



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



Detecção de Formação de Gaiolas no Alto-forno 2

Davidson Estole Rodrigues
Douglas Vinícius Ferreira de Castro
Matheus Augusto Santos Vieira

João Monlevade, MG
2024

Davidson Estole Rodrigues
Douglas Vinícius Ferreira de Castro
Matheus Augusto Santos Vieira

Detecção de Formação de Gaiolas no Alto-forno 2

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

2024

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

V658d Vieira, Matheus Augusto Santos.
Detecção de formação de gaiolas no alto-forno 2. [manuscrito] /
Matheus Augusto Santos Vieira. Davidson Estole Rodrigues. Douglas
Vinícius Ferreira de Castro. - 2024.
30 f.: il.: color., gráf., tab..

Orientador: Dr. Harlei Miguel de Arruda Leite.
Produção Científica (Especialização). Universidade Federal de Ouro
Preto. Departamento de Engenharia de Produção.

1. Altos-fornos. 2. Inteligência artificial. 3. Redes neurais
(Computação). 4. Siderurgia. 5. Sistemas de reconhecimento de padrões.
I. Castro, Douglas Vinícius Ferreira de. II. Rodrigues, Davidson Estole. III.
Leite, Harlei Miguel de Arruda. IV. Universidade Federal de Ouro Preto. V.
Título.

CDU 004.8

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



FOLHA DE APROVAÇÃO

Davidson Estole Rodrigues
Douglas Vinícius Ferreira de Castro
Matheus Augusto Santos Vieira

Detecção de Formação de Gaiolas no Alto-forno 2

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 30 de janeiro de 2024

Membros da banca

Dr. Harlei Miguel de Arruda Leite - Orientador - Instituto Tecnológico de Aeronáutica
Dr. Thiago Augusto de Oliveira Silva - Universidade Federal de Ouro Preto
Me. Péricles Guimarães Oliveira Aguiar - Aperam South America

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 19/02/2024



Documento assinado eletronicamente por **Thiago Augusto de Oliveira Silva, PROFESSOR DE MAGISTERIO SUPERIOR**, em 11/03/2024, às 11:31, 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 **0677360** e o código CRC **EF1F95F2**.

Resumo

Redes neurais são modelos computacionais inspirados no funcionamento do cérebro humano. Compostas por unidades chamadas neurônios artificiais, essas redes são capazes de aprender padrões e realizar tarefas complexas, como reconhecimento de padrões, classificação e previsão. Esse trabalho tem como objetivo criar uma ferramenta capaz de detectar a formação de gaiolas no Alto-forno 2 da Aperam através da identificação e compreensão das principais variáveis do processo e definição da técnica mais eficaz para lidar com elas. Nos altos-fornos, que são reatores responsáveis pela produção do ferro gusa, problemas como entupimentos, obstruções e reduções da velocidade de descida de carga podem ter impactos significativos na eficiência operacional e na produção de ferro gusa. Manter o alto forno em operação contínua e minimizar interrupções é crucial para o processo metalúrgico. Através da utilização da Rede Neural Convolutiva (CNN) capaz de realizar o reconhecimento de padrões auxiliando na resolução de problemas sistêmicos do processo foi possível construir um modelo que retira a subjetividade operacional da detecção das gaiolas na produção de gusa. Assim, para o objetivo de criação de um modelo capaz de detectar a formação das gaiolas, através da utilização do modelo de CNN, foi obtido uma acurácia de aproximadamente 90%, suficiente para o problema tratado.

Palavras-chaves: Alto-forno. Gaiola. Rede neural. Sonda. CNN.

Abstract

Neural networks are computational models inspired by the functioning of the human brain. Composed by units called artificial neurons, these networks can learn patterns and perform complex tasks, such as pattern recognition, classification, and prediction. This work aims to create a tool capable of detecting the formation of cages in Blast Furnace 2 at Aperam by identifying and understanding the key process variables and defining the most effective technique to deal with them. In blast furnaces, which are reactors responsible for pig iron production, issues such as blockages, obstructions, and reductions in the descent rate of the burden can have significant impacts on operational efficiency and pig iron production. Maintaining continuous blast furnace operation and minimizing interruptions is crucial for the metallurgical process. Through the use of Convolutional Neural Network (CNN) capable of pattern recognition to assist in resolving systemic process issues, it was possible to build a model that removes operational subjectivity from cage detection in pig iron production. Thus, for the purpose of creating a model capable of detecting cage formation, using the CNN model achieved an accuracy of approximately 90%, sufficient for the addressed problem.

Keywords: Blast Furnace. Cage. Neural Network. Probe. CNN.

Lista de ilustrações

Figura 1 – As zonas no alto-forno.	1
Figura 2 – Descida de carga de um alto-forno.	2
Figura 3 – Formação de gaiola e arriamento de carga em um alto-forno.	2
Figura 4 – Processo de Produção de Aço.	4
Figura 5 – Produção de aço no Brasil por tipo de usina.	5
Figura 6 – Fluxos no interior do alto-forno.	6
Figura 7 – Reações químicas de redução do minério de ferro.	7
Figura 8 – Alto-forno 2 da Aperam Timóteo.	7
Figura 9 – Sondagem e descida de carga do Alto-forno 2.	8
Figura 10 – Criação de vazios em um alto-forno.	9
Figura 11 – Formação de gaiola e arriamento de carga no Alto-forno 2.	9
Figura 12 – Sonda de Carga de Alto-forno.	14
Figura 13 – Resumo dos dados de trabalho e média das sondas.	19
Figura 14 – Medição das sondas do Alto-forno 2.	19
Figura 15 – Medição filtrada das sondas do Alto-forno 2.	20
Figura 16 – Classificação das medições da sonda.	20
Figura 17 – Código do modelo.	22
Figura 18 – Sumário do modelo.	23
Figura 19 – Acurácia do modelo utilizando 100 épocas.	24
Figura 20 – Acurácia do modelo utilizando 300 épocas.	24
Figura 21 – Acurácia do modelo utilizando 600 épocas.	25
Figura 22 – Acurácia do modelo utilizando 1000 épocas.	25
Figura 23 – Heatmap do modelo utilizando 100 épocas.	26
Figura 24 – Heatmap do modelo utilizando 300 épocas.	26
Figura 25 – Heatmap do modelo utilizando 600 épocas.	27
Figura 26 – Heatmap do modelo utilizando 1000 épocas.	27

Lista de tabelas

Tabela 1 – Composição química típica do gusa do AF2 da Aperam.	5
Tabela 2 – Descrição dos instrumentos de medição da altura da carga.	14
Tabela 3 – Análise exploratória dos dados.	14
Tabela 4 – Descrição dos instrumentos de medição da perda de carga.	15
Tabela 5 – Análise exploratória dos dados.	15
Tabela 6 – Descrição dos instrumentos de medição da pressão de topo.	16
Tabela 7 – Análise exploratória dos dados.	16
Tabela 8 – Descrição dos instrumentos de medição da pressão de sopro.	16
Tabela 9 – Análise exploratória dos dados.	17
Tabela 10 – Descrição dos instrumentos de medição da temperatura de topo.	17
Tabela 11 – Análise exploratória dos dados da sonda 1.	18
Tabela 12 – Análise exploratória dos dados da sonda 2.	18


Sumário

1	INTRODUÇÃO	1
1.1	Objetivo geral	3
1.1.1	Objetivos específicos	3
2	REVISÃO DA LITERATURA	4
2.1	Processo Siderúrgico	4
2.1.1	O Alto-Forno 2 da Aperam	7
2.2	Formação de Gaiolas	8
2.3	Métodos de Detecção de Gaiolas	10
3	METODOLOGIA	12
3.1	Coleta de Dados	12
3.1.1	Nível de Sonda	13
3.1.2	Perda de Carga	14
3.1.3	Pressão de Topo	15
3.1.4	Pressão de Sopros	16
3.1.5	Temperatura de Topo	17
3.2	Pré-processamento de Dados	18
3.3	Modelo de Rede Neural	21
3.4	Treinamento do Modelo	22
4	RESULTADOS	24
5	CONCLUSÃO	29
	REFERÊNCIAS	30

1 Introdução

O alto-forno é um reator contracorrente utilizado para a produção de ferro-gusa em estado líquido, que é uma liga de Ferro-Carbono e é a principal matéria-prima para a produção de aço no mundo (CHAIGNEAU *et al.*, 2015). No caso da Aperam, dois terços da produção de aço, que se dividem em inoxidável, elétrico e carbono, necessitam dessa matéria-prima. Externamente, o alto-forno é dividido em 5 regiões: goela (throat), cuba (stack), ventre (belly), rampa (bosh) e cadinho (hearth) e internamente dividimos o alto-forno em zona granular (burden layers), zona coesiva (cohesive zone), zona de carvão ativo (active coke zone), homem morto (dead man) e raceway. A Figura 1 mostra as zona internas e externas de um alto-forno.

Figura 1 – As zonas no alto-forno.



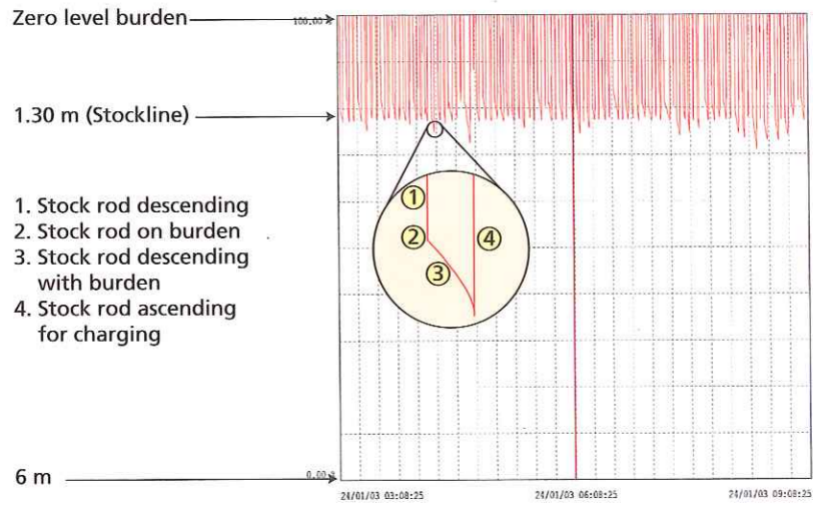
Fonte: Chaigneau *et al.* (2015).

Em um alto-forno, a carga metálica (sinter, pelota ou minério granulado), redutores (coque ou carvão vegetal) e fundentes se deslocam para baixo enquanto os gases se deslocam para cima à medida que ocorrem as reações químicas de redução do óxido de ferro passando de hematita (Fe_2O_3), para a magnetita (Fe_3O_4), em seguida para a wustita (FeO) e por fim chegando ao Fe (CHAIGNEAU *et al.*, 2015).

A Figura 2 mostra, de forma gráfica, a descida de carga medida por sondas verticais de nível superior, que se apoiam sobre a superfície dos materiais abastecidos no alto-forno.

A descida de carga estável contribui para a estabilidade do processo e, conseqüentemente, melhor desempenho em termos de produtividade e consumo de combustível. Entretanto, ocorrem distúrbios na descida de carga chamados de “gaiolas” que prejudicam a operação do alto-forno.

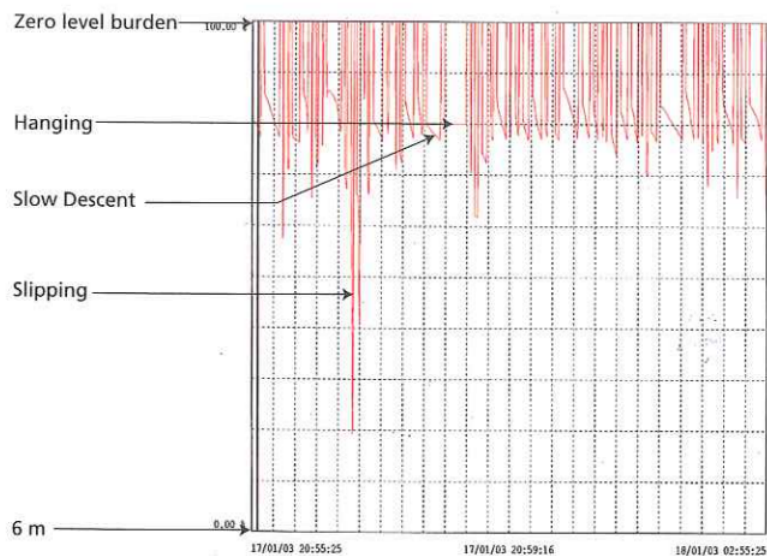
Figura 2 – Descida de carga de um alto-forno.



Fonte: Chaigneau *et al.* (2015).

As gaiolas ocorrem quando a descida de carga é interrompida ou fica lenta gerando espaços vazios no interior do alto-forno, que em seguida causam o arriamento da carga. Já os arriamentos podem ser definidos como descidas abruptas de carga que preenchem os espaços vazios gerados pelas gaiolas e sua detecção ocorre quando o nível de carga medido pelas sondas verticais apresenta um elevado delta em um curto espaço de tempo. A Figura 3 mostra a representação gráfica da formação de uma gaiola e em seguida o arriamento causado por ela.

Figura 3 – Formação de gaiola e arriamento de carga em um alto-forno.



Fonte: Chaigneau *et al.* (2015).

As gaiolas e arriamentos prejudicam a secagem das cargas na cuba superior, a condição redutora dos combustíveis, o fluxo gasoso e os parâmetros operacionais que medem o desempenho do reator, como por exemplo: a vazão de sopro, a temperatura do gusa e o rendimento gasoso.

As gaiolas alteram o fluxo gasoso no interior do alto-forno trazendo perda de rendimento gasoso e perda de nível térmico e isto reflete no consumo de redutor elevando o custo de produção. As gaiolas também impactam na produtividade, pois durante o processo de corte de gaiola é necessário reduzir a vazão de sopro, que é uma variável diretamente proporcional.

Este trabalho focaliza na automação da detecção de gaiolas, uma tarefa atualmente executada manualmente pelo operador do alto-forno, o que pode ser propenso a erros. A introdução de uma solução baseada em inteligência artificial visa proporcionar ao operador uma base mais sólida para suas decisões operacionais, contribuindo significativamente para a segurança e eficiência global do alto-forno.

1.1 Objetivo geral

Considerando a significativa influência das gaiolas como um desafio no processo do alto-forno, torna-se imperativo agilizar sua detecção, visando minimizar os potenciais impactos adversos. Atualmente, a identificação de gaiolas é conduzida por meio da interpretação de diversos parâmetros, como perda de carga, temperatura do gás de topo e leitura de sondas, dependendo, portanto, da subjetividade do operador.

Este trabalho propõe a implementação de um algoritmo de detecção automática de gaiolas, eliminando a subjetividade associada à interpretação dos parâmetros operacionais, resultando em uma percepção mais ágil e eficaz, reduzindo distúrbios no processo e mitigando impactos negativos. O objetivo geral é desenvolver uma ferramenta para identificação da formação de gaiolas no alto-forno 2.

1.1.1 Objetivos específicos

Para cumprimento do objetivo geral é necessário atender aos seguintes objetivos específicos:

- Identificar e compreender as principais variáveis relacionadas com a formação de gaiolas, considerando os fatores interligados;
- Determinar a técnica mais eficaz para lidar com as variáveis identificadas, considerando métodos existentes e desenvolvendo estratégias personalizadas.

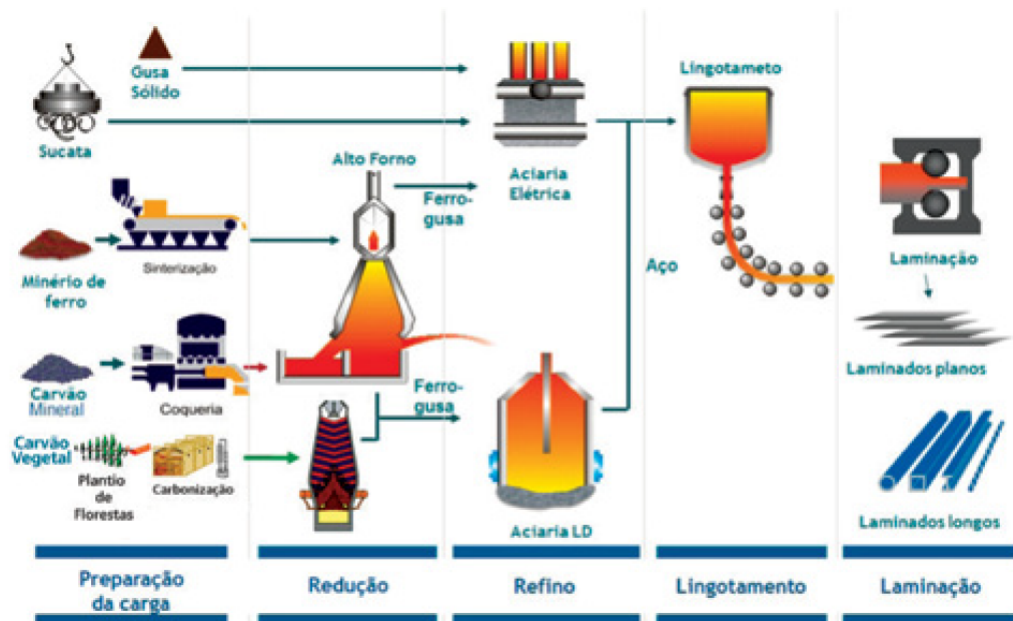
2 Revisão da Literatura

Ao considerar as principais teorias, conceitos e metodologias empregadas, esta revisão da literatura visa fornecer uma compreensão abrangente do estado atual do conhecimento sobre engaiolamentos em altos-fornos, as informações básicas para sua detecção e estabelecer as bases para a pesquisa que se segue.

2.1 Processo Siderúrgico

Existem basicamente duas rotas para produção de aço: a rota de produção integrada e a rota semi-integrada. As usinas integradas produzem aço consumindo gusa que é produzido através do consumo de minério de ferro e redutor (carvão vegetal ou coque) e por isso possuem três fases: redução, refino e laminação. As usinas semi-integradas produzem aço a partir do consumo de sucata e por isso possuem apenas duas fases: refino e laminação. A Figura 4 ilustra as rotas de produção.


Figura 4 – Processo de Produção de Aço.



Fonte: CNI (2012, p. 15).

De acordo com os dados do CNI (2017), a produção das usinas integradas corresponderam a 85,7% de produção enquanto as semi-integradas corresponderam a 14,3%, como pode ser visto na Figura 5 abaixo.

Figura 5 – Produção de aço no Brasil por tipo de usina.



Fonte: CNI (2017, p. 17).

O ferro gusa ou simplesmente gusa, é produzido em altos-fornos antes de ser enviado para as aciarias, onde corre o refino do gusa removendo elementos como enxofre, fósforo, carbono, silício e manganês. A composição química típica do gusa por ser vista na Tabela 1, formado com dados reais do Alto-forno 2 do mês de setembro de 2023 da Aperam.

Tabela 1 – Composição química típica do gusa do AF2 da Aperam.

Fe (%)	C (%)	Si (%)	Mn (%)	P (%)	S (%)	Cr (%)	Ti (%)	Al (%)
94,523	4,300	0,600	0,450	0,075	0,005	0,018	0,019	0,010

Fonte: Autores (2024).

No processo do alto-forno o minério de ferro, os redutores (coque ou carvão) e o ar atmosférico são transformados em gusa, escória e gás de alto-forno. O gusa e a escória são líquidos imiscíveis e por isso não se misturam e devido a diferença de densidade eles ficam separados no cadinho. A escória, menos densa, fica sobre o gusa, que é mais denso.


Segundo Chaigneau *et al.* (2015), um alto-forno pode ser dividido nas seguintes zonas:

- Zona Granular: formada pelas camadas de minério e redutor;
- Zona Coesiva: local onde ocorre o amolecimento e fusão dos sólidos descendentes da zona granular;
- Zona de Coque ou Carvão Ativo: local onde ocorre o gotejamento de gusa e escória em estado líquido;
- Zona de Combustão: onde ocorre a oxidação do carbono ao entrar em contato com o ar de sopro vindo das ventaneiras.

Em termos de formato, o alto-forno possui forma típica de segmentos tronco-cônicos e cilíndricos, que se dividem em: goela, cuba, ventre, rampa e cadinho.

O alto-forno é um reator em contra-corrente onde as cargas sólidas descem enquanto os gases soprados e formados sobem, como mostra a Figura 6. O ar soprado promove a queima do combustível e nesta reação química exotérmica ocorre a formação do monóxido de carbono (CO) e liberação de energia térmica. Este gás quente sobe, ele remove o oxigênio da carga sólida através de reações químicas de redução até que ocorra a fusão do ferro e dos óxidos que compõem a escória. Como vimos anteriormente, a fusão ocorre na zona de amolecimento e fusão e é nesta região onde ocorre a formação de vazios (CHAIGNEAU *et al.*, 2015).

Figura 6 – Fluxos no interior do alto-forno.




Fonte: Chaigneau *et al.* (2015).

Seguindo o caminho da carga, de cima para baixo, a carga sólida (carvão vegetal, carga metálica e fundentes) é aquecida gradualmente até que a umidade comece a evaporar. Após a secagem, iniciam-se as reações químicas de redução do óxido de ferro, passando de hematita para magnetita, de magnetita para wustita até chegarmos ao ferro metálico, quando todo o oxigênio for removido. A Figura 7 mostra as reações químicas de redução do minério de ferro.

Considerando a interação entre o gás e a carga de minério, quanto mais o gás remove oxigênio da carga metálica, mais eficiente é o processo do alto-forno. Consequentemente, o contato entre o gás e a carga de minério é muito importante. Isso significa que a carga do um alto-forno deve ser permeável para aumentar a interação. Muitos problemas em altos-fornos são consequência da permeabilidade deficiente.

Figura 7 – Reações químicas de redução do minério de ferro.



Fonte: Chaigneau *et al.* (2015).

2.1.1 O Alto-Forno 2 da Aperam

Na Aperam, a produção de gusa ocorre em dois altos-fornos, o alto-forno 1 e o alto-forno 2. O alto-forno 1 possui capacidade de produção anual de aproximadamente 180 mil toneladas de gusa e o alto-forno 2 possui capacidade anual de aproximadamente 360 mil toneladas de gusa, ou seja, possui uma capacidade duas vezes maior. Este fato mostra a importância do equipamento para a Aperam Timóteo, pois o gusa é a principal matéria-prima para a produção de aço. Além da importância para a nossa produção de aço, o alto-forno 2 também é o maior alto-forno a carvão-vegetal do Brasil.

As principais matérias-primas consumidas no alto-forno 2 são: pelota e minério de ferro, fundentes e o carvão vegetal, fornecido pela BioEnergia. O consumo de carvão vegetal é um grande diferencial do ponto de vista ambiental. O carvão vegetal diminui a emissão de gases de efeito estufa, tornando nosso produto um “gusa verde”. A Figura 8 apresenta o Alto-forno 2 da Aperam.

Figura 8 – Alto-forno 2 da Aperam Timóteo.




Fonte: Autores (2024)

2.2 Formação de Gaiolas

A carga no alto-forno se desloca de cima para baixo e a Figura 9 mostra uma representação gráfica da descida da carga. Ela é indicada pelas sondas mecânicas verticais que se apoiam sobre superfície da carga e descem à medida que a carga também desce. A velocidade da descida da carga depende do ritmo de produção. Quanto maior o ritmo de produção, maior a velocidade de descida da carga.

Figura 9 – Sondagem e descida de carga do Alto-forno 2.



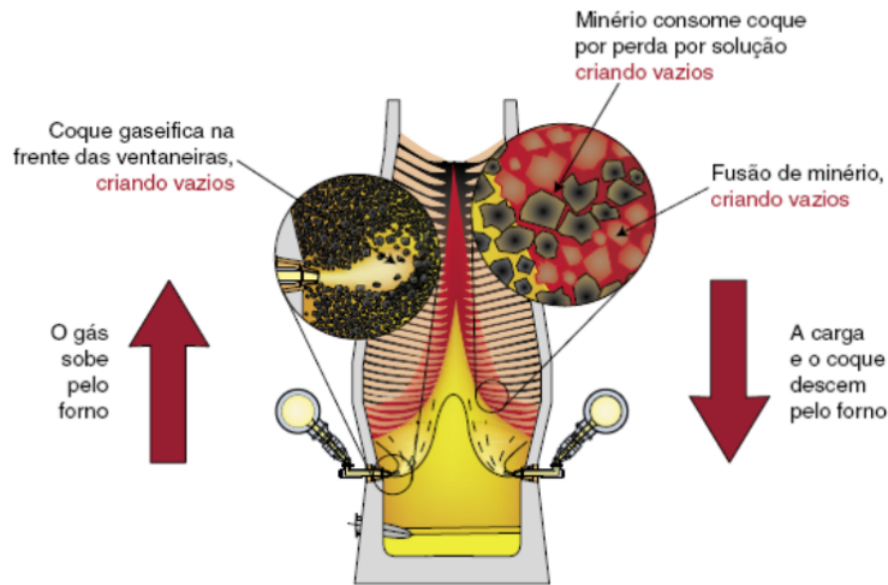
Fonte: Autores (2024).

Segundo [Chaigneau et al. \(2015\)](#), o movimento de descida de carga ocorre quando os espaços vazios em regiões inferiores do alto-forno são formados. Primeiramente, o carvão é queimado em frente às ventaneiras criando vazios. Em seguida o gás quente sobe pelo forno e funde o material da carga. Desta forma, o volume da carga começa a reduzir na zona de fusão e por último o gusa consome o carbono que forma o homem morto.

A maior parte dos vazios é criada na zona de fusão e na área imediatamente abaixo dela. Em um alto-forno típico, aproximadamente 25% dos vazios são criados como uma consequência da queima do coque em frente às ventaneiras. A Figura 10 mostra a criação de vazios no alto-forno.


Apesar da formação de vazios ocorrer de forma constante, a descida de carga nem sempre ocorre no mesmo ritmo. Podem existir fenômenos chamados engaiolamentos e arriamentos. Os engaiolamentos ocorrem quando não há descida de carga ou até mesmo quando ela reduz significativamente e arriamentos são descidas de carga rápida ou descontrolada. A Figura 11 mostra as descidas irregulares da carga.

Figura 10 – Criação de vazios em um alto-forno.



Fonte: Chaigneau *et al.* (2015).

Figura 11 – Formação de gaiola e arriamento de carga no Alto-forno 2.



Fonte: Autores (2024).

Para que a descida de carga ocorra, além da existência de espaços vazios, o somatório de forças descendentes deve ser maior que o somatório das forças ascendentes. A força descendente é formada pelo peso da coluna de carga no interior do alto-forno e a força ascendente é formada pela diferença de pressão entre o sopro e a pressão do topo. Quando a força descendente é maior que a força ascendente a carga desce e à medida que esta diferença cai a descida de carga começa a ficar prejudicada. Esses distúrbios geralmente ocorrem quando a perda de carga eleva-se, ou seja, quando a diferença entre a pressão de sopro e topo aumenta. A elevação da perda de carga reduz a força descendente resultante e pode até mesmo inverter a direção da força resultante. Quando isso acontece ocorre a formação de gaiolas.

2.3 Métodos de Detecção de Gaiolas

Segundo [Liu et al. \(2023\)](#), a detecção de gaiolas se baseia nas seguintes variáveis:

- Elevação repentina da pressão de sopro;
- Redução da permeabilidade do alto-forno;
- A velocidade de descida de carga reduz ou estagna;
- O volume de ar reduz gradualmente ou reduz acentuadamente;
- A pressão de topo cai devido a redução do volume de gás;
- A temperatura de topo eleva-se devido a redução de carregamento causada pela redução da velocidade de descida de carga;
- A pressão de topo é mais afetada quando o engaiolamento ocorre em regiões superiores e a pressão de sopro é mais afetada quando a gaiola é formada em regiões inferiores do alto-forno.

Da mesma forma, como citado acima, atualmente, a detecção de gaiolas no alto-forno 2 é realizada seguindo os procedimentos operacionais existentes e depende dos seguintes parâmetros:

- Elevação da perda de carga, ou seja elevação da diferença entre a pressão de sopro e pressão de topo;
- Redução da velocidade ou estagnação da descida de carga medidas pelas sondas mecânicas apoiadas sobre a carga;
- Elevação da temperatura de topo medida pelos quatorze tempores de topo localizado no topo do alto-forno.

Entretanto, mesmo seguindo as práticas, a percepção e a leitura das variáveis depende da experiência e da percepção de cada um dos colaboradores que exercem a função de Operador de alto-forno.

Como apresentado por [Liu et al. \(2023\)](#), no artigo “Blast Furnace Hanging Model Based on ReilefF-Decision Tree”, a detecção de gaiolas automaticamente através da utilização da ciência de dados já é um método em desenvolvimento na atualidade e o modelo proposto realiza essa detecção através diagnóstico de anomalias nas variáveis de processo citadas acima.

De acordo com o trabalho, a detecção das gaiolas se dá pelo uso do algoritmo ReliefF que se baseia em um algoritmo de ponderação de recursos. Ele é utilizado para problemas de multi categorização onde a ideia central do algoritmo é avaliar o grau de associação entre parâmetros característicos e categorias com base na capacidade de classificação de cada parâmetro característico. As características com bom efeito de classificação devem tornar a distância entre amostras semelhantes mais próximas e a distância entre amostras heterogêneas maiores. E a detecção é também realizada pelo uso da árvore de decisão que é um importante método de classificação e regressão em técnicas de mineração de dados. Ele pode resumir regras de decisão a partir de uma série de dados com características e rótulos, e apresentar essas regras na estrutura de um gráfico em árvore, de modo a realizar a classificação e regressão dos dados.

Pela utilização dos modelos propostos, foi observado a influência de duas principais variáveis que são o nível de carga e as pressões do alto-forno, obtendo, assim, uma acurácia para a detecção das gaiolas próximo a 96,5% com uma boa eficiência na performance do modelo. Além disso, pelas diversas influências que uma gaiola sofre para se formar, é necessário a utilização da tecnologia de inteligência artificial para identificar sua formação e descobrir os principais motivos que levaram à sua ocorrência.

A identificação de gaiola no alto-forno é uma tarefa desafiadora que envolve a detecção e monitoramento preciso das condições internas do equipamento e justamente essa complexidade e a falta de pesquisas sobre o assunto justificam o trabalho.

O desenvolvimento de sistemas automáticos para a identificação de gaiola no alto-forno representa um avanço significativo na eficiência operacional e na segurança industrial. A automação desses processos não apenas reduz a dependência de intervenções humanas em ambientes perigosos, mas também possibilita uma resposta mais rápida a possíveis falhas ou anomalias sempre impulsionando a busca constante da excelência e do progresso tecnológico.

3 Metodologia

A metodologia adotada neste trabalho teve como objetivo principal realizar um estudo para identificar a formação de gaiolas no alto-forno, com base em observações empíricas e verificações teóricas. O estudo visou correlacionar as variáveis do processo, prevendo quando ocorrerão as gaiolas, a fim de tomar as ações operacionais necessárias para manter a descida de carga estável e controlada.

3.1 Coleta de Dados

Neste trabalho, a coleta de dados foi realizada por meio do sistema de histórico de dados utilizado na empresa, chamado PIMS. Os dados provenientes dessa fonte são considerados como dados primários, pois são obtidos diretamente das medições no chão de fábrica.

A abordagem adotada foi qualitativa, com foco no estudo de caso do alto-forno 02. Foram coletados dados de 21 instrumentos, identificados pelas tags:

- RED-AF2-TOPO-NVSONDA1
- RED-AF2-TOPO-NVSONDA2
- RED-AF2-TOPO-NVSONDA3
- RED-AF2-TOPO-NVSONDA4
- RED-AF2-COW-PERDA-DE-CARGA
- RED-AF2-COW-PRESSAO-DO-TOPO
- RED-AF2-COW-PT6-PRES-SOPRO
- RED-AF2-PIR-TE11
- RED-AF2-PIR-TE12
- RED-AF2-PIR-TE13
- RED-AF2-PIR-TE14
- RED-AF2-PIR-TE15
- RED-AF2-PIR-TE16
- RED-AF2-PIR-TE21

- RED-AF2-PIR-TE22
- RED-AF2-PIR-TE23
- RED-AF2-PIR-TE24
- RED-AF2-PIR-TE25
- RED-AF2-PIR-TE26
- RED-AF2-PIR-TE27
- RED-AF2-PIR-TE28

Os instrumentos utilizados para a coleta de dados são responsáveis pelo acompanhamento dos seguintes parâmetros operacionais do processo de redução: nível de sonda, perda de carga, pressão de topo, pressão de sopro e temperatura de topo.

Esses dados foram coletados ao longo de sete dias no mês de abril de 2023, com intervalo de medição de um segundo totalizando 604.800 dados. Os dados foram inicialmente utilizados para identificar anomalias em suas séries temporais e classificados de acordo com o conhecimento da ocorrência de uma gaiola ou não. E, posteriormente, essas anomalias foram empregadas na identificação e previsão de engaiolamento no forno. Cada uma das variáveis são explicadas nas subseções seguintes.

3.1.1 Nível de Sonda

A medição do nível da carga é fundamental para a operação do alto-forno, sendo responsável pelo início de cada carregamento pois, ao realizar a medição e verificar que a carga está na altura objetivada ou acima não será realizado o carregamento do alto-forno e, de mesmo modo, caso a carga estiver abaixo de sua altura objetivada será realizado o carregamento do alto-forno. O Alto-forno 2 da Aperam possui quatro sondas para a medição de nível tipo eletromecânicas.


Seu funcionamento é baseado no momento em que a sonda desce e atinge a superfície da carga do forno, a tensão na corrente que a sustenta reduz, diminuindo o peso e atuando uma chave limite. Depois dessa redução momentânea da corrente, a chave limite comanda a reversão do motor e retorna a sonda para sua posição original de resguardo (MOTTA *et al.*, 2007).

O nível que a carga irá trabalhar é definido pelo operador do equipamento. Quando ocorre o abaixamento da carga devido à fusão do material e o valor medido pela sonda que está sobre o material estiver abaixo do nível objetificado, uma nova descarga de matérias-primas é autorizada pelo PLC.

De forma ilustrativa a Figura 12 exemplifica uma sonda para alto-forno.

As tags responsáveis pela medição deste parâmetro e a análise exploratória dos dados estão expostas nas Tabelas 2 e 3.

Figura 12 – Sonda de Carga de Alto-forno.



Fonte: Ecil (2016, p. 15).

Tabela 2 – Descrição dos instrumentos de medição da altura da carga.

Tags	Descrição	Tipo de Dados
RED-AF2-TOPO-NVSONDA1	A sonda 1 é uma medição no ângulo 0°	Reais
RED-AF2-TOPO-NVSONDA2	A sonda 2 é uma medição no ângulo 90°	Reais
RED-AF2-TOPO-NVSONDA3	A sonda 3 é uma medição no ângulo 180°	Reais
RED-AF2-TOPO-NVSONDA4	A sonda 4 é uma medição no ângulo 270°	Reais

Fonte: Autores (2024).

Tabela 3 – Análise exploratória dos dados.

	RED-AF2-TOPO-NVSONDA1	RED-AF2-TOPO-NVSONDA2	RED-AF2-TOPO-NVSONDA3	RED-AF2-TOPO-NVSONDA4
count	604800	604800	604800	604800
mean (m)	0,74	0,51	0,61	0,80
std (m)	0,71	0,87	0,86	0,63
min (m)	-2,82	-2,56	-3,36	-1,04
max (m)	1,60	1,61	1,68	1,60

Fonte: Autores (2024).

3.1.2 Perda de Carga

A perda de carga, também conhecida como queda de pressão, refere-se à diminuição da pressão do gás que flui através do alto-forno devido à resistência oferecida pelos materiais sólidos e pelos gases presentes no interior do forno. Essa perda de carga é influenciada por diversos fatores, como a granulometria dos materiais, a temperatura, a composição química e a distribuição dos sólidos.

É essencial monitorar e controlar a perda de carga no alto-forno para otimizar o processo siderúrgico. Uma perda de carga elevada pode resultar em uma menor produção de ferro gusa, menor eficiência energética e maior desgaste dos componentes do forno. Portanto, as indústrias siderúrgicas implementam estratégias de controle e ajuste dos parâmetros operacionais para garantir o equilíbrio entre a eficiência do processo e a minimização da perda de carga.

As tags responsáveis pela medição deste parâmetro e a análise exploratória dos dados estão expostas nas Tabelas 4 e 5.

Tabela 4 – Descrição dos instrumentos de medição da perda de carga.

Tags	Descrição	Tipo de Dados
RED-AF2-COW-PERDA-DE-CARGA	Delta da pressão de topo e de sopro	Reais

Fonte: Autores (2024).

Tabela 5 – Análise exploratória dos dados.

	RED-AF2-COW-PERDA-DE-CARGA
count	604800
mean (bar)	0,43
std (bar)	0,04
min (bar)	0,33
max (bar)	0,67

Fonte: Autores (2024).

3.1.3 Pressão de Topo

Este parâmetro refere-se à pressão exercida pelos gases no topo do alto-forno e está diretamente relacionado com a distribuição adequada de gases ao longo do forno, influenciando aspectos cruciais da produção de ferro gusa.

A compreensão e o monitoramento precisos da pressão de topo são essenciais para prevenir e lidar com potenciais problemas operacionais, tais como a formação de gaiolas.

A literatura destaca a importância de abordagens avançadas para o controle da pressão de topo. A implementação de sistemas de monitoramento em tempo real, combinada com técnicas de modelagem preditiva, permite uma resposta ágil a mudanças nas condições operacionais, contribuindo para a estabilidade e eficiência do alto-forno (MIRANDA; HOBL; MARZANO, 2005). Além disso, a integração de sensores avançados e sistemas de automação desempenha um papel crucial na otimização da pressão de topo, minimizando riscos operacionais e garantindo a qualidade do ferro gusa produzido.

As tags responsáveis pela medição deste parâmetro e a análise exploratória dos dados estão expostas nas Tabelas 6 e 7.

Tabela 6 – Descrição dos instrumentos de medição da pressão de topo.

Tags	Descrição	Tipo de Dados
RED-AF2-COW-PRESSAO-DO-TOPO	Sensor de pressão localizado no topo do alto-forno	Reais

Fonte: Autores (2024).

Tabela 7 – Análise exploratória dos dados.

	RED-AF2-COW-PRESSAO-DO-TOPO
count	604800
mean (bar)	0,93
std (bar)	0,13
min (bar)	0,54
max (bar)	1,30

Fonte: Autores (2024).

3.1.4 Pressão de Sopro

Este termo refere-se à pressão aplicada ao ar ou à mistura de gás injetada no alto-forno para sustentar o processo de redução química do minério. A otimização da pressão de sopro é essencial para garantir um equilíbrio adequado entre a velocidade de reação química e a eficiência energética do processo. A pressão de sopro afeta diretamente a distribuição de calor dentro do alto-forno, influenciando a fusão do minério e a formação do ferro líquido.

Para controlar a pressão de sopro, os operadores de alto-forno precisam considerar uma variedade de fatores, incluindo a qualidade do carvão, a granulometria do minério de ferro e as condições atmosféricas. Uma pressão inadequada pode afetar a qualidade do produto final, no caso, o ferro gusa.

As tags responsáveis pela medição deste parâmetro e a análise exploratória dos dados estão expostas nas Tabelas 8 e 9.

Tabela 8 – Descrição dos instrumentos de medição da pressão de sopro.

Tags	Descrição	Tipo de Dados
RED-AF2-COW-PT6-PRES-SOPRO	Sensor de pressão localizado próximo as ventaneiras do alto-forno	Reais

Fonte: Autores (2024).

Tabela 9 – Análise exploratória dos dados.

	RED-AF2-COW-PT6-PRES-SOPRO
count	604800
mean (bar)	1,36
std (bar)	0,13
min (bar)	1,02
max (bar)	1,70

Fonte: Autores (2024).

3.1.5 Temperatura de Topo

Como o alto-forno é um reator contracorrente, o ar pré aquecido ascendente que é soprado pelas ventaneiras fornece calor para as camadas de carga metálica, carvão e fundentes descendentes, saindo no topo do forno ainda com temperaturas próximas de 100°C.

Os gases gerados no processo de redução saem do alto-forno a elevadas temperaturas e ainda contendo uma energia química (poder calorífico), carregando consigo grande quantidade de calor, logo quanto maior o poder calorífico presente neste gás, maior será o consumo de combustível no processo, assim se identifica a importância do controle dessa temperatura (VIEIRA, 2012).

As tags responsáveis pela medição deste parâmetro e a análise exploratória dos dados estão expostas nas Tabelas 10, 11 e 12.

Tabela 10 – Descrição dos instrumentos de medição da temperatura de topo.

Tags	Descrição	Tipo de Dados
RED-AF2-PIR-TE11	Sensor de temperatura no topo do alto-forno na lança 1	Reais
RED-AF2-PIR-TE12	Sensor de temperatura no topo do alto-forno na lança 1	Reais
RED-AF2-PIR-TE13	Sensor de temperatura no topo do alto-forno na lança 1	Reais
RED-AF2-PIR-TE14	Sensor de temperatura no topo do alto-forno na lança 1	Reais
RED-AF2-PIR-TE15	Sensor de temperatura no topo do alto-forno na lança 1	Reais
RED-AF2-PIR-TE16	Sensor de temperatura no topo do alto-forno na lança 1	Reais
RED-AF2-PIR-TE21	Sensor de temperatura no topo do alto-forno na lança 1	Reais
RED-AF2-PIR-TE22	Sensor de temperatura no topo do alto-forno na lança 2	Reais
RED-AF2-PIR-TE23	Sensor de temperatura no topo do alto-forno na lança 2	Reais
RED-AF2-PIR-TE24	Sensor de temperatura no topo do alto-forno na lança 2	Reais
RED-AF2-PIR-TE25	Sensor de temperatura no topo do alto-forno na lança 2	Reais
RED-AF2-PIR-TE26	Sensor de temperatura no topo do alto-forno na lança 2	Reais
RED-AF2-PIR-TE27	Sensor de temperatura no topo do alto-forno na lança 2	Reais
RED-AF2-PIR-TE28	Sensor de temperatura no topo do alto-forno na lança 2	Reais

Fonte: Autores (2024).

Tabela 11 – Análise exploratória dos dados da sonda 1.

	RED-AF2-PIR-TE11	RED-AF2-PIR-TE12	RED-AF2-PIR-TE13	RED-AF2-PIR-TE14	RED-AF2-PIR-TE15	RED-AF2-PIR-TE16
count	604800	604800	604800	604800	604800	604800
mean (°C)	201,34	177,00	158,67	123,36	110,19	133,72
std (°C)	84,81	73,00	63,46	41,48	32,30	38,29
min (°C)	67,00	63,00	59,00	59,00	56,00	65,00
max (°C)	575,00	566,00	495,00	411,00	395,00	393,00

Fonte: Autores (2024).

Tabela 12 – Análise exploratória dos dados da sonda 2.

	RED-AF2-PIR-TE21	RED-AF2-PIR-TE22	RED-AF2-PIR-TE23	RED-AF2-PIR-TE24	RED-AF2-PIR-TE25	RED-AF2-PIR-TE26	RED-AF2-PIR-TE27	RED-AF2-PIR-TE28
count	604800	604800	604800	604800	604800	604800	604800	604800
mean (°C)	255,85	221,05	204,51	111,69	118,11	127,58	163,29	179,41
std (°C)	96,69	79,19	66,45	25,36	29,61	25,59	34,96	33,36
min (°C)	89,00	83,00	83,00	67,00	71,00	78,00	85,00	92,00
max (°C)	633,00	605,00	502,00	233,00	363,00	324,00	414,00	393,00

Fonte: Autores (2024).

3.2 Pré-processamento de Dados

De acordo com o banco de dados coletado no sistema PIMS da Aperam, foram analisadas as variáveis para criação do modelo de predição proposto.

Após o tratamento e carregamento dos dados, uma análise descritiva foi realizada, como mostra a Figura 13. O foco de interesse recai sobre a média das medidas das sondas do topo do forno, que reflete o comportamento da carga no forno. Essa informação foi adicionada à última linha do data frame, identificada como RED_AF2_TOPO_NVSON_MEDIA, conforme ilustrado na Figura 13.

Cada ciclo de medição da sonda, que tem início na descida da sonda e termina com a subida da mesma, representa um indivíduo a ser classificado. Ao longo de um período de 24 horas de medição, observamos uma média de 200 desses indivíduos, totalizando 1400 na base de dados coletada. Uma representação destes ciclos pode ser observada na Figura 14.


Foi observado uma quantidade excessiva de dados da sonda referente a sua atuação e retorno para garagem, assim, foi realizada uma limpeza dos dados retirando todos dados superiores a 0,5 metros, resultados de medição que indicam que a sonda está próximo a seu ponto de partida inicial. O resultado pode ser visto na Figura 15.

Figura 13 – Resumo dos dados de trabalho e média das sondas.

	count	mean	std	min	25%	50%	75%	max
RED_AF2_PIR_TE16	86400.0	118.773310	29.984767	73.000000	97.000000	114.000000	133.000000	303.000000
RED_AF2_PIR_TE15	86400.0	99.065938	26.235754	66.000000	82.000000	93.000000	108.000000	251.000000
RED_AF2_PIR_TE14	86400.0	114.799282	34.135519	70.000000	90.000000	105.000000	131.000000	274.000000
RED_AF2_PIR_TE13	86400.0	161.800417	60.712409	73.000000	114.000000	148.000000	197.000000	385.000000
RED_AF2_PIR_TE12	86400.0	172.832569	66.580731	79.000000	123.000000	157.000000	207.000000	445.000000
RED_AF2_PIR_TE11	86400.0	197.772812	77.417924	82.000000	138.000000	180.000000	241.000000	486.000000
RED_AF2_PIR_TE28	86400.0	165.964838	26.802471	112.000000	147.000000	162.000000	181.000000	278.000000
RED_AF2_PIR_TE27	86400.0	149.777951	28.148049	93.000000	131.000000	146.000000	165.000000	273.000000
RED_AF2_PIR_TE26	86400.0	114.234803	17.797497	82.000000	101.000000	112.000000	124.000000	183.000000
RED_AF2_PIR_TE25	86400.0	108.641887	23.368884	75.000000	91.000000	104.000000	121.000000	201.000000
RED_AF2_PIR_TE24	86400.0	112.187049	21.600964	73.000000	97.000000	112.000000	123.000000	191.000000
RED_AF2_PIR_TE23	86400.0	199.755556	57.959090	103.000000	155.000000	191.000000	234.000000	457.000000
RED_AF2_PIR_TE22	86400.0	209.553542	67.715179	99.000000	160.000000	197.000000	246.000000	541.000000
RED_AF2_PIR_TE21	86400.0	241.707025	86.323005	106.000000	174.000000	228.000000	295.000000	614.000000
RED_AF2_COW_PT6_PRES_SOPRO	86400.0	1.552270	0.129316	1.282786	1.395888	1.610694	1.650466	1.696680
RED_AF2_COW_PRESSAO_DO_TOPO	86400.0	1.120456	0.126013	0.856686	0.971800	1.190828	1.207325	1.300972
RED_AF2_COW_PERDA_DE_CARGA	86400.0	0.441929	0.025725	0.366862	0.423890	0.440330	0.460733	0.527897
RED_AF2_TOPO_NVSONDA1	86400.0	0.800397	0.726342	-1.814766	0.104770	0.723538	1.570378	1.599999
RED_AF2_TOPO_NVSONDA2	86400.0	0.577102	0.909917	-1.128307	-0.290782	0.218374	1.581400	1.610000
RED_AF2_TOPO_NVSONDA3	86400.0	0.685715	0.880035	-2.593725	-0.119104	0.449165	1.652032	1.679999
RED_AF2_TOPO_NVSONDA4	86400.0	0.842524	0.658811	-1.038000	0.234059	0.613812	1.581149	1.599998
RED_AF2_TOPO_NVSON_MEDIA	86400.0	0.726434	0.786661	-1.636504	-0.029007	0.495644	1.596568	1.621792

Fonte: Autores (2024).


Figura 14 – Medição das sondas do Alto-forno 2.



Fonte: Autores (2024).

A partir da limpeza dos dados, devido o banco de dados não ser rotulado se existe a presença de gaiola no momento ou não, na base de dados dos 7 dias de medição das sondas e de acordo com o conhecimento técnico da ocorrência das gaiolas no processo, foi realizada a rotulagem manual de cada medição superior a 100 segundos e inferior a 500 segundos (intervalo normal de medição de carga).

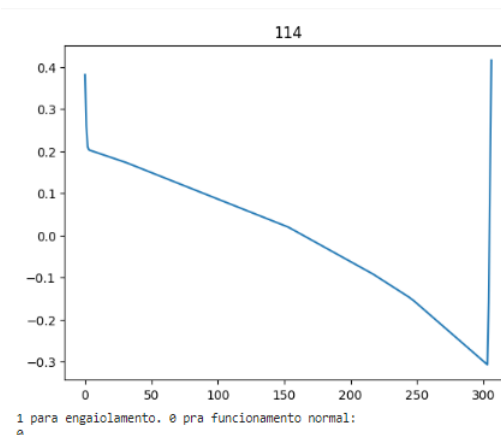
Figura 15 – Medição filtrada das sondas do Alto-forno 2.



Fonte: Autores (2024).

Através de cada matriz de dados que representa como está a descida de carga, caso a descida está lenta ou ocorra um arriamento, e o conhecimento prévio da formação das gaiolas no alto-forno é possível identificar se está ocorrendo a formação de uma gaiola ou não. A rotulagem foi baseada no padrão de que se recebe o valor 0 a medição de carga com funcionamento normal e recebe o valor 1 a medição de carga que indica a formação de uma gaiola no alto-forno, as medições inferiores a 100 segundos e superiores a 500 segundos foram rotuladas com valor 2, o qual indica a medição de carga com medições insuficientes ou por um excesso de medições que saem do intervalo normal de medição de carga. Com os indivíduos classificados foi possível averiguar um desbalanceamento na base de dados sendo 686 funcionamentos normais, 452 indivíduos não considerados e 132 indivíduos classificados representando o engaiolamento no forno. Os indivíduos então ficam representados por uma matriz de $N \times M$ onde N representa o número de variáveis coletadas, no caso 23 ao adicionar a média das sondas e a classificação das medições de sonda, e M representa o tempo de coleta do maior intervalo de medição, indivíduos com intervalo de medição menores tem a diferença de valores preenchidos com zeros. Na Figura 16 é apresentado um indivíduo rotulado de acordo com suas características e limites.

Figura 16 – Classificação das medições da sonda.



Fonte: Autores (2024).

3.3 Modelo de Rede Neural

As Redes Neurais Convolucionais (CNNs) representam uma abordagem revolucionária no campo da visão computacional e processamento de imagens. Essas arquiteturas de rede foram projetadas para extrair automaticamente características hierárquicas e espaciais de padrões visuais complexos, tornando-as particularmente eficazes em tarefas de reconhecimento de padrões.

Segundo LeCun *et al.* (1998), as CNNs foram originalmente inspiradas no processamento visual do córtex cerebral de animais, buscando replicar a capacidade do sistema visual biológico de reconhecer padrões complexos. Essa inspiração biológica resultou em uma arquitetura de rede que utiliza camadas convolucionais para aprender automaticamente filtros espaciais que capturam características relevantes nas entradas, reduzindo assim a necessidade de engenharia manual de características.

Uma característica distintiva das CNNs é a presença de camadas convolucionais e de pooling, que permitem a detecção de características locais e a redução da dimensionalidade, respectivamente. Essas camadas são intercaladas com camadas totalmente conectadas, permitindo que a rede aprenda padrões globais e faça previsões precisas.

Além disso, as CNNs têm demonstrado desempenho notável em uma variedade de tarefas, como classificação de imagens, detecção de objetos e segmentação semântica. A flexibilidade dessas redes, aliada à capacidade de aprendizado automático de representações hierárquicas, as torna uma escolha popular em muitas aplicações práticas.

A aplicação de uma CNN envolve 8 etapas:

- Coleta de Dados: reunir um conjunto de dados representativo para o problema que a CNN irá resolver.
- Pré-processamento de Dados: inclui redimensionamento de imagens, normalização de pixels e outras transformações que garantem uma entrada adequada a rede.
- Arquitetura da CNN: consiste em camadas de convolução, camadas de *pooling* e camadas totalmente conectadas. A escolha da arquitetura depende da natureza da tarefa.
- Compilação do Modelo: configurar o modelo, especificando otimizadores, funções de perda e métricas de avaliação.
- Treinamento: alimentar os dados de treinamento e ajustar os pesos dos neurônios através do processo de retropropagação. Este passo visa minimizar a função de perda e melhorar o desempenho da rede.
- Validação e Ajuste: avaliar o desempenho do modelo em dados de validação para evitar *overfitting*.
- Teste: avaliar o desempenho final da CNN em um conjunto de dados de teste independente.

- Implementação em Produção: e, após a validação e teste, a CNN pode ser implementada em ambientes de produção para realizar inferências em novos dados.

A escolha adequada da arquitetura, parâmetros e o conjunto de dados de treinamento são críticos para o sucesso da aplicação de uma CNN.

3.4 Treinamento do Modelo

A partir do tratamento, rotulagem e divisão dos dados coletados, foram obtidos os indivíduos, cada um representado por uma matriz de valores numéricos com dimensões correspondentes ao tempo de medição e pelo número de variáveis de processo de interesse. Considerando que um computador interpreta uma imagem como uma matriz de valores numéricos, decidimos empregar um algoritmo de classificação de imagens para realizar a categorização dos nossos indivíduos.

Foi utilizada a rede neural convolucional (CNN) para efetuar a classificação da base de dados onde 70% dos dados foram utilizados no treinamento e os outros 30% dos dados no teste do modelo. A divisão dos dados foi feita utilizando a sequência temporal devido a estrutura do modelo base utilizado para criação do modelo de classificação das anomalias. As configurações do modelo e o sumário são apresentados nas Figuras 17 e 18. A configuração da rede neural foi obtida através de modificações empíricas a fim de se obter resultados mais satisfatórios. Foram realizados inicialmente os experimentos com um modelo de 100 épocas e foram variados os parâmetros do modelo, como o número de épocas, camadas e treinamento, até alcançar a acurácia desejada para a detecção de gaiolas.

Figura 17 – Código do modelo.

```
model = Sequential()
model.add(Conv2D(128, (2,2), activation='relu', input_shape=(741,22,1))),
model.add(MaxPooling2D((2,2))),
model.add(Dropout(0.3)),

model.add(Conv2D(64, (2,2), activation='relu')),
model.add(MaxPooling2D((2,2))),
model.add(Dropout(0.2)),

model.add(Conv2D(32, (2,2), activation='relu')),
model.add(MaxPooling2D((2,2))),
model.add(Dropout(0.2)),

model.add(Flatten()),
model.add(Dense(256, activation='relu')),
model.add(Dropout(0.5)),
model.add(Dense(10, activation='softmax'))

model.summary()
```

Fonte: Autores (2024).

Figura 18 – Sumário do modelo.

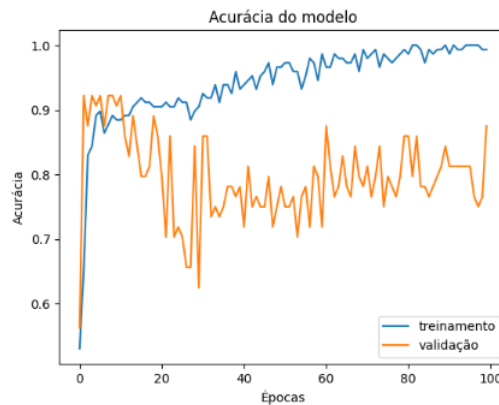
Layer (type)	Output Shape	Param #
conv2d_6 (Conv2D)	(None, 740, 21, 128)	640
max_pooling2d_6 (MaxPooling2D)	(None, 370, 10, 128)	0
dropout_8 (Dropout)	(None, 370, 10, 128)	0
conv2d_7 (Conv2D)	(None, 369, 9, 64)	32832
max_pooling2d_7 (MaxPooling2D)	(None, 184, 4, 64)	0
dropout_9 (Dropout)	(None, 184, 4, 64)	0
conv2d_8 (Conv2D)	(None, 183, 3, 32)	8224
max_pooling2d_8 (MaxPooling2D)	(None, 91, 1, 32)	0
dropout_10 (Dropout)	(None, 91, 1, 32)	0
flatten_2 (Flatten)	(None, 2912)	0
dense_4 (Dense)	(None, 256)	745728
dropout_11 (Dropout)	(None, 256)	0
dense_5 (Dense)	(None, 10)	2570
=====		
Total params: 789994 (3.01 MB)		
Trainable params: 789994 (3.01 MB)		
Non-trainable params: 0 (0.00 Byte)		

Fonte: Autores (2024).

4 Resultados

Nas Figuras 19, 20, 21 e 22 abaixo são apresentados a evolução do processo de treinamento e validação da rede CNN variando o número de épocas: 100, 300, 600 e 1000 épocas, respectivamente.

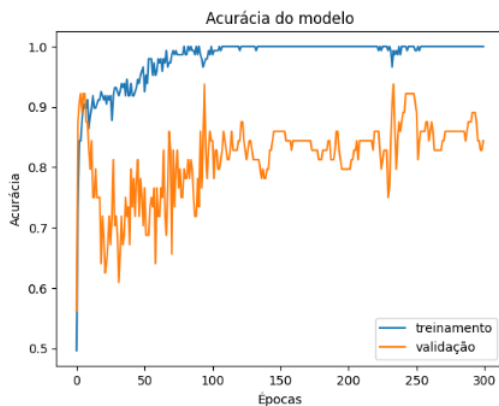
Figura 19 – Acurácia do modelo utilizando 100 épocas.



Fonte: Autores (2024).

No teste utilizando 100 épocas foi apresentado grande instabilidade na validação dos dados e uma acurácia média de 77% que variava entre 70% e 85% nas detecções. Devido a esta variação foi identificado a necessidade de elevar o número de épocas para avaliar o comportamento da variação da acurácia. Assim foi realizado um novo teste com 300 épocas.


Figura 20 – Acurácia do modelo utilizando 300 épocas.



Fonte: Autores (2024).

Quando elevado o número de épocas para 300 foi observado que a acurácia média foi igual a 83%. Como era esperado, houve elevação da acurácia em relação ao teste com 100 épocas. Além da elevação da acurácia, também se notou que a variação da acurácia reduziu a partir de 150 épocas e também que ela ainda continuava subindo. Devido a elevação da acurácia, foi realizado um novo teste elevando o número de épocas para 600.


Figura 21 – Acurácia do modelo utilizando 600 épocas.



Fonte: Autores (2024).

Na utilização de 600 épocas, como era esperado, houve elevação da acurácia média para 90%. A variação da acurácia reduziu em relação aos dois anteriores. Esse valor já se mostrou adequado ao processo de detecção de gaiolas. Porém, o gráfico ainda mostrava uma possível elevação de acurácia e da estabilidade com o aumento do número de épocas e por isso foi decidido elevar o número para 1000.

Figura 22 – Acurácia do modelo utilizando 1000 épocas.



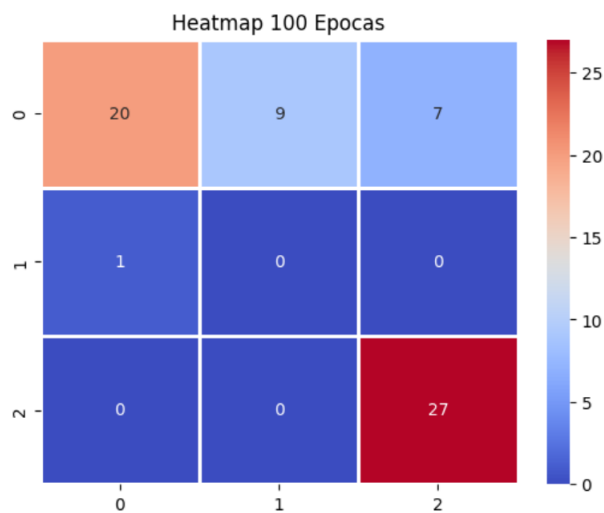
Fonte: Autores (2024).

No teste com 1000 épocas a acurácia média caiu para 87,8%, ou seja, ela piorou em relação ao teste com 600 épocas. Ao atingir o patamar máximo neste teste, por volta das 600 épocas, notou-se que a acurácia não continuou a subir e que a variação reduziu significativamente.

Em resumo, os resultados dos treinamentos das redes convolucionais apresentados nos gráficos indicam a instabilidade da acurácia nos modelos treinados até 300 épocas durante os testes. Nos modelos com 600 e 1000 épocas, foi observado uma tendência à estabilização da acurácia entre 500 e 600 épocas. Entretanto, os modelos treinados com quantidades de épocas superiores a 1000 não demonstraram melhorias na acurácia, conforme constatado. Para a avaliação da eficácia do modelo na tarefa proposta, foi considerado um patamar de acerto próximo aos 90% como satisfatório.


Nas Figuras 23, 24, 25 e 26 são apresentados os heatmaps das matrizes de confusão dos modelos treinados com 100, 300, 600 e 1000 épocas.

Figura 23 – Heatmap do modelo utilizando 100 épocas.




Fonte: Autores (2024).

Figura 24 – Heatmap do modelo utilizando 300 épocas.



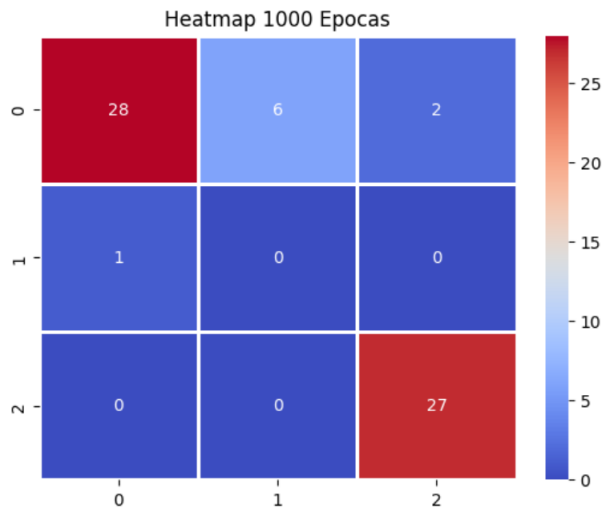
Fonte: Autores (2024).

Figura 25 – Heatmap do modelo utilizando 600 épocas.



Fonte: Autores (2024).

Figura 26 – Heatmap do modelo utilizando 1000 épocas.



Fonte: Autores (2024).

Nas figuras dos heatmaps é possível observar uma grande quantidade de acertos relacionados aos rótulos de funcionamento normal e indivíduos com medições insuficientes ou em excesso, os indivíduos com rótulos de engaiolamento não foram identificados adequadamente, acreditando-se que essa seleção seja em função do desbalanceamento da base de dados, tornando necessária a seleção de uma base de dados mais representativa e a utilização de novas ferramentas no modelo.

Atualmente a detecção de gaiolas em altos-fornos não é realizada de forma preditiva. Para que seja detectada, ele precisa estar ocorrendo ou se formando e o que torna isto possível são os parâmetros monitorados.

Ao perceber a alteração dos parâmetros como temperatura de topo, elevação da perda de carga e redução da velocidade de descida de carga, podemos concluir que o alto-forno está engaiolando.

Quanto maior a experiência e atenção do Operador de alto-forno, maiores são as chances de detectar a formação de gaiolas e quanto menor a experiência e atenção, menores são as chances de detectar gaiolas. Nesse ponto este trabalho pode contribuir. Como o método proposto, a detecção de gaiolas não dependerá da pessoa e todos os operadores terão a mesma capacidade de detectar a formação de gaiolas.

Eliminar a subjetividade da interpretação dos parâmetros e antecipar a percepção das gaiolas é importante para amenizar os efeitos negativos causados pelas gaiolas como elevação do consumo de carbono, redução da produtividade e piora na qualidade do gusa.

A detecção ou a antecipação da detecção de gaiolas é muito importante para que as ações de corte de gaiolas sejam executadas e evite maiores transtornos no processo do alto-forno 2. Quanto menor for o impacto das gaiolas menores serão as perdas sofridas no equipamento e consequentemente menor será o custo de produção.

5 Conclusão

Este trabalho possibilitou o entendimento dos mecanismos relacionados à formação de gaiolas no alto-forno, destacando a necessidade de uma ferramenta para identificação e previsão dessas ocorrências, além da utilização das técnicas aprendidas no curso de especialização em Ciência de Dados em problemas rotineiros da indústria.

Com o objetivo de atingir essa meta, foram estabelecidos dois objetivos específicos. O primeiro consistiu na identificação das principais variáveis relacionadas à formação de gaiolas, o que foi realizado de forma empírica, contando com a colaboração da equipe de operação e observação do equipamento.

Após identificar, registrar e sanitizar os dados provenientes das variáveis identificadas como relevantes, foi possível avançar para o segundo objetivo específico: definir a melhor técnica para trabalhar com essas variáveis. A técnica selecionada foi a identificação de anomalias pela rede neural convolucional (CNN) que, através do treinamento e teste, atingiu uma acurácia de aproximadamente 90%.

Essa precisão na identificação das anomalias indica o atingimento da meta de detecção das gaiolas no Alto-forno 2 e permite o avanço no desenvolvimento do projeto com o objetivo geral de criar uma ferramenta capaz de prever o engaiolamento no alto-forno. Essas anomalias ocorrem em áreas de mau funcionamento do equipamento e serão utilizadas para rotular os dados, que alimentarão o modelo responsável por fazer as previsões.

Ao analisar possibilidades de trabalhos futuros, destaca-se três áreas de enfoque que podem complementar os resultados desta pesquisa. Primeiramente, a exploração de ferramentas de tuning de redes neurais. A otimização precisa dos parâmetros da rede neural, como taxas de aprendizado e arquitetura, possibilita não só elevar a precisão das classificações, mas também otimizar a eficiência computacional do modelo.

A análise detalhada da divisão de dados emerge como uma segunda sugestão de trabalhos futuros. Estratégias mais refinadas, incluindo técnicas de validação cruzada e balanceamento de classes, podem fortalecer a robustez do modelo, garantindo uma representação mais fiel dos dados de treinamento, validação e teste.

Por fim, a previsão do engaiolamento com base no histórico imediatamente anterior aliado a classificação da série predita poderia antecipar os engaiolamentos, dando ao operador a oportunidade de antecipar ajustes operacionais. Para isso, técnicas de IA generativa são necessárias, para prever séries temporais.

Referências

- CHAIGNEAU, R.; GEERDES, M.; KURUNOV, I.; LINGIARDI, O.; RICKETTS, J. **Modern Blast Furnace Ironmaking: An Introduction**. 3. ed. Amsterdam: IOS Press, 2015. 218 p. ISBN 9781614994992. Disponível em: <<https://ebooks.iospress.nl/book/modern-blast-furnace-ironmaking-an-introduction>>. Acesso em: 2 dez. 2022.
- CNI. A indústria do aço no brasil. Brasília, p. 50, 2012.
- CNI. A indústria do aço no brasil. Brasília, p. 64, 2017.
- ECIL, G. Termopares. São Paulo, p. 16, 2016. Disponível em: <<https://ecil.com.br/pirometria-2/termopares/>>.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradientbased learning applied to document recognition. **IEEE Transactions on Knowledge and Data Engineering**, IEEE Computer Society, 1998.
- LIU, X.; MENG, L.; LI, X.; LI, H.; MI, J. Blast furnace hanging diagnosis model based on relieff-decision tree. *ISIJ International*, p. 30, 2023. Disponível em: <<https://doi.org/10.2355/isijinternational.ISIJINT-2023-350>>.
- MIRANDA, W. P.; HOBL, J. M.; MARZANO, L. F. Sistema de controle da turbina de topo do alto-forno nº3 da usiminas. Associação Brasileira de Metalurgia, Materiais e Mineração, 2005.
- MOTTA, R. S. N.; AGUIAR, F. N. de; REIS, M. A. dos; BARROS, F. M.; MARIANO, R. de O.; HARTNETT, M. Sondas radar de medição do nível da caga do af3 da csn. Associação Brasileira de Metalurgia, Materiais e Mineração, p. 1611–1621, 2007. Disponível em: <<https://abmproceedings.com.br/ptbr/event/62congresso-anual-da-abm/articles>>.
- VIEIRA, D. H. Avaliação de parâmetros operacionais que influenciam a taxa de injeção de carvão pulverizado em altos-fornos a carvão vegetal. Escola de Engenharia da UFMG, p. 123, 2012.