho focou-se somente na predição do carbono em função da matéria prima e parâmetros de processo.

O objetivo principal do estudo era desenvolver um modelo de fácil implementação utilizando a técnica da árvore de regressão. No entanto, os resultados obtidos não alcançaram as expectativas estabelecidas, uma vez que o erro observado foi significativamente superior ao que era esperado. Essa discrepância entre os resultados esperados e os resultados reais ressalta a complexidade do problema em questão e sugere que outras abordagens ou técnicas de modelagem podem ser necessárias para obter previsões mais precisas e confiáveis.

Para trabalhos futuros é recomendado a utilização de modelos de Redes Neurais integrado ao processo de forma a definir e configurar os parâmetros de melhor desempenho do equipamento em função da matéria prima garantindo um melhor resultado final. Além disso, um estudo desenvolvendo novos modelos de predição com foco em otimizar o resultado global do produto bem como a integração de variáveis de todas as variáveis ao longo do fluxo produtivo do aço GO.

Referências

- AGUIAR, E.; MESTRANDO, M. Teste de nao-linearidade em séries temporais utilizando método de poda em redes mlp. **Proceedings Seminário Interno da disciplina de Redes Neurais Artificiais**, Citeseer, p. 148, 2010.
- ALCÂNTARA, F. L. d.; CUNHA, M. A. d. Estudo da recristalização secundária do aço silício de grão orientado. **Tecnologia em Metalurgia, Materiais e Mineração**, ABM-Associação Brasileira de Metalurgia, Materiais e Mineração, v. 2, n. 3, p. 32–36, 2013.
- AZEVEDO, V. R. d. *et al.* Identificação do perfil de clientes utilizando redes neurais convolucionais. Universidade do Estado do Rio de Janeiro, 2020.
- Aços elétricos - Engenheiro de Materiais — engenheirodemateriais.com.br. <<https://engenheirodemateriais.com.br/2017/09/27/acos-eletricos/#:~:text=A%20classe%20de%20a%C3%A7os%20para,otimizadas%20em%20uma%20dire%C3%A7%C3%A3o%20espec%C3%ADfica.>> [Accessed 29-09-2023].
- BARCELOS, G. B. Previsão de temperatura de bobinamento de aços laminados a quente utilizando redes neurais artificiais. Universidade Federal de Minas Gerais, 2013.
- BOHN, F.; GÜNDEL, A.; SEVERINO, A.; LANDGRAF, F.; SOMMER, R. Propriedades magnéticas de aços elétricos de grão não-orientado. In: **Anais do XVI Congresso Brasileiro de Engenharia e Ciências dos Materiais**. [S.l.: s.n.], 2004. p. 85.
- CAMPOS, A. A. Desenvolvimento de escória sintética sinterizada para produção de aços elétricos de grão orientado (go). Universidade Federal de Minas Gerais, 2009.
- CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. Smote: synthetic minority over-sampling technique. **Journal of artificial intelligence research**, v. 16, p. 321–357, 2002.
- CHRISTIANO, D.; HERNÁNDEZ, M. I. M.; CHRISTIANO, P. L. Redes neurais em análises de qualidade de água. **Revista de Biologia e Ciências da Terra**, Universidade Estadual da Paraíba, v. 11, n. 1, p. 147–156, 2011.
- HONGYU, K.; SANDANIELO, V. L. M.; JUNIOR, G. J. de O. Análise de componentes principais: resumo teórico, aplicação e interpretação. **E&S Engineering and science**, v. 5, n. 1, p. 83–90, 2016.
- HOSTMÍDIA. **O que é Deep Learning**. 2024. <<https://www.hostmidia.com.br/blog/deep-learning>>. [Accessed 14-02-2024].
- LAWRENCE, J. **Introduction to neural networks**. [S.l.]: California Scientific Software, 1993.
- LEMO, E. P.; STEINER, M. T. A.; NIEVOLA, J. C. Análise de crédito bancário por meio de redes neurais e árvores de decisão: uma aplicação simples de data mining. **Revista de Administração-RAUSP**, Universidade de São Paulo, v. 40, n. 3, p. 225–234, 2005.

- LYRA, W. d. S.; SILVA, E. C. d.; ARAÚJO, M. C. U. d.; FRAGOSO, W. D.; VERAS, G. Classificação periódica: um exemplo didático para ensinar análise de componentes principais. **Química Nova**, SciELO Brasil, v. 33, p. 1594–1597, 2010.
- MAKLIN, C. Synthetic minority over-sampling technique (smote). **Medium**, mar 2022. <https://medium.com/@corymaklin/synthetic-minority-over-sampling-technique-smote-7d419696b88c>: :text=SMOTE
- MELQUIADES, S. dos R. O efeito do carbono no aumento do tamanho de grão e nas propriedades magnéticas de aços elétricos semiprocessados após recozimento final. **Escola Politécnica-USP, Tese (Mestrado)-Programa de Pós- graduação em Engenharia Metalúrgica, São Paulo-SP**, p. 21, 2006.
- MOREIRA, R. Uma ciência das práticas e saberes espaciais. **Revista Tamoios**, v. 13, n. 2, 2017.
- NEGRI, G. M. Estudo de caso de envelhecimento magnético em aços elétricos de grão não orientado. **Departamento de Pesquisa e Desenvolvimento da Whirlpool/Embraco S.A., Joinville**, p. 4, 2012.
- NEGRI, G. M. R. *et al.* Estudo de caso de envelhecimento magnético em aços elétricos de grão não orientado de baixa eficiência. Florianópolis, SC, 2011.
- PAIVA GABRIEL, B. M. H. Estudo de redes neurais artificiais para reconhecimento de padrões. **PET Engenharia Elétrica**, mar 2016. UFC.
- RAUBER, T. W. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, v. 29, 2005.
- RODRIGUES, D. de A.; FREITAS, F. N. C. Avaliação da recristalização e sua influência no desempenho de um aço elétrico de grão não orientado (gno).
- SILVA, M. d. C. A. d. **Avaliação da textura e da microestrutura de deformação de um aço elétrico GNO com 1, 25% de Si laminado a frio**. Tese (Doutorado) — Universidade de São Paulo, 2007.
- TOLMASQUIM, M. T. Perspectivas e planejamento do setor energético no Brasil. **Estudos avançados**, SciELO Brasil, v. 26, p. 247–260, 2012.
- VARELLA, C. A. A. Análise de componentes principais. **Seropédica: Universidade Federal Rural do Rio de Janeiro**, p. 38, 2008.
- WINCK, A. T. 3d-tri: Um algoritmo de indução de árvore de regressão para propriedades tridimensionais-um estudo sobre dados de docagem molecular considerando a flexibilidade do receptor. Pontifícia Universidade Católica do Rio Grande do Sul, 2012.
- YAMAZAKI, A. Uma metodologia para otimização de arquiteturas e pesos de redes neurais. Universidade Federal de Pernambuco, 2004.