





# Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração (PROFICAM) Escola de Minas, Universidade Federal de Ouro Preto (UFOP) Associação Instituto Tecnológico Vale (ITV)

### Dissertação

# PROPOSTA DE SENSORES VIRTUAIS BASEADOS EM APRENDIZADO DE MÁQUINA PARA ESTIMATIVA DE PARAMETROS DE QUALIDADE NA ETAPA DE PELOTAMENTO DE MINÉRIO DE FERRO

Fabricio Bertholi Dias

Ouro Preto Minas Gerais, Brasil 2021

#### **Fabricio Bertholi Dias**

# PROPOSTA DE SENSORES VIRTUAIS BASEADOS EM APRENDIZADO DE MÁQUINA PARA ESTIMATIVA DE PARAMETROS DE QUALIDADE NA ETAPA DE PELOTAMENTO DE MINÉRIO DE FERRO

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Gustavo Pessin, D.Sc.

Ouro Preto

2021

#### SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

D541p Dias, Fabricio Bertholi.

Proposta de sensores virtuais baseados em aprendizado de máquina para estimativa de parâmetros de qualidade na etapa de pelotamento de Minério de Ferro. [manuscrito] / Fabricio Bertholi Dias. Fabricio Bertholi Dias. - 2021.

88 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Gustavo Pessin.

Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração.

Área de Concentração: Engenharia de Controle e Automação de Processos Minerais.

Minério de Ferro - Pelotização.
 Detectores - Detector Virtual.
 Aprendizado de Máquina.
 Inteligência Artificial.
 Dias, Fabricio Bertholi.
 Pessin, Gustavo.
 Universidade Federal de Ouro Preto.
 IV. Título.

CDU 681.5:622.2

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716



#### MINISTÉRIO DA EDUCAÇÃO UNIVERSIDADE FEDERAL DE OURO PRETO REITORIA ESCOLA DE MINAS PROGR. POS GRAD. PROF. INST. CONT. E AUT. PROCESSOS DE MIN.



## FOLHA DE APROVAÇÃO

#### Fabricio Bertholi Dias

Proposta de Sensores Virtuais Baseados em Aprendizado de Máquina para Estimativa de Parametros de Qualidade na Etapa de Pelotamento de Minério de Ferro

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração (PROFICAM), Convênio Universidade Federal de Ouro Preto/Associação Instituto Tecnológico Vale - UFOP/ITV, como requisito parcial para obtenção do título de Mestre em Engenharia de Controle e Automação na área de concentração em Instrumentação, Controle e Automação de Processos de Mineração.

Aprovada em 09 de novembro de 2021

#### Membros da banca

Doutor - Gustavo Pessin - Orientador - Instituto Tecnológico Vale Doutor - Thiago Antonio Melo Euzébio - Instituto Tecnológico Vale Doutor - Bruno Nazário Coelho - Universidade Federal de Ouro Preto Doutor - Jefferson Rodrigo de Souza - Universidade Federal de Uberlândia

Gustavo Pessin, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 08/01/2022

\_\_\_\_\_\_ Documento assinado eletronicamente por Bruno Nazário Coelho,



# COORDENADOR(A) DE CURSO DE PÓS-GRAD EM INSTRUMENTAÇÃO CONTROLE E AUTOMAÇÃO DE PROCESSOS DE MINERAÇÃO, em

28/01/2022, às 11:30, 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 <a href="http://sei.ufop.br/sei/controlador\_externo.php?">http://sei.ufop.br/sei/controlador\_externo.php?</a>
<a href="mailto:acao=documento\_conferir&id\_orgao\_acesso\_externo=0">acesso\_externo=0</a>, informando o código verificador **0272908** e o código CRC **003E658B**.

**Referência:** Caso responda este documento, indicar expressamente o Processo  $n^{o}$  23109.001011/2022-18

SEI nº 0272908

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35400-000 Telefone: - www.ufop.br

#### Agradecimentos

Em primeiro lugar, agradeço a DEUS por todas as bênçãos recebidas ao longo de minha vida. Aos meus filhos João Victor e Ana Júlia por tornarem meus dias mais alegres, divertidos e involuntariamente fazerem-me querer ser um ser humano melhor. À Stephany (minha Téti!) pelo amor, carinho, apoio, paciência, compreensão e ânimo em todos os momentos. Aos meus pais, José Maria e Ociléia, e irmãos, Flávio e Clarissa, por todo amor, incentivo para que eu conseguisse atingir meus ideais. Aos professores da UFOP / ITV, em especial ao professor Gustavo Pessin, por todo apoio recebido e compreensão nos momentos de ausência, pelas observações e devidas correções. Meus agradecimentos aos amigos e aos colegas da Vale que muito contribuíram em minha formação técnica, transmitindo todos seus conhecimentos e experiências. Aos grandes amigos do Curso pelas discussões técnicas, pela colaboração no trabalho e sobretudo pela extrema amizade.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e da Vale SA.

"Caelum certe patet, ibimus illi."

"Certamente o céu está aberto, vamos por este caminho."

(De Dédalos para Ícaro, em Metamorfoses, do poeta romano Ovídio, Livro VIII, ao pensar em um meio de escapar de Creta e determinando que o céu era o único caminho aberto para eles) Resumo

Resumo de Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação,

Controle e Automação de Processos de Mineração como parte dos requisitos necessários para

a obtenção do grau de Mestre em Ciências (M.Sc.)

PROPOSTA DE SENSORES VIRTUAIS BASEADOS EM APRENDIZADO DE

MÁQUINA PARA ESTIMATIVA DE PARAMETROS DE QUALIDADE NA ETAPA DE

PELOTAMENTO DE MINÉRIO DE FERRO

Fabricio Bertholi Dias

Novembro, 2021

Orientadores: Prof. Gustavo Pessin, D.Sc

O processo industrial de pelotização de minério de ferro foi desenvolvido objetivando-se o

beneficiamento e aproveitamento comercial dos finos de minério. O pelotamento é a etapa deste

processo responsável pela formação das pelotas, sendo influenciado por diversas variáveis, com

reflexos diretos sobre a qualidade do produto. Logo, é importante que certas características

físicas, desejadas para as pelotas, sejam continuamente monitoradas durante o processo

produtivo. Atualmente o processo de garantia da qualidade é feito através de ensaios em

laboratórios, atividade com alta latência de resposta.

Dada a necessidade de aumento de eficiência deste processo e o respectivo impacto em toda a

cadeia produtiva, este trabalho propõe a aplicação de um sensor virtual para estimar parâmetros

de qualidade na etapa de pelotamento em uma usina de pelotização de minério de ferro. Foram

comparadas 3 técnicas de aprendizado de máquinas: Redes Neurais Artificias, Random Forests

e KNN – *K Nearest Neighbors*. Foi proposto um modelo de regressão baseado na coletânea nos

melhores modelos individuais comparados. A identificação das variáveis que mais influenciam

nos parâmetros de qualidade de pelotas cruas de minério de ferro é descrita, fundamentando-se

na teoria da metalurgia do processo de pelotização. As variáveis de processo candidatas

viii

(*features / targets*) ao modelo foram tratadas, formando a base de dados para a geração do modelo de predição. Os modelos dos sensores virtuais foram validados com sucesso, obtendose R2 de 0,944 e RMSE de 0,075 para o modelo de coletânea, comprovando a importância de variáveis, tais como dosagens de aglomerantes, taxas de dosagem e rotação dos discos de pelotamento, volumes de produção e retorno. A validação dos modelos evidencia seu potencial para aplicação em um ambiente real, e abre espaço para continuidade de estudos futuros.

**Palavras-chave**: Pelotização de Minério de Ferro, Pelotamento, Operação, Estimativa, Sensores Virtuais, Aprendizado de Máquinas, Inteligência Artificial.

Macrotema: Usina; Linha de Pesquisa: Tecnologias da Informação, Comunicação e Automação Industrial; Tema: Aumento da Produtividade na Usina / Pelotização; Área Relacionada da Vale: Operação de Usinas de Pelotização.

**Abstract** 

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and

Automation of Mining Process as a partial fulfillment of the requirements for the degree of

Master of Science (M.Sc.)

PROPOSAL OF VIRTUAL SENSORS BASED ON MACHINE LEARNING FOR

ESTIMATION OF QUALITY PARAMETERS IN THE IRON ORE BALLING STAGE

Fabricio Bertholi Dias

November 2021

Advisors:

Prof. Gustavo Pessin, D.Sc

The industrial iron ore pelletizing process was developed with the aim of commercially

exploiting ore fines. Pelleting (balling) is the stage of this process responsible for the formation

of pellets, being influenced by several variables, with direct effects on the quality of the product.

Therefore, it is important that certain physical characteristics, desired for pellets, be

continuously monitored during the production process. Currently, the quality assurance process

is performed through laboratory tests, an activity with high response latency.

Given the need to increase the efficiency of this process and the impact on the entire production

chain, this work proposes the application of a virtual sensor to estimate quality parameters in

the pelletizing stage in an iron ore pelletizing plant. Three machine learning techniques were

compared: Artificial Neural Networks, Random Forests and KNN - K Nearest Neighbors. An

estimation model based on the collection of the best individual models compared was proposed.

The identification of the variables that most influence the quality parameters of raw iron ore

pellets is obtained, based on the theory of metallurgy of the pelletizing process. The candidate

variables (features / targets) to the model were treated, forming a database to be used to generate

the estimation model. The soft sensor models were successfully validated, obtaining R2 of

0.944 and RMSE of 0.075 for the collection model, proving the importance of variables such

Х

as binder dosages, pelleting disc dosage and rotation rates, production and return volumes. The validation of the models highlights their potential for application in a real environment and opens space for further studies.

**Keywords**: Pelletizing, Balling, Operation, Estimation, Machine Learning, Artificial Intelligence

**Macrotheme:** Pelletizing Plants; **Research Line:** Information Technologies, Communication and Industrial Automation; **Theme:** Increase in Productivity at the Plant / Pelletizing; **Related Area of Vale:** Operation of Pelletizing Plants.

# Lista de Figuras

Figura 1 – Gabarito para teste de Número de Quedas	21
Figura 2 – Fluxo do Processo de Pelotização	26
Figura 3 – Exemplo de geração de superfície específica	28
Figura 4 – Modelo do processo de Moagem em Circuito Fechado, à Úmido	30
Figura 5 – Modelo de processo para as etapas de Homogeneização e Filtragem	33
Figura 6 – Processo na etapa de Prensagem.	34
Figura 7 – Processo na etapa de Mistura	35
Figura 8 – Disco de pelotamento mostrando a região de alimentação de minério e	
descarga das pelotas verdes, e o percurso do material	37
Figura 9 – Mecanismo de formação das pelotas	37
Figura 10 – Modelo de processo para a etapa do Pelotamento (Disco)	39
Figura 11 – Modelo de processo para a etapa da Queima (Grelha)	41
Figura 12 – Inteligência Artificial e Aprendizado de Máquina	47
Figura 13 – Gráfico ilustrativo da função "regressão" para estimação de valores	48
Figura 14 – Modelo de um Neurônio	51
Figura 15 – Problema de classificação com fronteiras de decisão e respectiva árvore de decisão	53
Figura 16 – Combinação de fronteiras de decisão para problemas de classificação	
em votação por maioria	
Figura 17 – Esquema de árvores de decisão em um modelo conjunto.	56
Figura 18 – Coleta de Dados do PIMS através do Excell e Addin Aspentech	
Infoplus.21	62
Figura 19 – Análise exploratória de dados. Variação da estatística descritiva "Antes"	
e "Depois" da atividade de limpeza de valores discrepantes.	64

Figura 20 – Histograma e Valores Discrepantes. Distribuição "normal" – variável	
Resistência de Pelota Seca	64
Figura 21 – Modelo dos métodos de aprendizado de máquina utilizados, através do	
Orange	66
Figura 22 – Divisão dos conjuntos de treinamento e validação.	66
Figura 23 – Modelo do Sensor Virtual	68
Figura 24 – Decision Tree – Índices de Erro x Profundidade da Árvore – Saída	
"Número de Quedas"	71
Figura 25 – Random Forest – Índices de Erro x Quantidade de Árvores – Saída "Número de Quedas"	72
Figura 26 – KNN – Índices de erro x Quantidade de Vizinhos – Saída "Número de	
Quedas"	73
Figura 27 – Histogramas de distribuição do Erro Absoluto – Saída "Número de	
Quedas"	75
Figura 28 – Gráficos de Dispersão – Saída "Número de Quedas"	76
Figura 29 – Gráficos "Previsto x Realizado" – Saída "Número de Quedas"	76
Figura 30 – Gráficos "Previsto x Realizado" – Saída "Resistência à Compressão de	
Pelotas Cruas"	77
Figura 31 – Gráficos de Dispersão – Saída "Resistência à Compressão de Pelotas	
Cruas"	78
Figura 32 – Gráficos "Previsto x Realizado" – Saída "Resistência à Compressão de	
Pelotas Secas"	79
Figura 33 – Gráficos de Dispersão – Saída "Resistência à Compressão de Pelotas Secas"	79
Figura 34 – Gráficos "Previsto x Realizado" – Saída "Umidade"	80
Figura 35 – Gráficos de Dispersão – Saída "Resistência à Compressão de Pelotas	
Secas"	81

### Lista de Tabelas

Tabela 1 – Influência de variáveis de qualidade da pelota crua na pelota queimada	18
Tabela 2 – Análise de Tempos e Movimentos para atividades laboratoriais de ensaios em pelotas cruas	23
Tabela 2 – Influência das principais variáveis de processo nas características das pelotas cruas.	43
Tabela 4 – Estatística Descritiva – Saída "Número de Quedas"	74
Tabela 5 – Estatística Descritiva – Saída "Resistência à Compressão – Pelota Crua"	77
Tabela 6 – Estatística Descritiva – Saída "Resistência à Compressão – Pelota Seca"	78
Tabela 7 – Estatística Descritiva – Saída "Resistência à Compressão – Umidade"	80

## Sumário

1.	Intro	odução	18
	1.1. Moti	vação	20
	1.2. Obje	tivos	22
	1.2.1.	Objetivo Geral	22
	1.2.2.	Objetivos Específicos.	22
	1.3. Bene	fícios (Estimativas de Ganhos)	23
	1.3.1.	Contribuições científicas	24
	1.3.2.	Contribuições industriais	24
2.	Proc	esso de Pelotização	26
	2.1. Emp	ilhamento e Recuperação de Minério – Pátio de Finos	27
	2.2. Moa	gem	28
	2.3. Espe	ssamento	31
	2.4. Hom	ogeneização	31
	2.5. Filtra	ngem	32
	2.6. Pren	sagem	34
	2.7. Mist	ura	35
	2.8. Pelo	amento	36
	2.9. Endu	recimento / Queima	39
	2.10. I	Peneiramento	42
	2.11.	Controle de Qualidade no Pelotamento	42
	2.11.1.	Dosagem de Carvão	43
	2.11.2.	Distribuição granulométrica das partículas de minério do pellet feed	43
	2.11.3.	Superfície Específica de Polpa Retida (Filtrada e Prensada)	44
	2.11.4.	Dosagem de Aglomerante	45

	2.11.5. Rotação	45
	2.11.6. Taxa de alimentação	45
	2.11.7. Taxa de Retorno - Carga circulante do pelotamento	46
	2.11.8. Umidade de Polpa Retida (Filtrada e Prensada)	46
3.	. Aprendizado de Máquina	47
	3.1. Aprendizado supervisionado	48
	3.2. Aprendizado de máquina e a estimativa de variáveis de processo	48
	3.2.1. Métricas para Avaliação de Desempenho de Modelos de Regressão	49
	3.3. Métodos de Aprendizado de Máquina	50
	3.4. Redes Neurais	50
	3.5. Árvores de Decisão, Bagging e Random Forests	52
	3.6. KNN – K Nearest Neighbors	56
4.	. Trabalhos Relacionados	58
5.	. Materiais e Métodos	61
5.	Materiais e Métodos	
5.		61
5.	5.1. Área de estudo	61 61
5.	<ul><li>5.1. Área de estudo</li></ul>	61 61
5.	<ul><li>5.1. Área de estudo</li></ul>	61 61 61
5.	<ul> <li>5.1. Área de estudo</li></ul>	616161
5.	<ul> <li>5.1. Área de estudo</li> <li>5.2. Arquitetura Lógica do Sistema</li> <li>5.3. Metodologia</li> <li>5.3.1. Entendimento do Negócio e de Dados</li> <li>5.3.2. Coleta e Preparação dos Dados</li> </ul>	61616161
<b>5.</b>	<ul> <li>5.1. Área de estudo</li> <li>5.2. Arquitetura Lógica do Sistema</li> <li>5.3. Metodologia</li> <li>5.3.1. Entendimento do Negócio e de Dados</li> <li>5.3.2. Coleta e Preparação dos Dados</li> <li>5.3.3. Modelagem</li> <li>5.3.4. Avaliação dos Resultados</li> </ul>	6161616161
	<ul> <li>5.1. Área de estudo</li></ul>	6161616161
	5.1. Área de estudo	6161616161657071

	6.4.	Umidade	80
7.		Conclusões	82
8.		Trabalhos futuros	85
9.		Referências Bibliográficas	86

#### 1. Introdução

O processo industrial de pelotização consiste na mistura úmida de finos de minério de ferro com granulometria inferior a 0,150 mm com quantidades pré-definidas de aglomerante, calcário, e carvão mineral, seguida de rolamento em disco ou tambor que promove a formação de um aglomerado esférico de tamanho entre 8 e 18 mm, as pelotas, e em seguida são submetidas a um tratamento térmico, garantindo elevada resistência mecânica, e propriedades metalúrgicas superiores (CAMPOS, CETEM, 2010).

A matéria-prima principal para o processo de queima no forno de endurecimento é a pelota crua, produzida pelos discos na etapa anterior de pelotamento. Estas pelotas devem possuir características físicas e químicas adequadas ao bom desempenho do processo de endurecimento. A Tabela 1 mostra a influência de algumas destas características no processo de queima (CAMPOS, CETEM, 2010).

Tabela 1 – Influência de variáveis de qualidade da pelota crua na pelota queimada

NAS PELOTAS CRUAS, QUANDO	NO PROCESSO DE QUEIMA
Aumenta a umidade da pelota crua,	<ul> <li>Aumenta a energia térmica requerida para secagem;</li> <li>Piora a qualidade física das pelotas queimadas.</li> </ul>
Diminui a resiliência,	Aumenta a alimentação do forno com pelotas "fracas" e/ou com trincas.
Aumenta a resiliência (acima de um limite aceitável), em função da umidade elevada,	<ul> <li>Aumenta a alimentação do forno com pelotas "plásticas";</li> <li>Diminui a permeabilidade do forno.</li> </ul>
Aumenta resistência à compressão da pelota crua e úmida ou seca,	Aumenta a estabilidade     (permeabilidade) do leito de pelotas.

Fonte: CAMPOS, CETEM, 2010.

Para garantir a qualidade das pelotas cruas, é prática comum às indústrias de pelotização realizar amostragens e análises de laboratório ao longo do processo produtivo. Este processo, no entanto, apresenta os inconvenientes de consumir recursos e principalmente tempo, fator

importante para a tomada de decisão para correção de variáveis de produção que impactam em custos e na qualidade dos produtos. Em função disto, a indústria de pelotização tem buscado soluções que permitam melhoria na produtividade deste processo (garantia da qualidade).

Como alternativa, as atividades de amostragem e análise laboratorial poderiam ser robotizadas, mas em grande parte dos casos, esta solução demonstra-se inviável economicamente. A opção por medição on-line de determinadas variáveis de qualidade em processos industriais complexos também se apresenta inviável tecnicamente, pela ausência de instrumentos específicos para este fim. Como alternativa viável técnica e economicamente, "sensores virtuais" têm sido desenvolvidos fazendo uso frequente de técnicas de aprendizado de máquinas e inteligência artificial.

Esta temática, no entanto, continua sendo um item de pesquisa bastante explorado devido às peculiaridades de cada produto e de cada processo envolvido.

Em linha com o que foi apresentado, este trabalho aborda especificamente o problema de estimativa de variáveis de qualidade na etapa de pelotamento de um processo industrial de pelotização de minério de ferro. Assim sendo, o problema abordado neste trabalho pode ser definido como se segue:

Dadas diversas variáveis do processo de Pelotização, deseja-se estimar automaticamente as variáveis de teor umidade, resistência à compressão de pelotas cruas, úmidas e secas, e resistência a quedas, - através de um sensor virtual baseado em técnicas de inteligência artificial e que seja capaz de lidar com diversos desafios, tais como:

- A. Custo computacional: o tempo de execução do sistema deve ser pequeno, permitindo sua aplicação em tempo real;
- B. Custo de hardware / software: o sistema deve ser composto por hardware / software de baixo custo de forma que a solução seja sustentável e viável economicamente (isto é, apresente uma taxa de retorno de investimento atrativa);
- C. Baixa qualidade dos dados: a aquisição pode ser afetada por ruídos provenientes de diversas fontes;

#### 1.1. Motivação

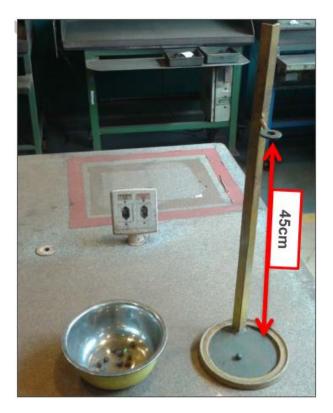
Oscilações no processo industrial de pelotização em variáveis como, por exemplo, granulometria, superfície específica, e taxas de dosagem de minério e insumos são inevitáveis, podendo ocasionar variações de qualidade nas pelotas. Desta forma, é necessário o monitoramento do processo de aglomeração (pelotamento) para identificação dos distúrbios existentes e tomada de ações corretivas de maneira a garantir qualidade do produto final (pelota queimada).

Como ainda é o padrão da indústria, o processo de garantia da qualidade da etapa de pelotamento é realizado através de ensaios em laboratórios.

Nos laboratórios das usinas de pelotização são feitas as análises do teor de umidade, do número de quedas das pelotas cruas (em quedas / pelota), e de resistência à compressão das pelotas cruas (verdes) e secas (em kgf/pelota), de forma a verificar a capacidade de resistência das pelotas quanto ao trajeto feito desde a saída dos discos até a entrada do forno, e a resistência para suportar as pressões da secagem e pré-queima. A umidade da pelota influencia diretamente os demais testes, visto que, uma pelota com pouca umidade possui baixa resistência ao número de quedas, tendo, porém, boa resistência à compressão.

- I. Teste de resiliência ou resistência a quedas ("drop test") Este ensaio tem como objetivo simular a resistência das pelotas cruas às diversas quedas que elas sofrem do disco de pelotamento até a grelha. Uma quantidade de pelotas cruas úmidas, sem trincas, e com granulometria entre 10 e 12,5 mm, é selecionada aleatoriamente. Cada pelota é solta em queda livre, individualmente, de uma altura de 45cm, várias vezes, até que apresente alguma trinca (Figura 1). O valor de resistência a quedas será dado pela média do número de quedas que as pelotas suportam sem apresentar trincas (MEYER, 1980, pg 80).
- II. Teste de resistência à compressão das pelotas cruas úmidas (RPC) e secas (RPS) Realizado com a finalidade de se conhecer a resistência do aglomerado à aplicação de uma carga contínua sobre ele. As pelotas não devem sofrer quebras até serem alimentadas não forno de grelha móvel, na etapa de queima. Neste teste, pelotas sem trincas, na faixa de 10 à 12.5m, são selecionadas aleatoriamente e submetidas à ação de uma força compressiva uniaxial em uma prensa de placas paralelas, até que ocorra a sua

- ruptura. O valor obtido será dado pela média aritmética das cargas registrada no momento da ruptura, dado em kgf/pelota (MEYER, 1980, pg 81).
- III. Umidade das pelotas cruas As pelotas são inicialmente pesadas para se obter a massa úmida (Peso Inicial). Em seguida são colocadas em estufas ou analisadores próprios, onde passam por um processo de secagem. Os aglomerados são pesados novamente para se obter a massa da pelota crua seca (Peso Final). A umidade é calculada através da equação: Umidade (%) = 100 \* (Peso Inicial Peso Final) /Peso Inicial.



 $\label{eq:Figura} Figura~1-Gabarito~para~teste~de~N\'umero~de~Quedas$   $\mbox{Fonte: VALE, PRO~008907-Preparo~e~Ensaios~de~Pelota~Verde}$ 

Após a conclusão dos ensaios, os técnicos de laboratório registram os resultados em uma base de dados de um sistema computacional (Nautilus<sup>1</sup>) para que as devidas ações

<sup>&</sup>lt;sup>1</sup> Nautilus software de propriedade da Thermo Fischer, é classificado como um LIMS – Sistema de Gerenciamento de Informações de Laboratório (*Laboratory Information Management System*), garantindo a confiabilidade dos resultados, rastreabilidade das informações, e atendimento a Normas Técnicas.

corretivas sejam executadas no processo produtivo. O operador da sala de controle acessa o sistema contendo as informações e toma as medidas de controle necessárias.

Este trabalho aborda o desenvolvimento de sensores virtuais baseados em aprendizado de máquina, para monitoramento de qualidade de pelotas cruas, cuja aplicação em um processo de pelotização permita maior agilidade na tomada de decisão para correção de oscilações do processo, garanta padronização e gere ganhos de qualidade e produtividade, e redução de custos e riscos.

#### 1.2. Objetivos

#### 1.2.1. Objetivo Geral

Este trabalho tem como objetivo geral propor um sistema para estimar variáveis de qualidade de pelotas cruas, de forma automática, na etapa de pelotamento do processo de pelotização de minério de ferro, possibilitando assim alavancar melhorias em indicadores qualidade, consequente redução de custos, e riscos de saúde e segurança ocupacional, e otimização do processo produtivo. Serão avaliadas as variáveis que influenciam significativamente a qualidade das pelotas cruas, e utilizada uma abordagem baseada em métodos de aprendizado de máquina para modelagem de um sensor virtual (preditor) tendo como entrada estes dados do processo obtidos em bases de dados históricos (PIMS) existentes.

#### 1.2.2. Objetivos Específicos

Para teste trabalho foram propostos os seguintes objetivos específicos:

- Propor, desenvolver e avaliar quatro sensores virtuais, usando diferentes técnicas de aprendizado de máquina (umidade, número de quedas, resistência a compressão de pelotas cruas e secas);
- II. Investigar parâmetros de configuração das técnicas de aprendizado de máquinas, buscando maximizar a acurácia das respostas;
- III. Propor e avaliar um método de coletânea;

#### 1.3. Benefícios (Estimativas de Ganhos)

A implementação de sensores virtuais para a estimativa das variáveis de qualidade em pelotas cruas permite o monitoramento das informações em tempo real, com a consequente atuação imediata no processo, além de aumentar a percepção de confiabilidade da informação, uma vez que se elimina a possibilidade de erros humanos.

O principal benefício (ganho) previsto é permitir a correção de distúrbios em etapas anteriores e a otimização **em tempo real**, através de sistemas de controle avançado, do perfil térmico do forno de pelotização nas etapas de secagem e pré-queima, com eventual redução do consumo específico de gás natural e energia elétrica com uso de ventiladores de processo. Uma vez implementada a lógica de otimização, os resultados poderiam ser quantificados através da aplicação de testes on-off (com e sem sensor virtual).

Além disto, com base em uma análise de "Tempos e Movimentos" para as atividades laboratoriais de ensaios em pelotas cruas (apresentada na Tabela 2), podemos afirmar que a implementação de sensores virtuais baseados em aprendizado de máquina permitiria eliminar tarefas manuais, tais como, a amostragem, transporte e a própria atividade de análise laboratorial de pelotas de minério de ferro, com consequente redução do tempo de exposição do trabalhador a riscos de saúde e segurança ocupacional inerentes às atividades, bem como otimizar a produtividade dos profissionais, e reduzir custos com manutenções corretivas e preventivas em equipamentos de laboratório. Observa-se que são necessárias cerca de 14,68 horas diárias de um profissional (em 2 turnos de trabalho) para a realização das atividades, considerando-se o parque instalado de 8 (oito) Usinas de Pelotização, em Vitória-ES.

Tabela 2 – Análise de Tempos e Movimentos para atividades laboratoriais de ensaios em pelotas cruas

Tarefa	Tarefas /dia	Qtde Usinas	Total Tarefas	Tempo/ Tarefa ** (min)	Tempo Total/dia (min)	Tempo Total/dia (horas)
Coleta de Amostras	2	8	16	11,19	179,04	2,98
Preparar Amostras	2	8	16	10,49	167,84	2,80
Resistência à compressão	4	8	32	9,48	303,36	5,06
Umidade	2	8	16	4,52	72,32	1,21
Número de Quedas	2	8	16	5,88	94,08	1,57
Armazenar Amostras	2	8	16	4,00	64,00	1,07

Total	880,64	14,68
	Improdutividade (40%) (horas)	5,87
Premissas:	Absenteísmo (2%) (horas)	0,12
*** considerando 1,5 horas para	Subtotal (Horas)	20,67
refeições e transporte	hours / turno (***)	1,97
1) Amostragem ocorre a cada 12 horas	# turno / dia	2
2) Turnos de 12 horas	Subtotal (FTE/turno)	0,98
3) Produtividade de 60%, logo,	Férias (8,33%)	0,08
12horas * 60% = 8.4 horas	Treinamentos (5%)	0,05
4) Referência de Tempos e Movimentos: 8ª Usina de Pelotização (Vitória-ES)	Total (FTE/turno)	1,12

Fonte: Elaborado pelo autor (2021)

Por fim, considerando que não foram identificadas na literatura técnica aplicação de sensores virtuais para determinação **destes parâmetros nesta etapa do processo produtivo de Pelotização de minério de ferro**, este desenvolvimento também representa uma inovação.

#### 1.3.1. Contribuições científicas

A contribuição científica do trabalho é o desenvolvimento da metodologia para modelagem de um preditor das variáveis de teor de umidade, resistência à compressão de pelotas cruas (secas e úmidas) e resistência a quedas, na etapa de pelotamento em uma Usina de Pelotização de minério de ferro. O trabalho contribui para demonstrar quais formas de préprocessamento e seleção de atributos são mais eficientes e demonstra o potencial da aplicação de algoritmos de aprendizado de máquina para estimativa de variáveis de qualidade em um processo produtivo sem a necessidade de intervenção humana.

#### 1.3.2. Contribuições industriais

A aplicação de um modelo de aprendizado de máquina para estimar variáveis, permite a mudança cultural da tradicional abordagem operacional de amostragem e análise laboratorial periódica. A análise de dados capturados em tempo real proporcionaria uma maneira de detectar oscilações na qualidade do produto, alimentando as equipes na planta com informações importantes para tomada de decisão e traria os seguintes ganhos:

- I. Aumento de qualidade e produtividade Estimativa precisa e objetiva, com margens de erros toleráveis, em intervalos de tempo pequenos o suficiente que permita que a intervenção seja efetuada antes da degradação da qualidade do produto e/ou do processo operacional;
- II. Otimização do perfil térmico do forno, com eventual redução do consumo específico de gás natural e energia elétrica com uso de ventiladores de processo, através da aplicação das variáveis preditas como entradas para Sistemas de Controle Otimizantes.
- III. Economia para a organização, pois permite a redução de custos com manutenções corretivas / preventivas em equipamentos de laboratório (ex: estufas, prensas, balanças, etc);
- IV. Redução de Riscos e Segurança Ocupacional A aplicação da metodologia em um processo automatizado com sensores virtuais iria promover a redução de exposição aos riscos de Saúde e Segurança Ocupacional, de pessoas (Homem-hora) em processos de amostragem, transporte, manipulação e análise laboratorial de amostras.

#### 2. Processo de Pelotização

As etapas envolvidas no processo de pelotização podem ser agrupadas em três estágios (MEYER, 1980, pg 23):

- I. Preparação A preparação das matérias primas tem por objetivo adequar as características do minério de ferro (*pellet feed*) e insumos à qualidade exigida para a produção de pelotas cruas.
- II. Pelotamento A formação de pelotas cruas também conhecida por pelotamento tem por objetivo aglomerar os finos de minério e aditivos para produzir pelotas com formato esférico com tamanhos adequados à necessidade do cliente, com resistência mecânica suficiente para suportar o impacto e a carga durante o transporte e tratamento térmico.
- III. Queima Confere às pelotas alta resistência mecânica e características metalúrgicas apropriadas após serem submetidas a um processamento térmico adaptado as características do material a ser processado e do produto requerido.

O processo de pelotização pode ser entendido através do fluxograma da Figura 2.

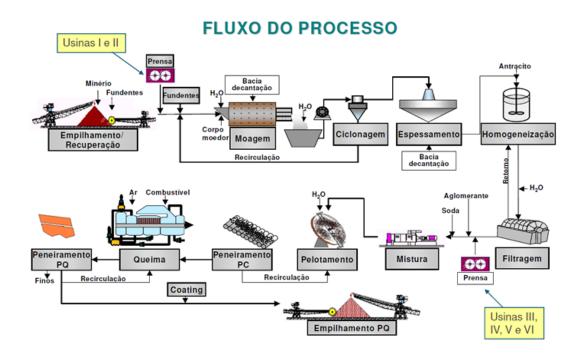


Figura 2 – Fluxo do Processo de Pelotização

FONTE: http://www.vale.com/PT/aboutvale/news/Paginas/entenda-funciona-processo-pelotizacao-usinas.aspx

A qualidade da produção das pelotas depende da eficiência e integração de todos os estágios do processo. Cada um deles é bastante influenciado pelo seu antecedente, por isto que um erro cometido em uma etapa qualquer, dificilmente poderá ser reparado por completo na próxima etapa (MEYER, 1980, pg 23).

Dentre os requisitos de qualidade que uma pelota deve apresentar destacam-se (MEYER, 1980, pg 3):

- I. Distribuição uniforme de tamanho (na faixa de 8 a 15 mm de diâmetro)
- II. Grande concentração de ferro (maior que 63%);
- III. Porosidade na faixa de 22 a 30%;
- IV. Resistência mecânica adequada;

#### 2.1. Empilhamento e Recuperação de Minério - Pátio de Finos

Os minérios utilizados nas Usinas de Pelotização da VALE localizadas na Unidade Tubarão são procedentes de diversas minas, sendo transportados até Vitória-ES via modal ferroviário.

Os finos de minério são descarregados – através de viradores de vagões – diretamente em correias transportadoras que os levam para serem formadas as pilhas por uma máquina empilhadeira (Empilhadeira de Finos).

O pátio de finos é a área onde são formadas as pilhas de minério para alimentação das usinas e onde acontece a primeira fase do processo de pelotização. Possui duas funções básicas:

- I. Estocar minérios e insumos para alimentação das usinas;
- II. Homogeneizar a matéria prima antes da recuperação.

Uma máquina recuperadora de caçambas (Recuperadora de Finos) desloca-se transversalmente à pilha (translação), transferindo o material das pilhas para um sistema de correias transportadoras interligadas aos silos de alimentação do circuito de moagem.

#### 2.2. Moagem

A moagem é o circuito responsável pela cominuição do minério onde são obtidos dois parâmetros físicos desejados: granulometria e superfície específica.

I. Superfície Específica – é a relação entre a somatória das áreas externas de um corpo e sua massa. Medida em laboratório com o auxílio de um aparelho chamado permeâmetro. De posse do valor da permeabilidade, consulta-se uma tabela de conversão para encontrar o valor da superfície específica. Medido em cm2/g. Podese afirmar que a soma das áreas externas de um corpo aumenta à proporção que este é fragmentado (Figura 3), ou seja, quanto maior for o grau de moagem e/ou prensagem sofrido pelo material, maior será a sua superfície específica, mantendose a massa total. **Quanto maior a superfície específica, melhor o rendimento da etapa de aglomeração (pelotamento)**. O material que alimenta o moinho tem superfície específica média de 450cm2/g e após a moagem é aumentada para em torno de 1750 cm2/g.

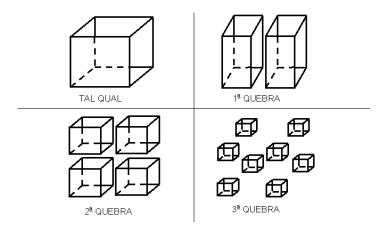


Figura 3 – Exemplo de geração de superfície específica

Fonte: Vale. REG 000291 – Manual de Operação Usinas de Pelotização, p133. 2012.

II. Granulometria – é a medição do tamanho das partículas de material a granel que pode ter duas unidades de medida, dependendo do material a ser analisado: mesh (#) ou mm. O teste de análise granulométrica é realizado em laboratório por uma peneira. Embora as usinas de pelotização recebam o pellet feed com granulometria inferior a 0,15 mm, a adequada formação das pelotas cruas requer um material com granulometria mínima de 80% inferior a 0,044 mm (JESUS, 2009).

A moagem é realizada em moinhos. Os moinhos são cilindros rotativos que possuem revestimentos internos em borracha ou aço e são carregados com corpos moedores de ferro fundido, chamado de *cylpebs* ou "bolas", ocupando aproximadamente 35% do volume interno útil do moinho.

Durante o movimento rotativo do moinho, os corpos moedores fragmentam o minério até as dimensões desejadas, por atrito e impacto (choque) com o minério.

Os circuitos de moagem podem ser classificados da seguinte forma (JESUS, 2009):

- I. Úmido o minério é alimentado ao moinho com adição de água em proporções ajustadas para resultar no teor de sólidos desenhado no interior do moinho. As usinas que possuem moagem a úmido e em circuito fechado necessitam das etapas de espessamento, homogeneização e filtragem. Já no circuito aberto, não utilizam o espessador.
- II. Seco A moagem a seco, por sua vez, exige a prévia secagem dos finos de minérios, dispensa as operações de espessamento, homogeneização e filtragem presentes na moagem a úmido. A moagem a seco para minério é utilizada nas regiões onde existe escassez de água, como por exemplo, no Oriente Médio.
- III. Fechado No circuito fechado os hidrociclones (a úmido) fazem a classificação do material descarregado pelo moinho. Após a classificação, o material mais fino é encaminhado para o espessador (a úmido) ou para o silo (a seco) e o mais grosso em ambos os casos, retorna ao moinho para ser remoído.
- IV. Aberto No circuito aberto, todo o material passa apenas uma vez pelo moinho e segue para os tanques homogeneizadores. Este tipo de operação dispensa o uso de baterias de hidrociclones e espessadores e não tem carga de recirculação.

A escolha por uma das modalidades de moagem depende das análises dos materiais a serem processados, além dos fatores de localização e ordem econômica. A proporção de valores de consumo energético para as duas situações varia com o tipo de minério, de modo que nenhuma regra geral pode ser fixada (MEYER, 1980, pg 64).

O processo de moagem é representado na Figura 4.

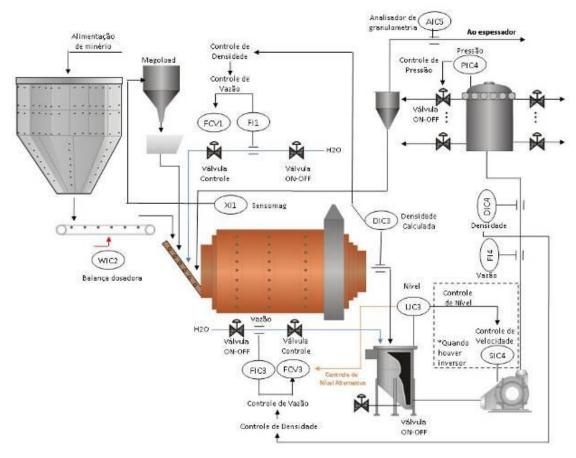


Figura 4 – Modelo do processo de Moagem em Circuito Fechado, à Úmido. Fonte: Vale, 2015

Nas usinas da Unidade Tubarão, a etapa de moagem é feita através de moinhos de bolas, em circuito úmido e fechado com emprego de hidrociclones na saída do moinho. O objetivo do subprocesso é diminuir a granulometria do minério que chega às etapas posteriores em 80 a 95% < 0,044 mm (325 mesh) e superfície na faixa de 1600 à 2000 cm2/g (JESUS, 2009).

Após moído, o minério (polpa) segue para o tanque de descarga onde água é adicionada à polpa, reduzindo o percentual de sólidos para a faixa de 40 a 50% (JESUS, 2009). Esta diluição faz-se necessária para aumentar a fluidez da mistura e propiciar a classificação das partículas por tamanho no processo de ciclonagem, com a utilização das forças centrífuga e gravitacional no interior de hidrociclones. A polpa diluída alimenta a bateria de hidrociclones que têm como função separar a parte da polpa que ainda apresenta granulometria e densidade maior que a desejada (*underflow*). Essa parcela de material realimenta o moinho de bolas passando por novo processamento. A outra parcela que apresenta granulometria adequada

(*overflow*) segue para o espessador que tem como objetivo retirar parte da água constituinte da polpa, passando de cerca de 20% para 70% o total de sólidos que constituem a polpa.

#### 2.3. Espessamento

O objetivo do espessamento é adequar o percentual de sólidos do *overflow* (transbordo) da ciclonagem no processo de moagem às necessidades da filtragem. Ao passar pela etapa de espessamento, a densidade de sólido da polpa de minério aumenta de 1,20 kg/l para aproximadamente 2.5 kg/l.

O espessador é o equipamento utilizado para promover o aumento da densidade por meio da sedimentação/decantação das partículas de minério de ferro e pelo transbordo do excesso de água no espessador. O seu formato cilíndrico, com o fundo cônico, facilita a movimentação da polpa decantada para o anel central (zona de descarga). O minério, por possuir peso específico superior ao da água, precipita-se, enquanto a água direciona-se para a periferia do espessador, transbordando para o tanque de processo, via calha de *overflow*. A água transbordada é recuperada e reutilizada na moagem.

#### 2.4. Homogeneização

Após o espessamento, a polpa de minério é bombeada para os tanques homogeneizadores.

Uma das funções do tanque homogeneizador é armazenar a polpa com o objetivo de garantir a matéria prima para a próxima fase do processo produtivo, prevenido eventuais paralizações em etapas anteriores e posteriores (SILVA 2010), possuindo capacidade para armazenar uma quantidade de polpa suficiente para manter uma usina funcionando por um tempo aproximado de 6 a 8 horas.

Além disto, nesta etapa, a polpa de minério é misturada à polpa de carvão com a finalidade de reduzir o consumo de combustível requerido para que ocorra a combustão interna da pelota na etapa da queima. A homogeneização desta mistura é realizada por intermédio de um agitador rotativo (hélice) que mantem os sólidos em suspensão, minimizando variações das características físicas e químicas do material: Quanto mais cheios estiverem os tanques

homogeneizadores, menores serão os efeitos negativos das oscilações da qualidade da polpa ciclonada.

O sistema de controle de adição de combustível sólido (carvão) processa as seguintes variáveis, para proceder a dosagem:

- A. Alimentação de minério ao tanque homogeneizador (base seca). No caso de operação em circuito fechado, é calculado a partir da vazão e densidade da polpa recalcada pelas bombas sob o espessador.
- B. Quantidade de combustível sólido (carvão) bombeado para o tanque homogeneizador (base seca). Cálculo efetuado a partir do volume recalcado de polpa e de sua densidade.
- C. Percentual de carbono fixo contido no combustível sólido. Carbono fixo é a massa energética contida no combustível sólido, variando em função do grau de pureza do produto utilizado. Dado fornecido e atualizado diariamente pelo laboratório químico.

Cuidados especiais devem ser tomados para que não haja flutuação no percentual de combustível sólido adicionado à polpa de minério, pois adições a menor comprometem a qualidade das pelotas queimadas e adições excessivas poderão ocasionar fusão parcial da carga no forno por excesso de queima, comprometendo a qualidade e gerando riscos de paralisações por entupimentos gerados por cachos ou queima das correias na descarga da grelha. Componentes dos fornos também poderão ser danificados por uso excessivo de combustível sólido.

#### 2.5. Filtragem

Na filtragem ocorre a diminuição do teor de água da polpa de minério de 30% para cerca de 9%, que é a **faixa de umidade considerada adequada para a formação das pelotas cruas no pelotamento** (SILVA, 2010).

A polpa, contendo aproximadamente 30% de água, é bombeada dos tanques homogeneizadores, para um tanque distribuidor localizado acima do nível dos filtros. Por gravidade, este tanque distribuidor alimenta cada filtro.

A filtragem é realizada em filtros de discos rotativos à vácuo, composto por seções (setores) recobertas por um meio filtrante através das quais escoa a polpa, e sob o qual os sólidos são depositados para formar a torta. Uma diferença de pressão entre a bacia de polpa do filtro e a superfície do meio filtrante é instituída por ação de bombas de vácuo, permitindo a passagem do filtrado (líquido) através do meio filtrante, enquanto as partículas sólidas de minério são retidas nesse meio, formando a torta de filtração.

A polpa retida (torta) é soprada por ação de ar comprimido gerado por compressores sopradores, sendo descarregada do filtro e transportada através de correias transportadoras até um silo de armazenagem da área de prensagem (próxima etapa de processo).

O desempenho da filtragem é verificado através de análises laboratoriais das variáveis de **umidade, granulometria e superfície específica da polpa retida**.

O processo da homogeneização e filtragem é representado na Figura 5.

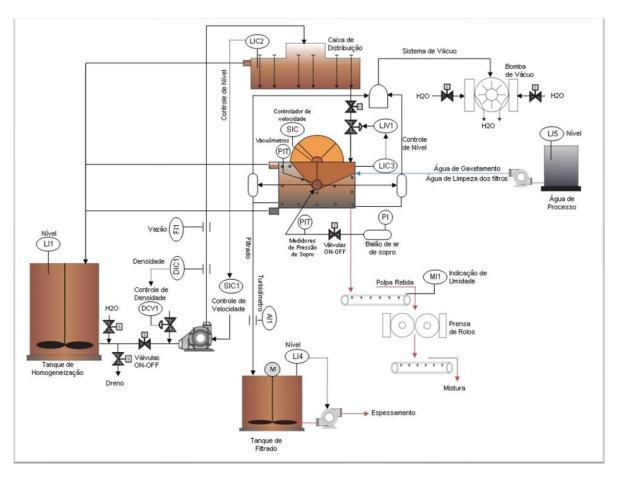


Figura 5 – Modelo de processo para as etapas de Homogeneização e Filtragem.

Fonte: VALE, 2015

#### 2.6. Prensagem

Na prensagem o minério passa num fluxo contínuo entre dois rolos e suas partículas são submetidas a elevadas pressões para gerar a fragmentação das mesmas e **elevar a superfície específica**. A cominuição ocorre tanto entre os rolos e as partículas de minério quanto entre as próprias partículas.

Depois de prensado, o minério é descarregado em transportadores de correia e segue para a área da mistura onde irá receber os insumos necessários para o processo de pelotamento.

A etapa de prensagem pode ser observada na Figura 6

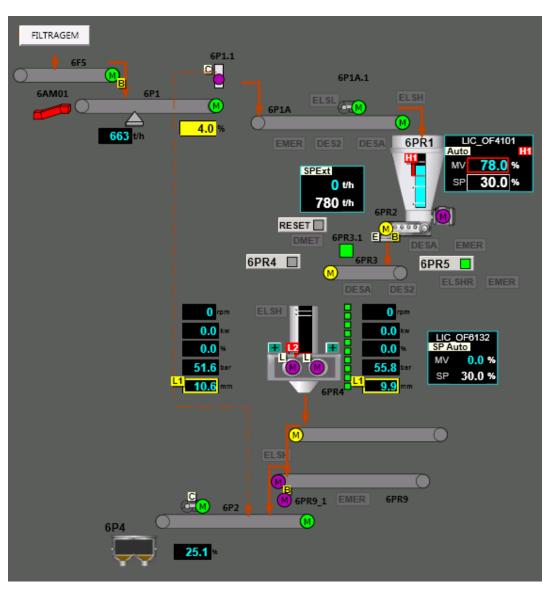


Figura 6 – Processo na etapa de Prensagem.

Fonte: VALE, Sistema de Supervisão e Controle ABB 800xA, 2021

#### 2.7. Mistura

Na etapa da mistura é feita a adição de aglomerantes.

Ao material proveniente da filtragem / prensagem, denominado polpa retida, adicionase estes insumos através de uma balança dosadora de precisão, a partir das descargas dos silos de aglomerantes. A homogeneização da mistura polpa retida / aglomerante é feita em misturadores cilíndricos rotativos. Em seguida, o material é transferido via correias transportadoras para os silos dos discos de pelotamento, concluindo-se, assim, a etapa de preparação das matérias primas (Figura 7) (JESUS, 2009).

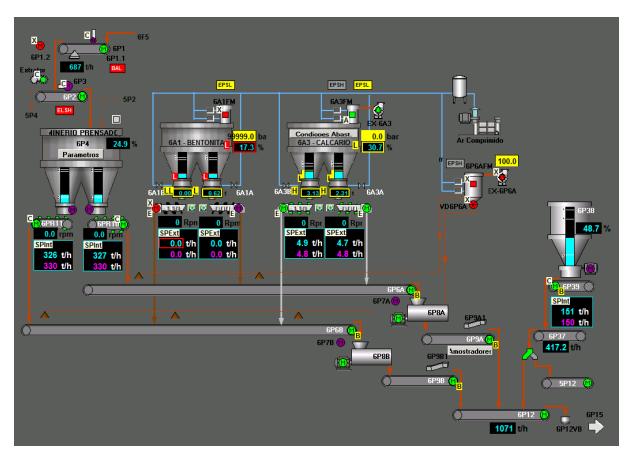


Figura 7 – Processo na etapa de Mistura

Fonte: VALE, Sistema de Supervisão e Controle ABB 800xA, 2021

A utilização de aglomerantes no processo de pelotização tem como objetivo principal auxiliar o processo de formação das pelotas e dotá-las de resistência física necessária para

suportar o transporte e as quedas sofridas no trajeto entre os discos e o forno. O aglomerante também capacita as pelotas a suportar as compressões sofridas nas fases de secagem ascendente e descendente e pré-queima que antecedem o processo de queima. A quantidade dosada depende do tipo de aglomerante e das características das pelotas a serem produzidas, sendo adicionado á polpa retida (*pelled feed*) proveniente da filtragem através de balanças dosadoras. Os produtos mais utilizados são a bentonita (mistura de argilas), a cal hidratada (Ca(OH)2), o calcário (rochas sedimentares com mais de 30% de carbonato de cálcio) e a dolomita (mineral de carbonato de cálcio e magnésio - CaMg(CO3)2). Alguns desses aglomerantes como a dolomita, a cal hidratada e o calcário, podem ser usados simultaneamente como aditivos para modificar a composição química das pelotas, servindo especialmente para corrigir a basicidade (BORIM, 2000).

#### 2.8. Pelotamento

O pelotamento é o processo de formação de pelotas cruas (ou pelotas "verdes") com tamanho e resistência mecânica adequada para a etapa do processamento térmico (queima).

A preparação das matérias primas é finalizada quando a mistura (polpa retida com insumos) é transferida através de correias transportadoras para os silos que fazem a alimentação dos discos / tambores de pelotamento.

Os discos são atualmente os equipamentos mais utilizados para a produção de pelotas de minério de ferro em escala industrial. Possuem formato de prato, velocidade de 5 a 7 rpm e inclinação média de 45°. A capacidade de produção varia aproximadamente de 90 a 170 t/h, dependendo da concepção do projeto (SILVA, 2010).

O processo de formação das pelotas em um disco de pelotamento é similar ao de uma bola de neve rolando numa ladeira íngreme, o que resulta num corpo redondo (SILVA, 2010).

CAMPOS (CETEM, 2010) descreve que a disposição e a forma de operação do disco permitem a classificação das pelotas em função do diâmetro, devido a combinação da força centrífuga e do próprio peso das pelotas formadas, conforme mostrado na Figura 8. O minério é alimentado numa determinada posição do disco. As partículas finas sofrem rolamentos sucessivos acarretando a formação gradativa de aglomerados em forma de pelotas. Os

raspadores funcionam como direcionadores de fluxo, orientando a trajetória dos aglomerados de diferentes tamanhos até sua descarga, na região oposta à da alimentação.

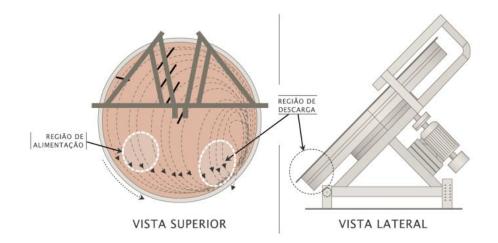


Figura 8 – Disco de pelotamento mostrando a região de alimentação de minério e descarga das pelotas verdes, e o percurso do material.

Fonte: TOMAZINI, et al (2019)

CAMPOS (CETEM, 2010) afirma que a água é o principal agente na formação das pelotas cruas, preenchendo vazios intersticiais entre as partículas de minério, formando um sistema capilar com múltiplas ramificações. Quando as extremidades dos capilares atingem a superfície externa da pelota (constituindo poros externos) a sucção capilar desenvolvida na interface ar/água provoca uma reação de igual intensidade sobre os grãos, mantendo as partículas unidas. Nestas condições, as pelotas cruas adquirem resistência a tensões mecânicas.

MEYER (1980) descreve o processo de formação das pelotas apresentado na Figura 9, conforme a seguir.

A B C D E F

Figura 9 – Mecanismo de formação das pelotas

Fonte: MEYER, 1980, p.26

- A. As partículas individuais de minério são recobertas por uma película de água e tocamse umas nas outras
- B. Devido a tensão superficial da água são formadas pontes liquidas entre as partículas.
- C. Os movimentos sucessivos de rolamento das partículas no interior do equipamento de pelotamento e a combinação de gotículas de água contendo uma ou mais partículas minerais levam a formação dos primeiros aglomerados.
- D. O número de pontes líquidas que une as partículas aumenta e os aglomerados são adensados, com crescente preenchimento dos poros com água.
- E. As forças capilares das pontes líquidas têm grande importância na formação das pelotas. O ponto ideal desta fase é atingido quando todos os poros internos estão preenchidos com água, porém o aglomerado ainda não está recoberto externamente por uma película uniforme de água.
- F. O estágio ideal é alcançado quando a pelota crua é totalmente recoberta por uma película de água. Nesta situação, o efeito das forças capilares é reduzido sensivelmente, permanecendo ativa apenas a tensão superficial da água.

Antes de serem enviadas para o forno, as pelotas cruas passam pela peneira de rolos onde as pelotas pequenas (menores que 8mm) e grandes (maiores que 18mm) são desviadas e devolvidas para o início do processo de pelotamento (SILVA, 2010).

A Figura 10 descreve o modelo de processo para a etapa do pelotamento.

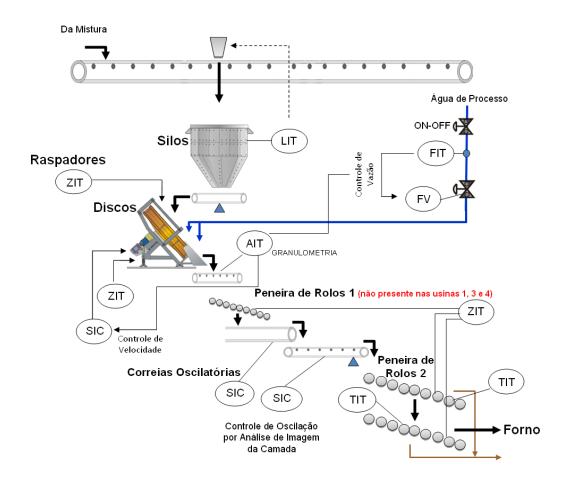


Figura 10 – Modelo de processo para a etapa do Pelotamento (Disco)

Fonte: VALE, 2015

## 2.9. Endurecimento / Queima

A etapa da queima refere-se ao tratamento térmico que confere alta resistência mecânica (daí, o termo "endurecimento") e propriedades metalúrgicas adequadas às pelotas que serão utilizadas nos reatores de redução e alto-fornos siderúrgicos.

Nas usinas de pelotização situadas no Brasil, o endurecimento das pelotas cruas é feito por um tipo de forno denominado "Forno de Grelha Móvel" (*Travelling Grate*).

Após o peneiramento, as pelotas cruas são distribuídas nos carros de grelha sobre uma camada de pelotas queimadas ("camada de forramento") com a função de evitar o choque térmico entre as pelotas cruas e o carro de grelha aquecido, o que resultaria na degradação das pelotas cruas, impermeabilizando o forno.

A grelha móvel funciona como uma espécie de esteira, transportando as pelotas no interior do forno, para que as mesmas sejam submetidas a altas temperaturas de acordo com o perfil térmico pré-definido.

Em um forno de grelha móvel, o aquecimento dos gases ocorre através da combustão de gás natural ou óleo combustível nos queimadores. Os gases, responsáveis pela secagem, queima e resfriamento das pelotas, são transportados no interior do forno através de tubulões com o auxílio de ventiladores

O processo de queima a que são submetidas as pelotas cruas pode ser dividido nas seguintes etapas (JESUS, 2009):

- I. Secagem Ascendente e Descendente: As pelotas, com umidade em torno de 9% e temperatura próxima da do ambiente, são expostas bruscamente à ação de gases quentes, a uma temperatura de 320 a 400° C. Nesta etapa, as pelotas devem perder seu conteúdo de água, preservando sua integridade física, resistindo às tensões internas que surgem em função da evaporação da água contida nos poros e às pressões dos gases quentes.
- II. Pré-queima: As pelotas secas são pré-aquecidas a uma temperatura aproximada de 900°C, de forma a garantir o máximo tempo de exposição das pelotas à temperatura de queima, na etapa subsequente. Nesta etapa é grande o risco de choque térmico, devido à brusca e acelerada elevação da temperatura. A resistência mecânica das pelotas deve ser suficiente para suportar este impacto, sem a ocorrência de choque térmico, que leva a fissura, trincas e à própria desintegração das pelotas, gerando grande quantidade de finos, com consequente perturbação da produção, perda em rendimento e maior desgaste do equipamento de queima.
- III. Queima: Nesta etapa as pelotas são submetidas à máxima temperatura do ciclo térmico, que atinge valores da ordem de 1.300 a 1.350°C, dependendo do tipo de pellet feed e da composição química da pelota que está sendo produzida. Sob estas condições ocorre a consolidação final do produto. As ligações que se estabelecem entre os grãos são diretamente influenciadas pela temperatura, e tempo de permanência da carga nesta temperatura. As pelotas adquirem alta resistência mecânica e características metalúrgicas apropriadas para utilização nos reatores siderúrgicos.
- IV. Pós-Queima: Esta etapa existe apenas nos sistemas que utilizam fornos de grelha reta e tem por objetivo favorecer a homogeneização térmica do leito de pelotas. É uma etapa de curta

- duração na qual o calor é transferido ao longo do leito, melhorando as condições de queima das pelotas das camadas inferiores.
- V. Resfriamento: A última etapa do ciclo, o resfriamento, é de grande importância, pois influência no rendimento térmico do forno. Nesta parte recupera-se o calor absorvido pelas pelotas ao longo do processamento térmico. A recuperação do calor é feita por ventiladores que succionam o ar quente, e em seguida os levam para serem utilizados nas etapas de secagem, pré-queima e queima.

Todo o ar utilizado no forno, antes de ser devolvido para a atmosfera, deve passar pelos precipitadores eletrostáticos, com o objetivo de remover todas as suas impurezas. Os finos de minério retido por estes equipamentos são retornados nas etapas iniciais do processo de pelotização.

A Figura 11 descreve o modelo de processo para a etapa de endurecimento de pelotas (queima).

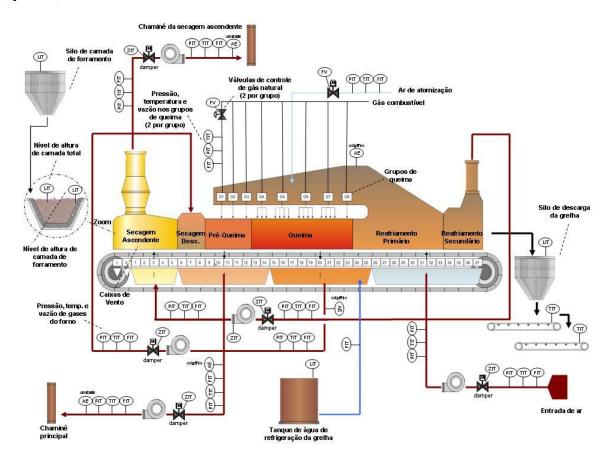


Figura 11 – Modelo de processo para a etapa da Queima (Grelha)

Fonte: VALE, 2015

#### 2.10. Peneiramento

Depois do tratamento térmico, as pelotas são levadas pelas correias transportadoras para a estação de peneiramento (JESUS, 2009).

A peneira opera com vibração permanente e distribui as pelotas por toda a extensão das malhas, durante deslocamento para baixo devido a inclinação e vibração da peneira.

As pelotas de produção são descarregadas sobre uma malha de 12,5mm. As pelotas menores seguem para a malha de 5mm, que por fim seguem para um primeiro chute, onde posteriormente os finos são retirados e transferidos para a área do porto por caminhões basculantes e misturados ao minério *sínter feed* para serem vendidos a clientes que possuem usinas de sinterização. As pelotas maiores que 5mm e menores que 12,5mm são descarregadas em um segundo chute, de onde vão para correias que as transportam até o pátio de pelotas (produção). Pelotas com tamanhos acima de 12,5mm são transferidas para uma malha de 24mm, abastecendo um terceiro chute que fornecerá pelotas para formação da camada de forramento dos carros de grelha, servido de leito para as pelotas cruas.

Concluído o processo de classificação das pelotas, as pelotas são empilhadas para posterior recuperação e envio aos clientes (embarque de navios).

## 2.11. Controle de Qualidade no Pelotamento

A performance de um disco de pelotamento é uma função direta de fatores tais como, a avaliação do atendimento a produção (taxas em toneladas/hora), ao tamanho médio ideal das pelotas (distribuição granulométrica) e a resistência mecânica das mesmas.

O alcance dos objetivos de performance (qualitativos e quantitativos) na operação dos discos de pelotamento é obtido através do monitoramento e o controle do teor de umidade, e da resistência de pelotas cruas – fatores importantes para manutenção da qualidade da pelota crua, e que possuem relação direta com outras variáveis de processo, e que, portanto, devem ser controladas para se adequarem à formação das pelotas. Desta forma, é de extrema importância conhecer a influência direta dessas variáveis no resultado final do processo produtivo (exemplos: natureza dos insumos - taxas de dosagem de carvão da etapa de homogeneização, distribuição granulométrica, superfície específica e umidade da polpa retida (filtrada e prensada), taxas de adição de aglomerantes na etapa de mistura, rotação e taxas de dosagem /

produção e retorno, e rotação dos discos de pelotamento, tempo de residência, e aspectos mecânicos não variáveis no tempo – posição de alimentação, da altura e posição dos raspadores, e da inclinação do disco) (MEYER, 1980).

As principais variáveis de processo e suas influências nas características das pelotas cruas são mostradas resumidamente na Tabela 3 e descritas a seguir.

Tabela 3 – Influência das principais variáveis de processo nas características das pelotas cruas.

			Tempo de residência do material	Acabamento superficial	Tamanho de pelotas	Homogeneidade do material na descarga do disco	
-	S. Específica	MAIOR	MAIOR	MELHOR	MENOR	MAIOR	
Pellet Feed	Umidade	MAIOR	MENOR	PIOR	MAIOR	MENOR	
	% < 325#	MAIOR	MAIOR MELHOR		MENOR	MAIOR	
Discos	Rotação	MAIOR	MAIOR	MELHOR	MAIOR	MENOR	
	Profundidade útil	rofundidade útil MAIOR		MELHOR	MAIOR	MAIOR	
	Tonelagem de alimentação	MAIOR	MENOR	PIOR	MENOR	MENOR	
	Inclinação	MAIOR	MENOR	PIOR	MENOR	MENOR	
	Granulometria dos insumos	MAIOR	MAIOR	MELHOR	-	MAIOR	

Fonte: Campos, CETEM, 2010

### 2.11.1. Dosagem de Carvão

O Carvão Mineral é responsável por introduzir energia térmica no processo de endurecimento da pelota, reduzindo parcialmente o consumo de combustível. Dada a sua característica higroscópica, possui a propriedade de absorver a água contida na polpa. Se dosado em excesso na etapa de homogeneização, a primeira providência a tomar, é reduzir a produção dos discos de pelotamento, de forma a corrigir a granulometria das pelotas, e evitar a formação de cachos com consequente parada da etapa de queima (parada de usina).

## 2.11.2. Distribuição granulométrica das partículas de minério do pellet feed

Um fator importante que afeta a resistência das pelotas cruas e queimadas (resistência à compressão e resiliência ou resistência a quedas) é a distribuição granulométrica do minério – variável muito importante para o controle da porosidade das pelotas.

Se a distribuição granulométrica é ampla, ou seja, variando desde a fração menor que 10µm até a fração passante em 0,044 mm, a resistência dos aglomerados é alta devido ao melhor empacotamento e ao grande número de pontos de contato, alterando a porosidade dos aglomerados (o que influencia nas propriedades das pelotas queimadas) (CAMPOS, CETEM, 2010). Partículas muito finas, durante a formação das pelotas, ocupam os espaços vazios (poros) dos aglomerados, reduzindo os interstícios e as ramificações capilares do sistema, favorecendo o aumento da densidade da pelota.

## 2.11.3. Superfície Específica de Polpa Retida (Filtrada e Prensada)

Variável que interfere diretamente na granulometria das pelotas e em sua resistência.

A superfície específica determina a capilaridade dos vasos da pelota. Quanto mais alta for a superfície específica, maior será a capilaridade dos vasos, tendo como consequência a formação de uma pelota mais compacta, mais polida e de **maior resistência mecânica**. O aumento da superfície especifica reduz o tempo de retenção do minério para a formação da pelota, uma vez que em seu percurso haverá menor contato com os finos alimentados no disco, e, portanto, as pelotas produzidas terão seu diâmetro reduzido. Para compensar esta redução do diâmetro da pelota, o sistema de controle deve atuar em outras variáveis, como por exemplo, na redução da produção do disco, ou no aumento da rotação dos discos.

O material que alimenta o pelotamento deve apresentar superfície específica na faixa ideal, entre 1400 e 2100 cm²/g.

- I. Material com SE muito alta O tempo de residência para formação da pelota será menor, causando a diminuição do tamanho das pelotas, além de gerar aglomeração de material nos discos e excesso de finos. Neste caso, deve-se aumentar a rotação do disco e reduzir a produção dos discos até que se consiga a granulometria desejada da pelota.
- II. Material com SE muito baixa O tempo de residência para formação da pelota será maior, produzindo pelotas grandes, ásperas e sem resistência. Neste caso, deve-se reduzir a rotação do disco, e/ou aumentar a taxa produção do pelotamento dos discos. Caso isto não seja possível, opcionalmente é possível parar um disco e distribuir sua produção entre os demais.

## 2.11.4. Dosagem de Aglomerante

O aglomerante, devido à sua característica aglutinante, atua na união das partículas de minério durante a etapa de pelotamento, proporcionando maior resistência mecânica às pelotas, fator importante para o transporte até a etapa de queima.

O excesso de dosagem de aglomerante na etapa de mistura irá secar o material, de forma que os discos de pelotamento tenderão a produzir pelotas de tamanho reduzido. Neste caso, deve-se imediatamente aumentar a rotação dos discos e/ou reduzir a produção, de forma a adequá-la à granulometria ideal para a etapa de queima.

A redução na dosagem de aglomerantes deixará o material úmido e **sem resistência mecânica**, o que acarretará a geração de finos e formação de cachos durante o processo de queima.

Nestes casos mais graves, onde as pelotas produzidas poderão comprometer a permeabilidade no forno, a produção do referido disco deverá ser retornada, até que a granulometria das pelotas produzidas atinja a condições ideais de queima.

### 2.11.5. **Rotação**

A variação de velocidade interfere diretamente no ajuste da granulometria das pelotas cruas. Aumentando a rotação do disco, o percurso do material em seu interior será maior, devido ao aumento da força centrífuga criada sobre as pelotas em movimento. O tempo de residência para formação da pelota será maior, aumentando a captação de partículas de minério, e consequentemente, o tamanho das pelotas. Quando rotação do disco é reduzida, o percurso do material em seu interior é menor, fazendo com que o tamanho das pelotas diminua. Rotações muito baixas tendem a causar aglomeração de material no disco, gerando pelotas malformadas e finos. Já na situação inversa aumenta-se significativamente a carga constante de material no disco, podendo causar sobrecarga no motor de acionamento.

#### 2.11.6. Taxa de alimentação

Igualmente à rotação, a taxa de alimentação influencia diretamente no tempo de residência do minério para a formação das pelotas. Elevadas taxas de alimentação geram pelotas fora do tamanho desejado, com menor resistência e que se desfazem no momento seguinte à saída do disco, gerando assim, partículas finas (CAMPOS, CETEM, 2010).

## 2.11.7. Taxa de Retorno - Carga circulante do pelotamento

As pelotas e aglomerados produzidos pelos discos de pelotização que são rejeitados no processo classificação por peneiras de rolos ( $\leq 8$ mm, e  $\geq 16$ mm), retornam ao processo de pelotamento, e são chamados de carga circulante (*undersize* e *oversize*). Pelotas cruas muito grandes ou muito pequenas, e aglomerados de baixa resistência mecânica se quebram devido as quedas envolvidas no transporte, gerando finos que também constituem a carga circulante do processo de aglomeração. A quantidade de finos na carga circulante é, portanto, diretamente influenciada pela resistência a quebras das pelotas cruas (NUNES, 2007).

# 2.11.8. Umidade de Polpa Retida (Filtrada e Prensada)

A umidade é definida como o percentual de água (em peso) contido em um determinado material ou mistura de materiais. A medição é feita em laboratório. A variável interfere diretamente nas forças de ligação entre as partículas, consequentemente na distribuição granulométrica das pelotas e em sua resistência à compressão.

O aumento da umidade acelera o processo de formação da pelota, também aumentando o seu diâmetro. O aumento excessivo da umidade prejudica a qualidade das pelotas cruas (saturação dos poros), com redução da resistência à compressão e ao número de quedas, além de permitir a ocorrência de trincas durante etapa de secagem e elevar o consumo específico de combustível e energia elétrica no processo de queima.

Umidade baixa - É preciso trabalhar com muita atenção com este tipo de material, visto que a variação da granulometria é uma constante. A falta de resistência das pelotas e as variações provocam um retorno muito alto de finos. É necessário que seja evitado que estes finos entrem no forno, pois isso acarretaria a vedação do mesmo (redução da permeabilidade), com consequente produção de cachos.

O ideal é controlar a umidade do *pellet feed*, de forma que no pelotamento haja um nível de saturação de poros que resulte em resistência à compressão aceitável ao processo.

# 3. Aprendizado de Máquina

O desafio de resolver problemas cada vez mais complexos provocou o desenvolvimento de sistemas ditos "inteligentes" que modelam a inteligência biológica de seres vivos. Estes sistemas, que formam o campo da **Inteligência Artificial** (IA), são compostos por algoritmos inteligentes que envolvem lógica, raciocínio dedutivo, sistemas especialistas e sistemas de aprendizado de máquina (RUSSEL e NORVING, 2010).

**Aprendizado de Máquina** (do inglês *Machine Learning* - ML) é um ramo da IA que tem como principal característica o auto-aprendizado a partir de exemplos: aplicar modelagens estatísticas para detectar padrões e melhorar performance baseando-se em dados e informação empírica (experiência passada), reduzindo a necessidade de intervenção humana (FACELI, 2011, p3).

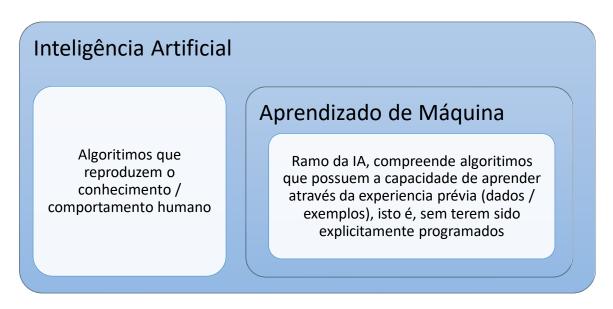


Figura 12 – Inteligência Artificial e Aprendizado de Máquina Fonte: Elaborado pelo autor (2021)

Em aprendizado de máquina, os dados (vetores de entradas e saídas) são divididos em conjunto de treino e conjunto de testes. O conjunto de treino é utilizado para desenvolver o modelo. Após o desenvolvimento do modelo, ele pode ser testado com um novo conjunto de dados (conjunto de testes). O modelo treinado e testado, de forma satisfatória pode ser utilizado então para reconhecer padrões e realizar classificações e predições, tomar decisões, etc (FACELI, 2011, p4).

## 3.1. Aprendizado supervisionado

Segundo FACELI (2011, p6), o termo "supervisionado" vem da "simulação de um supervisor externo que conhece a saída desejada de cada exemplo de entrada". Neste tipo de aprendizado, o modelo é alimentado com exemplos com vários atributos de entrada e o valor correto de saída ("rótulo") para os dados. O algoritmo então decifra os padrões de atributos que existem no conjunto de dados e cria um modelo que pode reproduzir as mesmas regras com um novo conjunto de dados. Exemplo de Algoritmo: Redes Neurais Perceptron Multicamadas, Árvores de Decisão, *Random Forests*, etc.

## 3.2. Aprendizado de máquina e a estimativa de variáveis de processo

FACELI (2011) afirma que em tarefas de estimação de variáveis, o objetivo dos métodos de aprendizado de máquina é encontrar uma função (também chamada de "modelo") a partir de um conjunto de exemplos (dados de treinamento) que possa ser utilizada para prever um valor de uma variável resposta Y, com base nos valores de seus atributos de entrada (variáveis preditoras X) (Figura 13). Para isso, cada objeto do conjunto de treinamento deve possuir atributos de entrada e de saída, seguindo o paradigma do aprendizado supervisionado.

Uma definição formal seria (FACELI, 2011):

Dado um conjunto de observações de pares  $D = \{(x_i, f(x_i), i=1, ..., n\}, em$  que  $f(x_i)$  representa uma função desconhecida, um algoritmo de aprendizado de máquina preditivo aprende uma aproximação (modelo) da função desconhecida  $f(x_i)$ . Essa função aproximada permite estimar o valor de  $f(x_i)$  para novas observações de  $x_i$ .

 $y_i = f(x_i) \in \Re$ , ou seja,  $f(x_i)$  assume valores em um conjunto infinito e ordenado de valores.

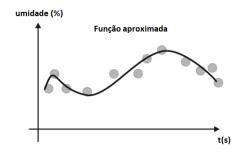


Figura 13 – Gráfico ilustrativo da função "regressão" para estimação de valores

Fonte: FACELI, 2011

## 3.2.1. Métricas para Avaliação de Desempenho de Modelos de Regressão

O propósito de um modelo de regressão é aplicá-lo para estimativa de uma variável / predição de novos dados (instâncias). Para tanto, torna-se necessário fazer avaliações para se medir a acurácia dos modelos criados pelos algoritmos de aprendizado de máquina. As principais métricas conhecidas e utilizadas para avaliar o desempenho dos modelos de regressão são (FACELI, 2011, p160):

I. MSE (Mean Squared Error): Os erros (valor real – valor predito) são elevados ao quadrado antes de ter a média calculada. Por conta do expoente ao quadrado, essa métrica é bastante sensível a valores discrepantes. Conforme os valores de erros das ocorrências aumentam, o índice do MSE aumenta consideravelmente, prejudicando a métrica.

MSE = 
$$\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$

II. RMSE (*Root Mean Square Error*): Raiz quadrada do MSE, permite apresentar os valores do erro na mesma dimensão das saídas analisadas.

RMSE = 
$$\sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$

III. MAE (Mean Absolute Error): O erro médio absoluto é a média do somatório do módulo do erro. Não é afetado por outliers.

$$MAE = \frac{1}{n} \sum_{i=1}^{n} ABS(y_i - \hat{y}_i)$$

IV. R²: O valor do R-quadrado descreve a fração da variância total nos dados observados que pode ser explicada pelo modelo. Terá como saída valores compreendidos entre 0 e 1, onde 0 (zero) significa que o modelo não foi capaz de realizar qualquer predição correta, e 1(um) representa que o modelo acertou todas as predições.

MAE, MSE e RMSE apresentam sempre valores positivos, indicando a magnitude do erro e não sua direção. Para ambas as medidas, valores mais baixos correspondem a modelos com melhores desempenho, ou seja, apresentam melhores aproximações do caso verdadeiro (FACELI, 2011, p160).

Com base nisto, pode-se afirmar que a tarefa de estimação de valores pode ser formulada como um "problema de minimização" de uma função "erro" que expressa a discrepância entre os valores previstos pelo modelo sendo treinado e os valores obtidos em casos reais.

## 3.3. Métodos de Aprendizado de Máquina

O aprendizado de máquina abrange uma ampla gama de métodos, cobertura abrangente muito além do escopo de um trabalho como este. Desta forma, a aplicação de três diferentes frameworks de aprendizado de máquina para processar a estimação dos parâmetros de qualidade do pelotamento será considerada: Métodos de aprendizado supervisionado baseados em redes neurais artificiais, e abordagens de modelagem em árvore de decisão / florestas randômicas e *K-Nearest Neighbors*. Como será discutido, cada uma dessas estruturas representa uma plataforma abrangente para o desenvolvimento e implementação de todas as operações necessárias para a estimação de variáveis de processo, aproveitando ao máximo as abordagens de aprendizado de máquina.

#### 3.4. Redes Neurais

Redes neurais artificiais (RNAs) são modelos computacionais "inspirados pelo comportamento do cérebro humano" (neurônios interconectados) (FACELI, 2011, p107), capazes de realizar o aprendizado de máquina com potencial aplicação nas áreas de reconhecimento de padrões, aproximação de funções, identificação, modelagem e controle de processos, previsão de séries temporais e otimização de sistemas (HAYKIN, 1999).

Historicamente, a Rede Perceptron, cuja arquitetura está mostrada na Figura 14, foi a primeira e mais simples forma de configuração de uma Rede Neural Artificial *Feedfoward*, inventada em 1957 no *Cornell Aeronautical Laboratory* por Frank Rosenblatt. Sua simplicidade está associada à sua condição de ser uma rede constituída de uma única camada neural, tendo somente um neurônio artificial nesta camada.

HAYKIN (1999) identifica três elementos básicos na arquitetura do Perceptron, comuns as demais arquiteturas de redes neurais: (i) um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso (wk), (ii) um somador para somar os sinais das entradas (x), ponderados pelas sinapses dos neurônios e (iii) uma função de ativação para restringir a amplitude de saída (y) do neurônio.

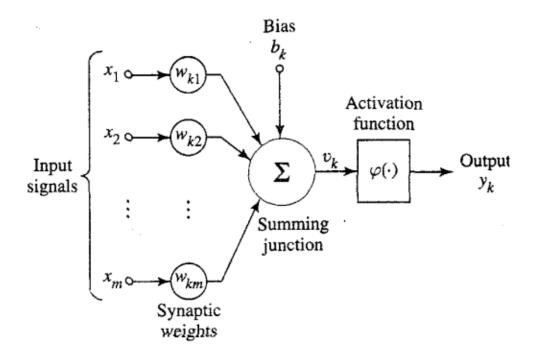


Figura 14 – Modelo de um Neurônio

(Fonte: Simon Haykin - Neural Networks - A Comprehensive Foundation)

O desenvolvimento da rede Perceptron apresentou uma limitada capacidade de resolução de problemas: suas aplicações consistem em identificar padrões denominados linearmente separáveis (isto é, padrões que residem em lados opostos de um hiperplano). Porém, embora seja uma rede simples e limitada, o Perceptron atraiu, quando de sua proposição, diversos pesquisadores que ansiavam conhecer a área de Inteligência Artificial, e estabeleceu as bases para o aprofundamento desta área de pesquisa, permitindo o desenvolvimento de novos tipos de arquiteturas de redes neurais, com capacidades de resolução de problemas mais complexos. Dentre estas, a arquitetura mais comum delas e a de maior importância para atividades de classificação é o Perceptron Multi Camadas (*Multi Layer Perceptron* – MLP).

HAYKIN (1999) define uma Rede Neural Artificial do tipo Perceptron Multicamadas como um conjunto de elementos sensores que constituem uma camada de entrada, uma conexão

em paralelo de vários elementos de processamento (neurônios) distribuídos em uma ou mais camadas intermediárias (ocultas), e uma camada de saída. A rede é treinada de modo supervisionado, com um algoritmo popular de Retropropagação (*Backpropagation*) do erro.

O algoritmo de aprendizagem (treinamento) *Backpropagation* opera em duas etapas: Na primeira, de propagação adiante (*forward*) um padrão é apresentado à camada de entrada da rede. Opera-se o cálculo das saídas e dos erros das camadas (da entrada para a saída). A atividade resultante propaga-se através da rede, camada por camada, até que a resposta seja produzida na camada de saída; Na segunda etapa, de propagação reversa (*backward*) a saída obtida é comparada à saída desejada. Se não for a correta, o erro calculado é propagado a partir da camada de saída até a camada de entrada. Os pesos sinápticos das camadas internas vão sendo gradativamente ajustados em função dos pesos das camadas adiante e o erro é retropropagado (correção do erro quadrático pelo método do Gradiente). Por fim, repete-se este processo até que a Rede Neural aprenda o padrão de entrada.

Redes Neurais Perceptron Multicamadas têm sido aplicadas com sucesso para solução tanto em problemas lineares como não lineares (HAYKIN, 1999).

# 3.5. Árvores de Decisão, Bagging e Random Forests

Árvores de decisão são métodos de aprendizado de máquina baseados em procura em um espaço de hipóteses definidos por uma linguagem de representação baseada em árvore. ALDRICH E AURET (2013) descrevem que o algoritmo de aprendizagem particiona recursivamente um espaço de dados de entrada para obter subespaços com distribuições de saída cada vez mais puras, onde o resultado é uma coleção de hiper-retângulos não sobrepostos no espaço de dados de entrada, com partições paralelas aos eixos das variáveis de entrada.

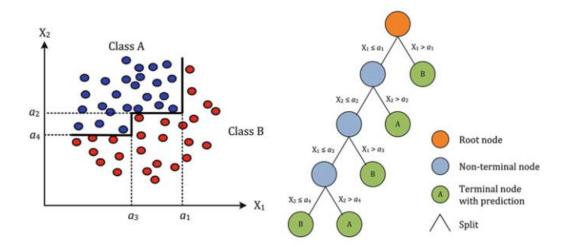


Figura 15 – Problema de classificação com fronteiras de decisão e respectiva árvore de decisão (fonte: Aldrich e Auret. *Unsupervised Process Monitoring and Fault Diagnosis with Machine Learning Methods*)

A Figura 15 representa uma árvore de decisão e a divisão correspondente no espaço definido pelos atributos de entrada x1 e x2. Cada nó representa uma correspondente região neste espaço, mutuamente excludentes. A união destas regiões abrange todo o espaço definido pelos atributos de entrada, de forma que a árvore pode fazer classificações para qualquer exemplo de entrada.

A vantagem dos algoritmos da árvore de decisão está relacionada à sua capacidade de ajustar-se a quase qualquer distribuição de dados. Entretanto, o uso adequado de árvores de decisão deve ser considerado à luz de determinadas restrições do espaço de hipóteses.

- Restrições estatísticas Problemas complexos podem exigir grandes árvore de decisão para resultar em uma classificação precisa, demandando um maior conjunto de dados de treinamento. Caso o volume de amostras de treinamento seja insuficiente, várias árvores podem mostrar múltiplas hipóteses (múltiplas generalizações) com precisões idênticas (desempenho de treinamento).
- Restrições Computacionais Árvores de decisão são modelos considerados estatisticamente instáveis, no sentido que, uma pequena alteração no conjunto de treinamento pode afetar o modelo final. Os algoritmos exploram heurísticas que executam uma pesquisa um passo à frente. Uma vez que a decisão é tomada, nunca é

- reconsiderada. Este processo é suscetível aos riscos usuais de convergência a uma solução ótima localmente e não globalmente.
- Restrição Representacional Árvores de decisão podem se ajustar erroneamente às distribuições ruidosas ou cujas superfície de decisão seja complexa (ex: diagonais), devido dificuldade de representação de problemas por meio de partições hiper retangulares.

Para minimizar estas restrições e erros de ajuste, usam-se métodos que combinam a estimativa de um conjunto de diferentes modelos de árvores de decisão para obter uma única saída com melhor desempenho que cada árvore do modelo em separado. A lógica de combinar modelos permite:

- Reduzir o risco de selecionar um modelo ruim (restrição estatística).
- Evitando a visão estreita de um único modelo localmente ótimo (restrição computacional).
- Aproximar-se de estruturas de representação complexas. (restrição representacional)

Métodos de combinação de árvores de decisão usam a técnica de re-amostragem *bootstrap* para criar subconjuntos de dados utilizados no treinamento das árvores do modelo. A técnica amostra instâncias aleatoriamente e com reposição, a partir dos dados originais, para formar novos conjuntos de mesmo tamanho que o original.

No método *Bagging* (ensacamento), também conhecido por *Bootstrap Aggregating*, com base em diversas árvores de decisão, um modelo estatístico é construído de forma que a saída seja definida através de uma votação por maioria (ou média) utilizando-se as respostas obtidas de cada modelo individual (Figura 16) (Aldrich e Auret, 2013).

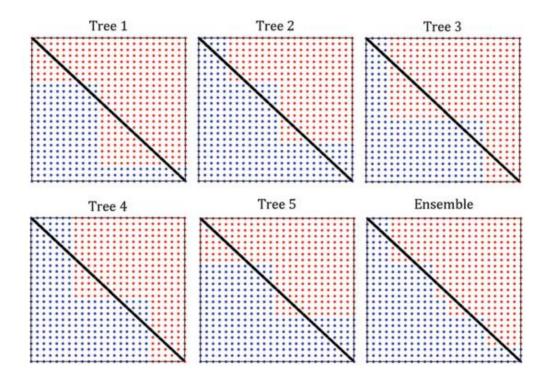


Figura 16 – Combinação de fronteiras de decisão para problemas de classificação em votação por maioria

(fonte: Aldrich e Auret. *Unsupervised Process Monitoring and Fault Diagnosis with Machine Learning Methods*)

O método Floresta Aleatória – *Random Forest* – usa a técnica *bootstrap* para criar subconjuntos de dados de treinamento, porém, diferentemente do método *Bagging*, o modelo de Floresta Aleatória utiliza somente um certo número do total de atributos (entradas) do conjunto de dados de treinamento para realizar a construção das árvores. Em termos práticos, amostra-se aleatoriamente linhas e colunas de uma base de dados de treinamento (Figura 17).

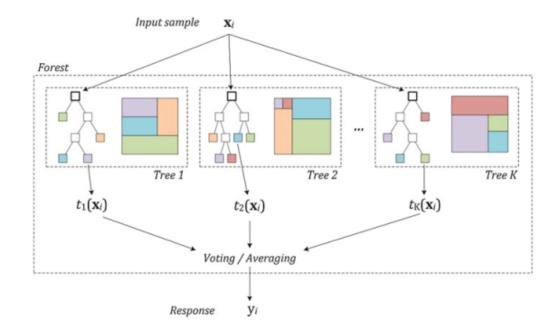


Figura 17 – Esquema de árvores de decisão em um modelo conjunto.

(fonte: Aldrich e Auret. *Unsupervised Process Monitoring and Fault Diagnosis with Machine Learning Methods*)

### 3.6. KNN – K Nearest Neighbors

FACELI (2011) relata que o algoritmo dos vizinhos mais próximos – KNN – *K Nearest Neighbors* – é uma técnica de aprendizado de máquina que considera a proximidade entre os dados na realização de predições. A hipótese base é que dados semelhantes tendem a estar concentrados em uma mesma região do espaço de entrada. De maneira alternativa, dados não similares estarão distantes entre si. Ao observar os valores das características e encontrar observações semelhantes a que se precisa prever, pode-se inferir uma possível resposta através da média dos valores vizinhos ou escolhendo a resposta mais frequente observada entre eles.

A estratégia do método é baseada na memorização. Definido como um algoritmo preguiçoso, nenhum aprendizado real é realizado no momento do treinamento, mas apenas o registro dos dados (FACELI, 2011). Considerando que nenhum modelo matemático é definido, o método é classificado como uma forma de regressão não-paramétrica.

Neste algoritmo cada objeto representa um ponto (representado por coordenadas) em um espaço definido pelos atributos, denominado espaço de entrada. Definindo uma métrica neste espaço, é possível calcular as distancias entre um ponto e seu vizinho (FACELI, 2011).

Abaixo tem-se duas métricas mais comuns no cálculo de distância entre dois pontos, sendo que a mais utilizada.

Seja 
$$X=(x_1, x_2, ..., x_i)$$
 e  $Y=(y_1, y_2, ..., y_i)$  dois pontos do  $\Re^n$ .

 Distância Euclidiana – Calculada como a raiz quadrada da soma das diferenças ao quadrado entre os elementos de dois vetores (FACELI, 2011, p 59, 200).

$$d(x,y) = \sqrt{\sum_{i=1}^{n} (x_i - y_i)^2 = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_i - y_i)^2}}$$

 II. Distância Manhattan – Calculada como a soma dos valores absolutos das diferenças entre os elementos dos vetores (FACELI, 2011, p199).

$$d(x,y) = \sum_{i=1}^{n} ABS(x_i - y_i) = ABS(x_1 - y_1) + ABS(x_2 - y_2) + \dots + ABS(x_i - y_i)$$

Não existem regras absolutas a respeito de qual medida é a melhor. É preciso testar cada distância como uma hipótese e verificar por validação qual funciona melhor para o problema que está sendo resolvido.

O algoritmo dos vizinhos mais próximos tem variações definidas pelo número de vizinhos considerados (valor "K"), parâmetro que deve ser ajustado para que o algoritmo KNN funcione adequadamente (FACELI, 2011).

Quanto menor o valor k, mais o algoritmo se adaptará aos dados apresentados, porém o resultado será mais sensível à valores discrepantes (maior variância). Quanto maior o parâmetro k, mais o modelo se abstrai de altos e baixos dos dados reais, produzindo curvas suaves (menor variância), porém à custa de se levar em conta exemplos irrelevantes, de forma que um aumento expressivo de k enfraquece a influência das amostras uteis.

### 4. Trabalhos Relacionados

Embora modelos de regressão baseados em aprendizado de máquinas sejam amplamente utilizados no mundo, durante a revisão bibliográfica, não foram identificados na literatura associada, casos de aplicação à circuitos de pelotamento em indústrias de pelotização de minério de ferro **para estimativa das variáveis de umidade, resistência a compressão de pelotas cruas e secas e número de quedas**. Desta forma, destacam-se exemplos limitados de sistemas de estimação orientados à dados aplicados à outros processos de beneficiamento mineral.

FAN (2012) e seus colegas propuseram modelos baseados em análise de regressão e redes neurais artificiais para previsão de variáveis em uma sinterização de minério de ferro. Diversas estruturas de redes neurais *back propagation* foram avaliadas, de forma que os modelos foram capazes de prever: o teor de umidade com precisão de 96,67%; a razão combustível/água, com a precisão de 93,33%; a velocidade de sinterização, com precisão de 86,67%; a resistência do tambor de sinterização, com precisão de 93,33%.

DRUMMOND e outros (2018) modelaram sensores virtuais capazes de estimar o teor de SiO2 em uma etapa de flotação de minério de ferro. Foram aplicadas técnicas de mineração de dados e seleção de características em um conjunto de dados abrangendo variáveis da Flotação e da Deslamagem, obtendo-se entradas para elaboração de 03 modelos de *Machine Learning: Random Forest, GradientBoostedTrees* e *MultiLayerPerceptron*. O sensor virtual baseado em redes neurais artificiais se mostrou estatisticamente mais eficiente na etapa de teste. Na versão online, o baixo erro médio absoluto (MAE = 0,8%) obtido comprovou a robustez do modelo, entregando agilidade para a operação e certificando o poder dessa abordagem em processos industriais com alta latência de resultados laboratoriais.

TOHRY et al (2019) introduziram a técnica de floresta aleatória (RF) como um modelo preditivo de consumo de energia em moinhos de bolas. A determinação do consumo de energia do moinho pode desempenhar um papel crítico para operação eficiente sob ótica econômica, operacional e de controle de todas as plantas de processamento mineral, uma vez que o custo da moagem é a maior despesa individual dentro do processo. Foi relatado que para um moinho de bolas com 5m de diâmetro e 7m de comprimento, o consumo de energia pode variar entre 2,5 e 3,5 MW, onde apenas 1–5% desta energia é utilizada para a redução do tamanho das partículas, objetivo real de moagem. Portanto, a estimativa do consumo de energia pode ser

considerada como um indicador para o desempenho de uma usina. Existem diversos parâmetros operacionais que influenciam o consumo de energia do moinho e podem ser considerados para sua previsão (taxa de alimentação de minério e água, velocidade, distribuição granulométrica do minério – passante e retido, etc.). Um banco de dados de um moinho de bolas industrial da planta de processamento de minério de ferro de Chadormalu foi usado para desenvolver um modelo de RF e explorar as relações entre o consumo de energia e estes parâmetros operacionais monitorados. Os resultados da modelagem indicaram que o modelo baseado em RF pôde melhorar muito a precisão da previsão do consumo de energia em comparação com a regressão como um método típico (R2: 0,98 vs. 0,60, respectivamente) e além de permitir classificar os parâmetros de moagem com base em sua importância (seleção de características).

SANDHYA e outros (2019) implementaram sete (7) diferentes algoritmos de ciência de dados para prever propriedades mecânicas do aço inoxidável, comparando-os e identificando o modelo com maior precisão. O aço inoxidável é a liga metálica mais amplamente utilizada em aplicações na industrial (ex: construção civil, infraestrutura, aeroespacial, automóveis, navios, armas, instrumentação cirúrgica, produtos domésticos, etc), devido à sua elevada resistência à tração e reciclabilidade. A abordagem tradicional, para se determinar as propriedades mecânicas do aço, de realização de ensaios de tração usando UTM (máquina de ensaio de tração universal) e alguns outros testes não é eficaz em termos de custo e tempo consumido. Desta forma, o trabalho apresentado propôs a aplicação de modelos baseados em regressão (floresta aleatória, SVM, ANN, árvore de decisão, regressão linear, K- Vizinho mais próximo e método de conjunto) para prever a resistência à tração com base nas variáveis de conteúdo de carbono, tamanho da seção, temperaturas, processo de fabricação, etc. Os modelos estudados apresentaram valores de resistência à tração com uma precisão de 96,3%, 95%, 94%, 90%, 89%, 93.6 e 95% respectivamente.

De forma semelhante, GUEDES (2020) aplicou sensores virtuais baseados em Redes Neurais Artificiais e *Random Forests* para predição em tempo real de teor de ferro no concentrado da flotação de minério de ferro. Os dados coletados de uma linha de flotação passaram por dois métodos de redução de dimensionalidade paralelamente, o RReliefF e o *Principal Component Analysis* (PCA), e foram utilizados para treinamento, validação e teste dos modelos propostos. Os desempenhos dos métodos utilizados foram comparados e os resultados indicaram forte correlação entre os dados disponíveis em tempo real no processo da

flotação e os resultados da análise laboratorial realizada em intervalos de 2 horas, permitindo uma resposta mais rápida para correção dos parâmetros do processo.

DEVI et al (2020), apresentam um algoritmo para predição das propriedades mecânicas de resistência à tração, limite de escoamento e dureza de ligas de alumínio, com base na composição química, e usando diferentes técnicas de aprendizado de máquina, como regressão linear (LR), rede neural artificial (ANN) e algoritmo de k-vizinho mais próximo (KNN). Nas ligas de alumínio, o alumínio é elemento predominante; outros elementos são manganês, cobre, estanho, zinco e magnésio. São materiais leves e resistentes à corrosão usados em estruturas e componentes. A quantidade de silício na liga dá boas propriedades de fundição reduzido custo devido ao seu baixo ponto de fusão e baixa resistência à tração. O aumento do magnésio melhora inflamabilidade e reduz o peso, o que é adequado para a fabricação aeroespacial. Nos resultados obtidos, o algoritmo KNN forneceu uma melhor previsão dos valores de resistência à tração e dureza, porém com sensibilidade a ruídos e outliers, presentes em grandes conjuntos de dados. Em previsões de limites de escoamento, as Redes Neurais artificiais apresentaram resultados melhores e mais precisos em comparação com os outros dois algoritmos, mesmo para dados não lineares.

KAPLAN e TOPAL (2020) propuseram uma técnica de estimativa combinando redes neurais *feed-forward* multicamadas e modelos de k-vizinho mais próximo (kNN) para estimar a distribuição de teor em um depósito mineral, uma etapa fundamental na exploração mineral que desempenha um papel significativo na avaliação econômica de projetos de mineração. Os modelos foram criados usando as informações geológicas disponíveis (litologia e alteração), bem como localizações de amostras (leste, norte e altitude) obtidas a partir dos dados dos furos de sondagem. O algoritmo KNN foi modelado para prever tipos de rocha e níveis de alterações em locais não amostrados. Na sequência, o modelo de redes neurais artificiais foi treinado para prever os teores de minério usando as previsões geológicas e espaciais feitas pelo modelo kNN, bem como informações geográficas como variáveis de entrada. O estudo de caso apresentado demonstrou que a abordagem proposta pôde prever os teores minerais com um erro absoluto médio (MAE) de 0,507 e R2 = 0,528, valores melhores quando comparados com os modelos tradicionais de estimativa, sendo, portanto, considerado uma forma alternativa para estimação de teores minerais.

## 5. Materiais e Métodos

# 5.1. Área de estudo

O projeto foi desenvolvido na área da Diretoria de Pelotização da VALE, em Vitória-ES.

## 5.2. Arquitetura Lógica do Sistema

A arquitetura lógica do sistema utilizado por este trabalho foi organizada conforme camadas definidas pela Norma ISO / IEC 62443 (Antiga ISA 99). As variáveis foram obtidas em tempo real por instrumentos analógicos e discretos interligados ao sistema de controle, através de Controladores Lógicos Programáveis e Unidades Remotas de Entradas/Saídas. Servidores coletores de dados, coletaram as informações através de protocolo OPC e disponibilizam para o Sistema de Informações da Planta (PIMS).

### 5.3. Metodologia

Adotou-se como metodologia, a divisão do trabalho em etapas conforme descrito a seguir.

#### 5.3.1. Entendimento do Negócio e de Dados

A fase de entendimento do negócio compreendeu as atividades de revisão bibliográfica e pesquisa teórica sobre o funcionamento da etapa do pelotamento, bem como entendimento de suas principais variáveis de controle. De forma semelhante, foram estudados os métodos de aprendizado de máquinas escolhidos. O conteúdo desta etapa encontra-se descrito nos capítulos 2 e 3, desta dissertação.

### 5.3.2. Coleta e Preparação dos Dados

A etapa de coleta e preparação de dados envolveu as atividades de montagem de tabelas / planilhas contendo as informações necessárias para os algoritmos de modelamento, préprocessamento através da limpeza dos dados brutos iniciais, para eliminar amostras com dados ausentes, ruídos e inconsistências.

Conforme observado na Figura 18, a coleta de dados foi realizada através do Excel com um uso de *Addin* do Infoplus – Sistema PIMS – *Plant Information Management System* – desenvolvido pela Aspentech, e em uso pela Vale em Vitória-ES. Trata-se de uma base de dados

temporal (histórica) contendo dados amostrados de diversas fontes, permitindo uma visão unificada do processo.

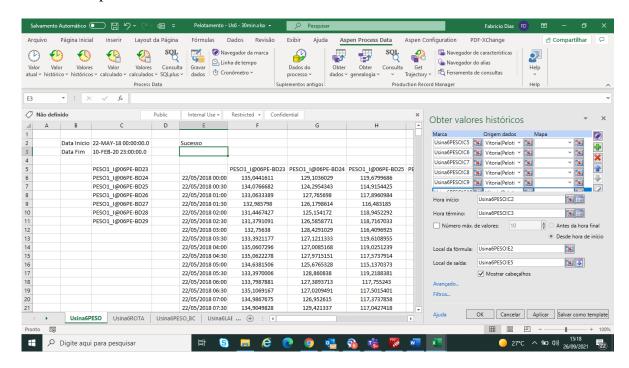


Figura 18 – Coleta de Dados do PIMS através do Excell e Addin Aspentech Infoplus.21 Fonte: Elaborado pelo autor (2021).

Foram coletadas originalmente 28.273 amostras, no período entre 22/05/2018 às 00 horas e 31/12/2019 às 23 horas, com intervalo de 30 minutos entre amostras. O intervalo de dados da coleta e a frequência de amostragem foram definidos de forma a obter uma grande quantidade de dados, de forma que um maior número de exemplos garantisse variabilidade suficiente para se obter uma generalização dos dados, e evitar sobreajustes (*overfitting*), auxiliando os algoritmos de aprendizado de máquina a esclarecer as funções de cada variável escolhida para modelar a previsão.

Durante a atividade de limpeza foram identificadas amostras que possuíam dados ausentes em alguma das características (*features*). Isto deve-se aos períodos de paradas do processo produtivo em períodos de manutenções programadas ou corretivas. As amostras foram retiradas dos conjuntos de dados de treinamento e validação.

Considerando-se que eventualmente as etapas de mistura e pelotamento podem operar com um ou mais equipamentos parados (ex: balança dosadora, misturador, disco), buscou-se identificar os períodos em que estes equipamentos se encontravam parados com o auxílio de

variáveis discretas de "Funcionando" coletadas do PIMS. Foi possível observar ocorrências de pequenos erros de medições em variáveis de dosagem (PESO) de aglomerantes e minério ou rotações de discos, e que teoricamente deveriam estar representadas como "0" (zero). Alguns pequenos valores negativos foram encontrados, em função de erros de medição / calibração. Nestes casos, os valores identificados foram substituídos por "0", de forma a deixar o conjunto de dados coerente entre variáveis correlatas (ex: dosagem – rotação de disco).

Realizou-se uma *análise exploratória de dados*, uma abordagem univariada, com objetivo de observar algumas estatísticas descritivas chaves. Ao explorar os dados, identificou-se ocorrências de valores diferentes dos esperados, discrepantes, por serem altos ou baixos demais, incomuns e altamente improváveis, com comportamento semelhante à um ruido, aumentando a variância das estimativas e afetando a estatística descritiva, por exemplo, desviando valores de média e mediana e enfraquecendo a relação entre variáveis.

Embora, de forma geral, os algoritmos não possuam restrições quanto ao tipo de distribuição de cada variável, buscou-se observar o efeito de valores discrepantes sobre as distribuições, conforme pode ser observado na Figura 20. Constatou-se que a maioria das características contava estatisticamente com uma distribuição "normal". De forma a minimizar o peso de poucos casos extremos, e evitar que algoritmos se esforçassem para minimizar erros extremos, analisou-se os dados que encontravam-se nas caudas direta e esquerda da curva de distribuição normal de cada variável, acima de ±3σ (desvios padrão), e que estatisticamente deveriam representar 0,07% dos casos. Em alguns casos as amostras foram eliminadas do conjunto de dados (Resistencia Pelota Crua > 1,3; Resistência Pelota Seca > 3,6; Superfície específica na Prensa > 2300; Superfície Específica na Filtragem < 1480, Produção do Pelotamento < 450 t/h e Retorno do Pelotamento > 140 t/h, Soma Rotações < 28, Média Rotações < 4, Soma Taxas Alimentação < 560, Media Taxas Alimentação < 81). A Figura 19 apresenta um resumo da atividade de análise exploratória dos dados, observando-se a variação da estatística descritiva "antes" e "após" limpeza de valores discrepantes.

NUM_NQ_	RES_RPC_P	RES_RPS_P	UMID_H2O	SUP_SE_PP	UMID_H2O	GRAN	SUP_SE_PR
PV_L	V_L	V_L	_PV_L	_L	_PP_L	0,045_PR_L	_L
			ANTES				
5,133	0,933	2,252	8,182	1.945,750	8,672	86,470	1.708,000
5,313	0,942	2,296	8,186	1.956,504	8,670	86,139	1.715,682
1,109	0,109	0,390	0,302	97,970	0,045	3,489	77,079
8,640	1,269	3,465	9,091	2.250,413	8,806	96,606	1.946,920
1,987	0,614	1,127	7,281	1.662,596	8,534	75,671	1.484,443
			DEPOIS				
5,104	0,931	2,243	8,177	1.945,000	8,671	86,552	1.706,875
5,276	0,939	2,280	8,179	1.952,934	8,671	86,250	1.713,367
1,081	0,106	0,367	0,296	88,550	0,034	3,444	73,517
8,519	1,258	3,380	9,067	2.218,583	8,774	96,583	1.933,919
2,032	0,620	1,180	7,291	1.687,284	8,569	75,917	1.492,815
	5,133 5,313 1,109 8,640 1,987 5,104 5,276 1,081 8,519	PV_L         V_L           5,133         0,933           5,313         0,942           1,109         0,109           8,640         1,269           1,987         0,614           5,104         0,931           5,276         0,939           1,081         0,106           8,519         1,258	PV_L         V_L         V_L           5,133         0,933         2,252           5,313         0,942         2,296           1,109         0,109         0,390           8,640         1,269         3,465           1,987         0,614         1,127           5,104         0,931         2,243           5,276         0,939         2,280           1,081         0,106         0,367           8,519         1,258         3,380	PV_L         V_L         V_L         _PV_L           ANTES           5,133         0,933         2,252         8,182           5,313         0,942         2,296         8,186           1,109         0,109         0,390         0,302           8,640         1,269         3,465         9,091           1,987         0,614         1,127         7,281           DEPOIS           5,104         0,931         2,243         8,177           5,276         0,939         2,280         8,179           1,081         0,106         0,367         0,296           8,519         1,258         3,380         9,067	PV_L         V_L         V_L         _PV_L         _L           ANTES           5,133         0,933         2,252         8,182         1.945,750           5,313         0,942         2,296         8,186         1.956,504           1,109         0,109         0,390         0,302         97,970           8,640         1,269         3,465         9,091         2.250,413           1,987         0,614         1,127         7,281         1.662,596           DEPOIS           5,104         0,931         2,243         8,177         1.945,000           5,276         0,939         2,280         8,179         1.952,934           1,081         0,106         0,367         0,296         88,550           8,519         1,258         3,380         9,067         2.218,583	PV_L         V_L         V_L         _PV_L         _L         _PP_L           ANTES           5,133         0,933         2,252         8,182         1.945,750         8,672           5,313         0,942         2,296         8,186         1.956,504         8,670           1,109         0,109         0,390         0,302         97,970         0,045           8,640         1,269         3,465         9,091         2.250,413         8,806           1,987         0,614         1,127         7,281         1.662,596         8,534           DEPOIS           5,104         0,931         2,243         8,177         1.945,000         8,671           5,276         0,939         2,280         8,179         1.952,934         8,671           1,081         0,106         0,367         0,296         88,550         0,034           8,519         1,258         3,380         9,067         2.218,583         8,774	PV_L         V_L         V_L         _PV_L         _L         _PP_L         _0,045_PR_L           ANTES           5,133         0,933         2,252         8,182         1.945,750         8,672         86,470           5,313         0,942         2,296         8,186         1.956,504         8,670         86,139           1,109         0,109         0,390         0,302         97,970         0,045         3,489           8,640         1,269         3,465         9,091         2,250,413         8,806         96,606           1,987         0,614         1,127         7,281         1.662,596         8,534         75,671           DEPOIS           5,104         0,931         2,243         8,177         1.945,000         8,671         86,552           5,276         0,939         2,280         8,179         1.952,934         8,671         86,250           1,081         0,106         0,367         0,296         88,550         0,034         3,444           8,519         1,258         3,380         9,067         2,218,583         8,774         96,583

Figura 19 – Análise exploratória de dados. Variação da estatística descritiva "Antes" e "Depois" da atividade de limpeza de valores discrepantes.

Fonte: Elaborado pelo autor (2021).

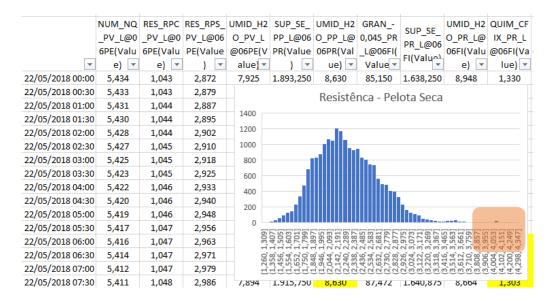


Figura 20 – Histograma e Valores Discrepantes. Distribuição "normal" – variável Resistência de Pelota Seca

Fonte: Elaborado pelo autor (2021).

Novamente, considerando-se que eventualmente a operação pode ocorrer com um disco ou um misturador parado, acreditou-se que eventualmente os dados brutos obtidos por contribuições individuais de cada equipamento (ex: rotação e dosagem de minério de um determinado disco de pelotamento) poderiam não possuir todas as características necessárias para executar a tarefa de aprendizado de máquina. Desta forma, foi necessário criar algumas características próprias, a partir dos dados existentes, com objetivo de obter o resultado

desejado. Acreditando-se que as novas variáveis possuiriam maior poder preditivo que as originais, foram criadas variáveis que representassem Somas, Médias e Desvios Padrão das dosagens e rotações de cada disco de pelotamento, bem como das dosagens de aglomerantes.

Concluída a etapa de limpeza e preparação dos dados, o conjunto de dados passou a ser formado por 20.109 amostras.

#### 5.3.3. Modelagem

A etapa de modelagem envolveu as atividades de construção, parametrização e treinamento dos modelos de estimação através dos algoritmos de aprendizado de máquina escolhidos, e com base no conjunto de dados contendo variáveis explicativas obtido na etapa anterior de coleta e preparação dos dados.

Adotou-se o Orange – um software de código aberto que apresenta um *front-end* de programação visual composto por conjunto de ferramentas para análise exploratória, visualização interativa de dados, aprendizado de máquina e mineração de dados. Os componentes são chamados de *widgets* e variam desde uma visualização simples de dados, seleção de subconjunto, ranqueamento de variáveis, pré-processamento até avaliação empírica de algoritmos de aprendizagem e modelagem preditiva. A programação visual é implementada por meio de fluxos de trabalho criados pela vinculação destes *widgets*. A Figura 21 – apresenta o modelo desenvolvido no Orange, para exploração dos métodos de aprendizado de máquinas.

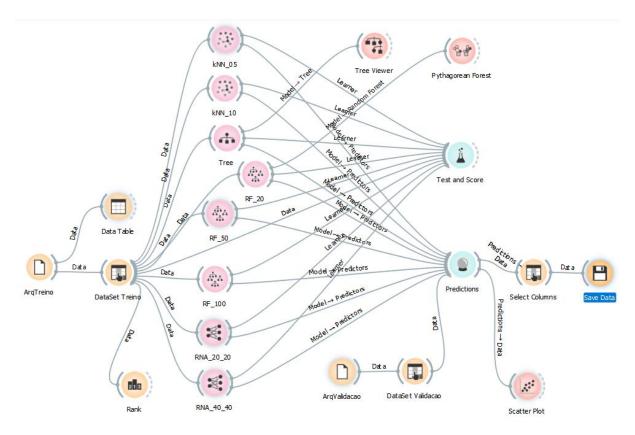


Figura 21 – Modelo dos métodos de aprendizado de máquina utilizados, através do Orange Fonte: Elaborado pelo autor (2021)

Para obter estimativas de desempenho confiáveis, definiu-se subconjuntos de treinamento e de teste distintos, de forma que as medidas de desempenho pudessem ser obtidas a partir de um conjunto de exemplos diferente daquele usado no aprendizado. Foi adotado o método de amostragem aleatória simples (holdout), sem reposição. Dividiu-se o conjunto de dados original em uma proporção de p para treinamento e (1-p) para validação, sendo p=0.8. (Figura 22)

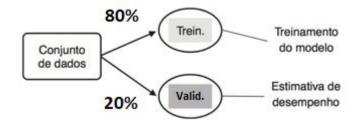


Figura 22 – Divisão dos conjuntos de treinamento e validação.

Fonte: Elaborado pelo autor (2021)

Os dados foram divididos aleatoriamente em arquivos de treinamento e validação, com auxílio da função "ALEATORIO()" do Excel. Uma nova coluna foi adicionada ao conjunto de dados com valores aleatórios, entre 0-1. Um valor de limiar (*threshold*) foi definido de forma a dividir os conjuntos (ex: Treinamento <= 0.8 / Validação > 0.8) com auxílio de filtros. Os arquivos foram lidos pelo software através dos *widgets* tipo "File" – ArqTreino e ArqValidação.

As variáveis de teores de Carbono Fixo, Carvão e CaO na Homogeneização, Umidade de Polpa Retida na Filtragem, Umidade, Granulometria e Superfície Específica de Polpa prensada, foram descartadas da matriz de variáveis de entrada (*widget* tipo "Select Column" – DataSet Treino e DataSet Validação), embora sejam parâmetros que afetem diretamente a qualidade das pelotas cruas. Tais variáveis atualmente são coletadas e analisadas por método laboratorial, o que implica que seus valores só estariam disponíveis em intervalos periódicos (ex: geralmente 4 horas), o que inviabilizaria a implementação do modelo em tempo real <sup>2</sup>.

Desta forma os sensores virtuais foram modelados considerando-se apenas variáveis obtidas através de instrumentos em tempo real, reduzindo-se de 42 ara 33 variáveis de entradas analisadas, conforme pode ser visto na

Figura 23. Foram consideradas entradas: Dosagens de Aglomerantes Calcário e Bentonita (4 balanças dosadoras, somas e médias), rotações e taxas de alimentação de 7 discos de pelotamento e respectivas somas, médias e desvios, taxas de produção e retorno de pelotamento. O critério para escolha destas variáveis, considerou a influência direta destas sobre a qualidade da pelota crua, conforme descrito na seção 2.11.

Α

Figura 23 descreve o modelo para a variável "umidade", e as 32 características apresentadas ao modelo. Os modelos para os sensores virtuais para medição de número de quedas e resistência à compressão de pelotas cruas e secas podem ser compreendidos de forma semelhante, considerando que utilizam as mesmas variáveis de entrada.

67

<sup>&</sup>lt;sup>2</sup> Obs.: Durante o processo de pesquisa, foram investigados modelos com aplicação destas variáveis, observandose melhoras nos modelos apresentados, o que destaca a importância de estudos semelhantes para determinar estas variáveis nestas etapas do processo.

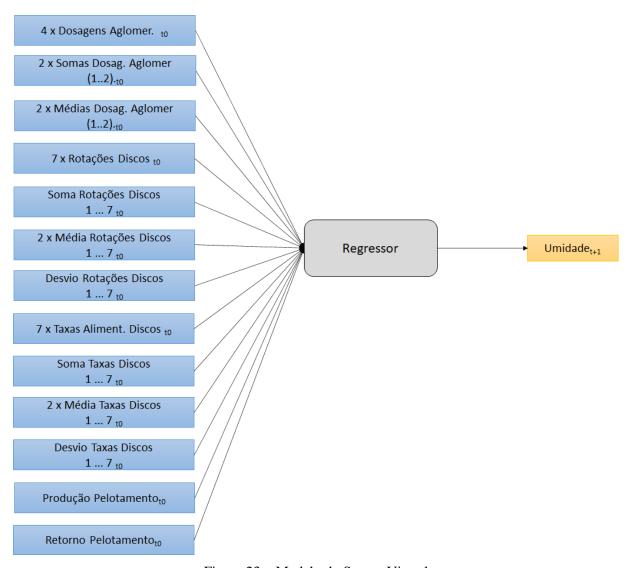


Figura 23 – Modelo do Sensor Virtual Fonte: Elaborado pelo autor (2021).

Foram adotados três métodos de aprendizado de máquinas para efeitos de comparação: *Random Forests*, Redes neurais MLP e KNN, métodos comumente utilizados no aprendizado de máquina com dados complexos e que permitem a generalização da informação aprendida.

Os widgets dos algoritmos *Random Forest*, Redes Neurais e kNN utilizam um préprocessamento padrão do Orange quando nenhum outro bloco de pré-processamento de dados é definido no fluxo. Dentre as atividades executadas, normalizam os dados centralizando a média e escalando os dados para o desvio padrão de 1. Desta forma, não houve necessidade de realizar uma etapa de transformação de dados na etapa anterior de preparação de dados.

Foram feitas variações nos parâmetros de configuração dos *widgets* de modelagem, de forma a avaliar a influência destes valores nas métricas de qualidade do modelo, e encontrar os modelos com melhor acurácia, conforme descrito a seguir

#### 5.3.3.1. Tree

Limit the maximal tree depth: limita a profundidade da árvore de classificação ao número especificado de níveis de nó. Foram testados valores: 5, 10, 15, 20, 25, 50, 75 e 100, apenas para a variável Número de Quedas.

#### 5.3.3.2. Random Forest

Number of trees: especifica o número de árvores de decisão que devem ser incluídas na floresta. Foram testados valores: 5, 10, 15, 20, 35, 50, e 100, apenas para a variável Número de Quedas. Para demais saídas, foram testados os valores: 20, 50 e 100.

#### 5.3.3.3. KNN

- Number of Neighbors: Define o número de vizinhos mais próximos. Foram testados valores 3, 5, 7, 10 e 15 apenas para a variável Número de Quedas. Para demais saídas, foram testados os valores: 5 e 10;
- Metric: Define o parâmetro de distância (métrica). Adotado: Manhattan (soma das diferenças absolutas de todos os atributos).
- Weight: Adotado: Distance os vizinhos mais próximos têm uma influência maior do que os vizinhos mais distantes.

#### 5.3.3.4. Redes Neurais

- Neurons per hidden layer: Define número de neurônios por camada oculta. Foram testadas duas redes neurais com duas camadas ocultas, e número de neurônios 20/20 e 40/40.
- Activation function for the hidden layer: Função de ativação para a camada oculta.
   Adotado: tanh a função tangente hiperbólica.
- Solver: Adotado: L-BFGS-B um otimizador na família dos métodos quase Newton.

Max iterations: Número máximo de iterações. Adotado: 1000.

# 5.3.4. Avaliação dos Resultados

A etapa de avaliação dos resultados compreendeu a revisão de passos executados para obtenção do modelo matemático, e a validação do alcance dos objetivos deste trabalho. Os resultados obtidos encontram-se descritos no capítulo 6 – Resultados e Discussão.

A validação foi feita através de uma amostra do conjunto de dados original, contendo 4001 ocorrências (20%). Através do *widget "predicitions*" foi possível observar as métricas de desempenho, bem como exportar em um arquivo (.csv) as predições de cada modelo / método avaliado.

Adotou-se os indicadores de R2 e RMSE como medidas de desempenho dos modelos validados.

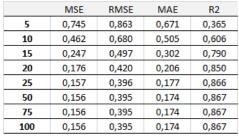
### 6. Resultados e Discussão

#### 6.1. Resiliência ou Resistência ao Número de Quedas

A Figura 24 apresenta os resultados a variação das métricas de desempenho para uma árvore de decisão que tem sua profundidade variada entre 5 e 100 níveis. Observa-se melhoria em todos os indicadores de desempenho, à medida que se aumenta a profundidade da árvore até determinado valor, indicando que o modelo atingiu sua profundidade máxima.

Dada a complexidade do problema devida a não linearidade entre variáveis, grande número de variáveis explicativas (33), e a dificuldade do método em representar o problema por meio de hiperplanos, conclui-se que o método demanda maior profundidade da árvore para obter melhor desempenho.

A diferença de valores entre RMSE e MAE (RMSE > 2 \* MAE) indicar a presença de ajustes errôneos causados por ruídos, justificada novamente pela superfície de decisão complexa, ou dada a tendência do índice RMSE ser cada vez maior que o MAE à medida que o tamanho do conjunto de validação aumenta.



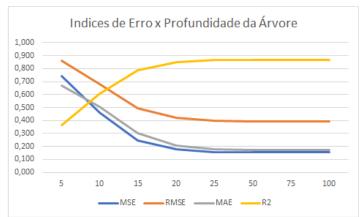


Figura 24 – *Decision Tree* – Índices de Erro x Profundidade da Árvore – Saída "Número de Quedas" Fonte: Elaborado pelo Autor (2021)

A Figura 25 apresenta a influência do parâmetro "quantidade de árvores votantes" em uma Floresta Aleatória. À medida que se aumenta a quantidade de árvores envolvidas no cálculo da média das respostas individuais, observa-se melhoria em todos os indicadores de erro e no R2 (medida de diversidade de árvores). Entretanto, observa-se que, em termos do

aumento do número de árvores, o erro aproxima-se assintoticamente de um valor limite, onde a melhora passa a ser insignificante.

A menor diferença entre os valores de RMSE e MAE (RMSE < 2 \* MAE) indica melhora frente às restrições representacionais impostas pelo modelo de uma única árvore de decisão, produzindo curvas mais suaves para as variáveis previstas.

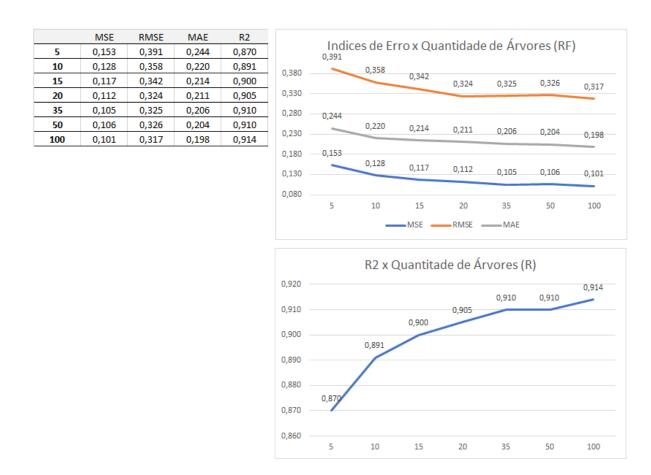


Figura 25 – *Random Forest* – Índices de Erro x Quantidade de Árvores – Saída "Número de Quedas"

Fonte: Elaborado pelo autor (2021)

A Figura 26 apresenta resultados obtidos para o método KNN, e a influência do parâmetro "Quantidade de Vizinhos" nas métricas de desempenho.

Os baixos valores obtidos para MAE, confirmam a aplicabilidade do método KNN para solução de problemas complexos. Entretanto, dado a diferença entre RMSE e MAE (RMSE > 2x MAE) também se observa a sensibilidade do método à valores discrepantes / *outliers*. De fato, como veremos adiante, as curvas dos sinais previstos indicam algumas previsões erráticas.

O desempenho modelo KNN também parece ser afetado pela dimensionalidade dos atributos (33), presença de atributos redundantes e/ou irrelevantes. O desempenho pode ser melhorado através da aplicação de técnicas para redução de dimensionalidade e seleção de características.

Por fim, observa-se que, à medida que se aumenta o valor k (número de vizinhos), ocorre uma degradação das métricas de desempenho, indicando que o modelo passa considerar exemplos de vizinhos irrelevantes, enfraquecendo a influência dos vizinhos realmente uteis.



Figura 26 – KNN – Índices de erro x Quantidade de Vizinhos – Saída "Número de Quedas" Fonte: Elaborado pelo Autor (2021)

A

Tabela 4 apresenta comparativo entre as técnicas de aprendizado de máquinas. As células destacadas em fundo verde, indicam os melhores resultados obtidos.

Tabela 4 – Estatística Descritiva – Saída "Número de Quedas"

	NUM_QUED PV	Tree	RF_20	RF_50	RF_100	RNA_20_20	RNA_40_40	kNN_05	kNN_10	RF_100+KN N_05
R2		0,853	0,909	0,922	0,926	0,674	0,788	0,922	0,918	0,938
MAE		0,176	0,213	0,200	0,198	0,467	0,364	0,093	0,100	0,141
MSE		0,177	0,116	0,102	0,099	0,384	0,250	0,092	0,097	0,077
RMSE		0,420	0,340	0,320	0,315	0,620	0,500	0,303	0,311	0,277

Fonte: Elaborado pelo autor (2021).

Comparou-se duas (2) diferentes configurações de Redes Neurais Artificiais, tipo Perceptron Multicamadas, com duas camadas ocultas. A primeira possuía 20 neurônios / camada, enquanto a segunda, 40. A rede neural com 20 neurônios nas duas camadas ocultas apresentou os piores resultados (R2 de 0,674 e RMSE 0,620) se comparada ao modelo com 40 neurônios. Em ambos os casos, as redes neurais avaliadas apresentaram os piores quando comparadas aos demais métodos, de forma que não é um modelo indicado para ser aplicado na prática para este caso prático.

A Random Forest com 100 árvores apresentou os melhores resultados do Coeficiente de correlação (R2 de 0,926), embora os modelos KNN também tenham apresentados resultados bastante satisfatórios (ex: R2 de 0,922).

A Figura 27 – apresenta histogramas de Erro Absoluto. Observa-se que o modelo KNN com 5 vizinhos apresentou os menores Erros Médios Absolutos (MAE). De fato, observa-se através dos gráficos previsto x realizado, uma grande quantidade de acertos de previsão (Erro=0), com as curvas apresentando-se sobrepostas em vários momentos.

Mesmo considerando a sensibilidade à outliers e à dimensionalidade dos atributos, o modelo KNN com 5 vizinhos ainda assim apresentou também o melhor RMSE (RMSE=0,303), embora o modelo *Random Forest* com 100 árvores tenha apresentado resultado bem semelhante.

Um modelo baseado na média dos dois melhores modelos RF e KNN foi proposto, de forma a explorar a possibilidade de melhora nos parâmetros de qualidade. Observou-se que os algoritmos quando usados em conjunto, apresentaram melhor desempenho quando comparado com seus modelos individuais – onde um modelo passou a corrigir a fraqueza do outro,

aumentando a precisão. Conforme Figura 28, o novo modelo apresentou melhores respostas de R2, (ex: R2 de 0,938), e da medida RMSE (0,277).

Avaliando-se os gráficos "predito x realizado" (Figura 29), observa-se uma suavização da saída prevista do modelo conjunto (KNN+RF), considerando que o modelo RF\_100 atenua a sensibilidade do modelo KNN à presença de "outliers".

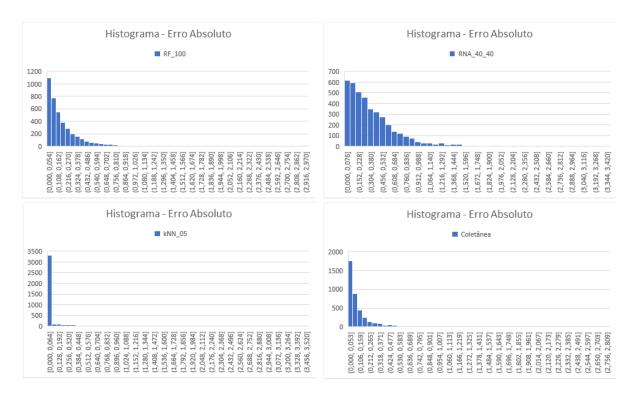


Figura 27 – Histogramas de distribuição do Erro Absoluto – Saída "Número de Quedas" Fonte: Elaborado pelo autor (2021)

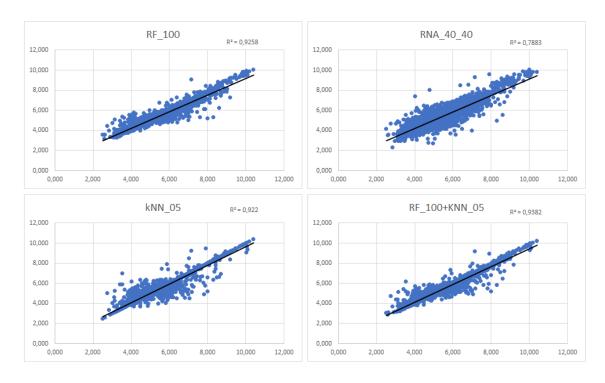


Figura 28 – Gráficos de Dispersão – Saída "Número de Quedas" Fonte: Elaborado pelo autor (2021).

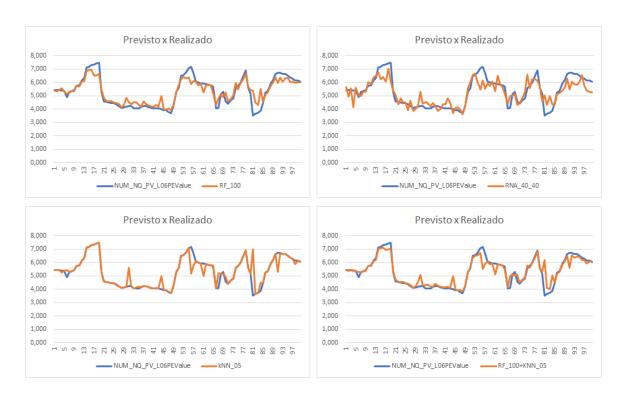


Figura 29 – Gráficos "Previsto x Realizado" – Saída "Número de Quedas" Fonte: Elaborado pelo autor (2021).

## 6.2. Resistência à Compressão de Pelotas Cruas (RPC)

A Tabela 5, bem como as figuras 30 e 31 apresentam os resultados obtidos para a saída "Resistência à Compressão de Pelotas Cruas" (úmidas). Os resultados obtidos e observações foram bem semelhantes ao caso anterior (Número de Quedas).

Tabela 5 – Estatística Descritiva – Saída "Resistência à Compressão – Pelota Crua"

	RPC PV	Tree	RF_20	RF_50	RF_100	RNA_20_20	RNA_40_40	kNN_05	kNN_10	RF_100+KN N_05
R2		0,869	0,919	0,929	0,932	0,585	0,705	0,923	0,909	0,944
MAE		0,017	0,021	0,020	0,019	0,053	0,044	0,009	0,010	0,014
MSE		0,002	0,001	0,001	0,001	0,005	0,003	0,001	0,001	0,001
RMSE		0,039	0,033	0,031	0,031	0,069	0,058	0,030	0,032	0,027

Fonte: Elaborado pelo autor (2021).

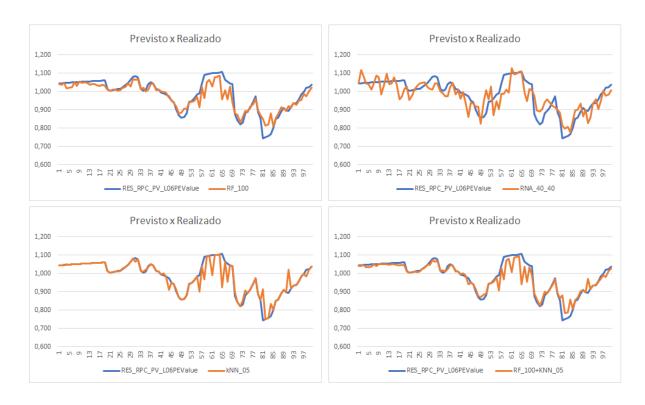


Figura 30 – Gráficos "Previsto x Realizado" – Saída "Resistência à Compressão de Pelotas Cruas" Fonte: Elaborado pelo autor (2021).

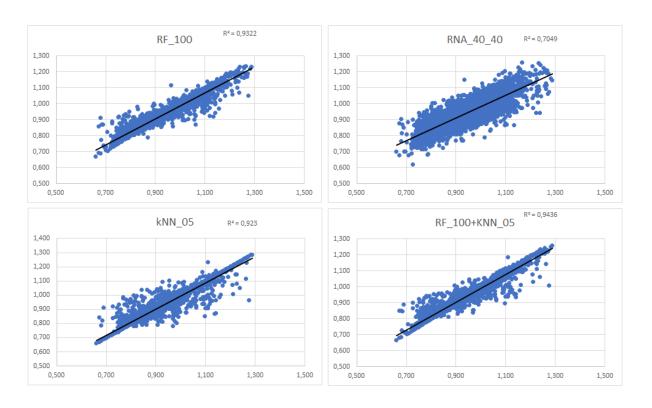


Figura 31 – Gráficos de Dispersão – Saída "Resistência à Compressão de Pelotas Cruas" Fonte: Elaborado pelo autor (2021).

## 6.3. Resistência à Compressão de Pelotas Secas (RPS)

A Tabela 6, bem como as figuras 32 e 33 apresentam os resultados obtidos para a saída "Resistência à Compressão de Pelotas Secas". Os resultados obtidos e observações foram bem semelhantes aos casos anteriores (Número de Quedas / RPC).

Tabela 6 – Estatística Descritiva – Saída "Resistência à Compressão – Pelota Seca"

	RPS PV	Tree	RF_20	RF_50	RF_100	RNA_20_20	RNA_40_40	kNN_05	kNN_10	RF_100+KN N_05
R2		0,855	0,916	0,925	0,929	0,627	0,743	0,919	0,911	0,941
MAE		0,062	0,074	0,072	0,070	0,173	0,141	0,034	0,037	0,051
MSE		0,020	0,013	0,012	0,012	0,051	0,035	0,011	0,012	0,009
RMSE		0,143	0,115	0,111	0,109	0,226	0,188	0,105	0,110	0,095

Fonte: Elaborado pelo autor (2021).

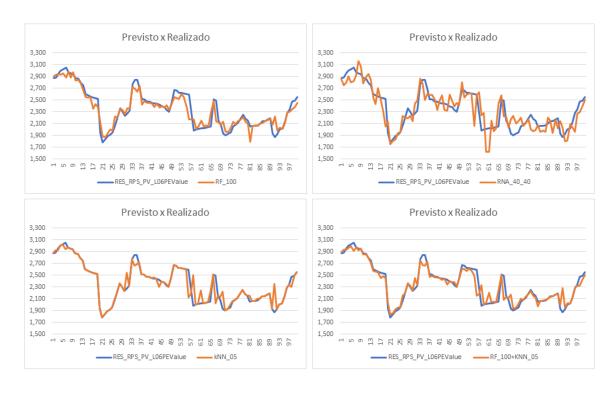


Figura 32 – Gráficos "Previsto x Realizado" – Saída "Resistência à Compressão de Pelotas Secas" Fonte: Elaborado pelo autor (2021).

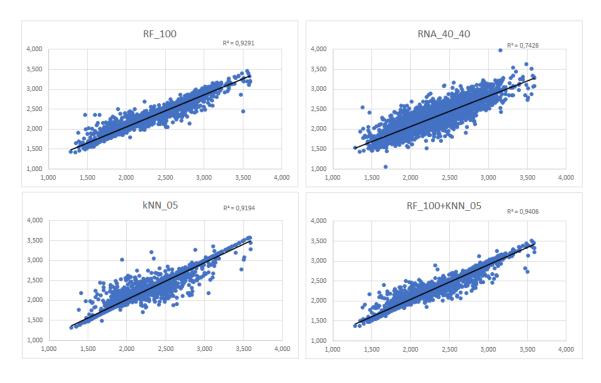


Figura 33 – Gráficos de Dispersão – Saída "Resistência à Compressão de Pelotas Secas" Fonte: Elaborado pelo autor (2021).

#### 6.4. Umidade

A Tabela 7, bem como as figuras 34 e 35 apresentam os resultados obtidos para a saída "Umidade".

Observa-se neste caso que, comparando-se os modelos individuais, o método Random Forest com 100 árvores apresentou o melhor resultado de RMSE, enquanto o método KNN com 5 vizinhos apresentou o melhor MAE. O método "coletânea" apresentou os melhores resultados de R2 e RMSE, sendo considerado o melhor modelo.

Tabela 7 – Estatística Descritiva – Saída "Resistência à Compressão – Umidade"

	UMID. PV	Tree	RF_20	RF_50	RF_100	RNA_20_20	RNA_40_40	kNN_05	kNN_10	RF_100+KN N_05
R2		0,854	0,916	0,925	0,929	0,614	0,707	0,908	0,906	0,939
MAE		0,051	0,058	0,057	0,055	0,139	0,117	0,027	0,029	0,039
MSE		0,013	0,008	0,008	0,007	0,033	0,025	0,008	0,008	0,006
RMSE		0,113	0,090	0,088	0,086	0,181	0,158	0,088	0,089	0,075

Fonte: Elaborado pelo autor (2021).

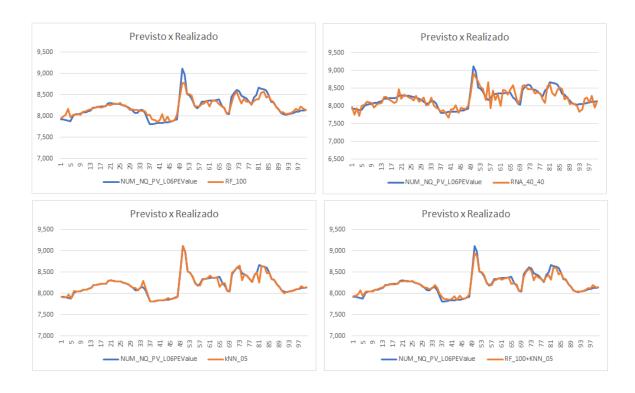


Figura 34 – Gráficos "Previsto x Realizado" – Saída "Umidade" Fonte: Elaborado pelo autor (2021).

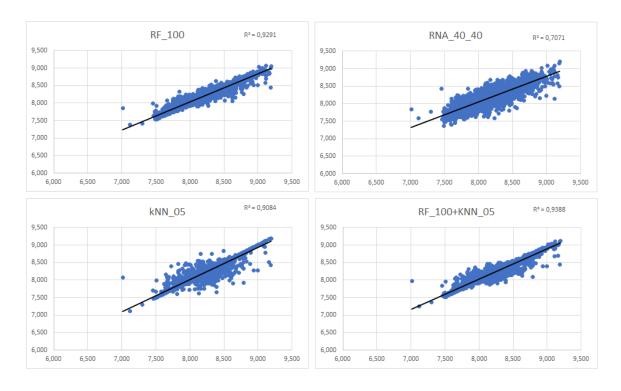


Figura 35 – Gráficos de Dispersão – Saída "Resistência à Compressão de Pelotas Secas" Fonte: Elaborado pelo autor (2021).

### 7. Conclusões

Este trabalho propôs avaliar a aplicação de algoritmos de aprendizado de máquinas para solução do problema de predição em tempo real dos parâmetros de qualidade da etapa de pelotamento de usinas de pelotização de minério de ferro. Não havia casos registrados na literatura técnica existente sobre modelagem para o circuito específico proposto.

Foram coletados dados de uma das Usinas de Pelotização da Vale, em Vitória-ES, através da base de dados histórica do PIMS. Os dados foram tratados e aleatoriamente foram definidos o conjunto de treinamento e validação, contendo originalmente 4 variáveis de saída (target) e 42 variáveis de entrada (features), totalizando 20.109 amostras. A definição do intervalo de dados da coleta e a frequência de amostragem mostrou-se adequada, sendo obtida uma grande quantidade de dados, garantindo variabilidade suficiente para se obter uma generalização dos dados.

O modelamento dos sensores virtuais foi feito utilizando-se a ferramenta computacional Orange. Foram avaliadas técnicas distintas de modelamento: Árvores de Decisão, Florestas Aleatórias, KNN e Redes Neurais artificiais.

De acordo com widgets de ranqueamento do Orange, foi possível observar e confirmar que novas variáveis criadas na etapa de preparação de dados possuíam maior poder preditivo do que variáveis originalmente coletadas.

Com base no conjunto de dados e modelos desenvolvidos:

- I. Verificou-se na prática que modelos estatísticos baseados em árvores de decisão, porém, construídos de forma que a saída é definida através média das respostas obtidas de cada modelo individual (*Random Forest*) apresentam indicadores de qualidade do modelo (Coeficiente de Correlação / R2, MSE, RMSE) muito melhores que uma única árvore de decisão.
- II. Comparou-se 3 diferentes modelos *Random Forest*, com quantitativos diferentes de árvores. Observou-se que à medida que se aumenta o número de árvores de votação, os indicadores de qualidade melhoram. Entretanto, observou-se que, a partir de um determinado quantitativo de árvores, a melhora não é significativa, o que se leva a necessidade de se definir um compromisso entre performance computacional x precisão do modelo.
- III. Comparou-se duas (2) diferentes configurações de Redes Neurais Artificiais, tipoPerceptron Multicamadas, com duas camadas ocultas. A primeira possuía 20

neurônios / camada, enquanto a segunda, 40. Observou-se que a Rede com maior número de neurônios na camada oculta apresentou melhor resposta. Entretanto, cabe-se ressaltar que não é possível generalizar isto como uma afirmação verdadeira. As configurações das RNA's variam de acordo com o problema a ser modelado. Não existe formulação matemática que defina o número adequado para a quantidade de neurônios. Na prática, a definição é feita de forma empírica e através de "tentativa e erro", com base na melhora do Coeficiente de Correlação (R2).

- IV. Comparou-se dois modelos KNN, variando-se a quantidade de vizinhos (5 e 10).
   Os resultados apresentaram-se muito homogêneos com uma pequena melhora para o modelo configurado com quantidade inferior de vizinhos.
- V. Comparou-se as técnicas entre sí. A rede neural com 20 neurônios nas duas camadas ocultas apresentou os piores resultados para as 4 saídas estudadas (ex: R2 de 0,525, para saída "Resistência de Pelota Crua"). Curiosamente, a distribuição deste modelo apresentou o menor desvio padrão comparada aos demais modelos, o que sugere uma incapacidade de generalização, ou ocorrência de *overfitting*, de forma que não é um modelo indicado para ser aplicado na prática.
- VI. A Random Forest com 100 árvores apresentou os melhores resultados do Coeficiente de correlação para as quatro (4) saídas estudadas (ex: R2 de 0,932, para a saída "Resistência de Pelota Crua"), embora os modelos KNN também tenham apresentados resultados bastante satisfatórios (ex: R2 de 0,923, para a mesma saída). Os resultados obtidos permitiram concluir que, para problemas complexos e com relações não lineares entre as variáveis, possuir um sistema de medidas de importância de variáveis, como um meio de seleção de variáveis, permite superar qualitativamente os resultados de outros modelos de predição (ex: Redes Neurais Caixa preta).
- VII. O modelo KNN com 5 vizinhos apresentou os menores Erros Médios Absolutos (MAE). De fato, observa-se através dos gráficos previsto x realizado, uma grande quantidade de acertos de previsão (Erro=0), com as curvas apresentando-se sobrepostas em vários momentos.

VIII. Com base nas observações dos valores de MAE encontrados, é possível indicar a adoção dos sensores virtuais baseados nos algoritmos *Random Forest* e KNN.

Um modelo baseado na média dos dois melhores modelos RF e KNN foi proposto, de forma a explorar a possibilidade de melhora nos parâmetros de qualidade. Para as 4 variáveis de saída estudadas, verificou-se que em todos os casos, o novo modelo apresentou melhores respostas de R2, (ex: R2 de 0,944, para saída "resistência de pelota crua", superior à 0,932 do modelo RF\_100), e da medida RMSE (ex: 0,075, ante 0,88 do modelo KNN\_5), porém com Erros Médios Absolutos (MAE) ligeiramente piores que o modelo KNN\_5, sem que isto represente fator depreciativo para o novo modelo. De fato, avaliando-se os gráficos "predito x realizado", observa-se uma suavização da saída prevista, considerando que o modelo RF\_100 atenua os poucos erros "bruscos" causados pelo modelo KNN\_5, corroborando para a melhora do RMSE (mais influenciado pelo quadrado destes "outliers").

O circuito de pelotamento analisado neste trabalho apresentou-se altamente complexo com dinâmica não linear, e como variáveis importantes não medidas (medidas em laboratório). Mesmo diante deste cenário, os resultados obtidos indicaram forte correlação entre os dados gerados pelos modelos de predição (Random Forest, KNN e Ensable KNN\_5+RF\_100) e os resultados de análise laboratorial, de forma que é possível confirmar a hipótese originalmente levantada por este trabalho, onde a aplicação de sensores virtuais baseados em aprendizado de máquina é viável técnica e economicamente a ser explorada no caso real do processo de pelotamento de minério de ferro, permitindo tomada de decisão rápida para correção das variáveis mais significativas, evitando produção de pelotas cruas fora dos parâmetros de qualidade estipulados e reduzindo custos operacionais (redução de retorno do pelotamento).

### 8. Trabalhos futuros

Indica-se que os modelos de predição dos parâmetros de qualidade do pelotamento apresentados neste trabalho sejam aplicados em um ambiente real de uma usina de pelotização de minério de ferro, de forma que os sensores virtuais possam ser avaliados em uma situação prática e mensurados vantagens, desvantagens, e dificuldades decorrentes de sua utilização na indústria.

Uma vez implantado, sugere-se a aplicação deste sensor virtual como variável de entrada para o sistema de otimização da etapa de pelotamento.

Dada a necessidade de aumento de eficiência do processo produtivo de pelotamento, e o grande número de variáveis envolvidas em seu funcionamento, sugere-se o desenvolvimento de um modelo de classificação por aprendizado de máquina, para determinar uma medida de performance do processo com base na taxa de produção e atendimento às restrições dos parâmetros de qualidade.

Considerando-se a importância das variáveis de qualidade, medidas em laboratórios nas etapas de Moagem, Homogeneização, Filtragem e Prensagem, sugere-se a criação de novos modelos de predição que atendam às necessidades de informação em tempo real para tomada de decisão nestes processos. Além disto, os modelos para predição de qualidade de pelota crua apresentados neste trabalho, podem ser reavaliados para inclusão destas variáveis, o que se acredita, pode melhorar ainda mais a performance do preditor.

A utilização de outros algoritmos de Aprendizado de Máquina, como o AdaBoost, e Processos Gaussianos, bem como a aplicação de técnicas para redução de dimensionalidade e/ou seleção de características (ex: abordagem *Wrapper, Gulosa, Correlation Atribute Eval*, Análise de Componentes Principais) podem melhorar os resultados obtidos neste trabalho.

# 9. Referências Bibliográficas

ALDRICH, C; AURET, L. Unsupervised Process Monitoring and Fault Diagnosis with Machine Learning Methods. 2013, Springer. 577p.

HAYKIN, S. **Redes Neurais: princípios e práticas**. Tradução de Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001. 900p.

BORIM, J. C.; Modelagem e Controle de um Processo de Endurecimento de Pelotas de Minério de Ferro. UFMG, 2000

CETEM – Centro de Tecnologia Mineral – Ministério de Ciência e Tecnologia; **Tratamento de Minérios**. 2010. 5ª Edição. Rio de Janeiro, RJ.

DE PAULA, A. F. S., et al. Influência da Qualidade do Pellet Feed para Dosagem de Insumos na Pelotização.

DEVI, M. A.; JOSHI, V. P.; PRAKASH, C. P. S.; PALADA, R. S.; CHINNANNAVAR, R. P., DIXIT, R.; **An Informatic Approach to Predict the Mechanical Properties of Aluminum Alloys using Machine Learning Techniques**. IN: Proceedings of the International Conference on Smart Electronics and Communication (ICOSEC 2020)

DRUMOND, P.; KAPPES, D.; MORAES, C.; OLIVEIRA, E.; TEIXEIRA, M.; **Soft Sensor: Machine Learning Tradicional ou Deep Learning?** Trabalho apresentado no 22º Seminário de Automação e TI. 02 a 04 de outubro de 2018, São Paulo, SP.

FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F.; Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina. 2011. LTC. Rio de Janeiro, RJ.

FAN, X.; LIB, Y.; CHEN, X.; **Prediction of Iron Ore Sintering Characters on the Basis of Regression Analysis and Artificial Neural Network**. IN: Energy Procedia, 16, 2012, pg 769-776. Publicado por Elsevier B.V.

GUEDES, E. V. O.; Aplicação de Soft Sensor Baseado em Redes Neurais Artificiais e Random Forest para Predição em Tempo Real do Teor de Ferro no Concentrado da Flotação de Minério de Ferro. Universidade Federal de Ouro Preto, 2020. Ouro Preto, MG

JESUS, E. F.; Modelagem e Controle de um Processo de Dosagem de Carvão Mineral e de um Processo de Endurecimento de Pelotas de Minério de Ferro. Universidade Federal do Espírito Santo, 2009. Vitória, ES.

NUNES. Influência da Carga Circulante do Pelotamento na Qualidade Física das Pelotas Cruas e Queimadas da Samarco Mineração. 2007. Ouro Preto, MG.

KAPLAN, U.E.; TOPAL, E.; A New Ore Grade Estimation Using Combine Machine Learning Algorithms. IN: Minerals 2020, 10, 847.

MEYER, K.; **Pelletizing of Iron Ores**. Heidelberg: Springer-Verlag Berlin, Dusseldorf: Verlag Stahleisen mbH, 1980

SANDHYA, N., SOWMYA, V., BANDARU, C. R.; BABU, G. R.; Prediction of Mechanical Properties of Steel using Data Science Techniques. IN: International Journal of Recent Technology and Engineering (IJRTE). ISSN: 2277-3878, Volume-8 Issue-3, Setembro de 2019

Tohry, A.; Chelgani, S. C.; Matin, S. S.; Noormohammadi, M.; **Power-draw prediction by random forest based on operating parameters for an industrial ball mill**. IN: Advanced Powder Technology. Publicado por Elsevier B.V.

PIROLA A. C.; TASAICO. D. E. O.; FONSECA, M. C.; Influência do Tempo de Secagem, Tamanho das Pelotas, Vazão e Temperatura dos Gases no Processo de Secagem de Pelotas de Minério de Ferro. IN: Tecnologia, Metalurgia, Materiais, e Mineração, São Paulo, v. 16, n. 1, p. 37-44, jan./mar. 2019.

RUSSEL, S.; NORVING, P.; **Artificial Intelligence – A Modern Approach**. 3a edição, Prentice Hall, 2010.

SILVA, F. D.; Redução do Delta de Resistencia à Compressão entre Pelotas Produzidas e Embarcadas nas Usinas de Pelotização da Vale – Uma Análise de Causas. UFOP, 2010.

THOMAZINI, A.D; TRÉS, E.P.; MACEDO, F.A.D.; BUENO, G.; FERNANDES, R.B.; NUNES, R.A.P.; **Pelotização de Minério de Ferro Cominuído por Múltiplas Prensagens**. Trabalho apresentado no 49° Seminário de Redução de Minério de Ferro e Matérias-Primas e 7° Simpósio Brasileiro de Aglomeração de Minério de Ferro. 01 a 03 de outubro de 2019, São Paulo, SP, Brasil

VALE; Diretoria de Pelotização, Complexo de Tubarão. **PRO 005630 – Realizar Testes Físicos no Processo de Pelotização Industrial e Piloto, revisão 16**. 2021. Vitória, ES.

VALE; Diretoria de Pelotização, Complexo de Tubarão. **REG 000291 – Manual de Operação** Usinas de Pelotização. 2012, Vitória, ES

VALE; Diretoria de Pelotização, Complexo de Tubarão. **Relatório Técnico – Plano Diretor** de Automação e Instrumentação – Processos de Moagem, Filtragem, Pelotamento e Queima – Memorial Descritivo – Projeto Conceitual. 2015. Vitória, ES.