



UNIVERSIDADE FEDERAL DO PARÁ  
CAMPUS UNIVERSITÁRIO DE TUCURUÍ  
FACULDADE DE ENGENHARIA ELÉTRICA

RICKELLE MORAES LACERDA

**ANÁLISE DE DADOS DE MANUTENÇÃO USANDO APRENDIZADO DE  
MÁQUINA – ESTUDO DE CASO EM UMA PENEIRA VIBRATÓRIA DO  
SEGMENTO DE MINERAÇÃO**

TUCURUÍ - PA

2021

RICKELLE MORAES LACERDA

**ANÁLISE DE DADOS DE MANUTENÇÃO USANDO APRENDIZADO DE MÁQUINA – ESTUDO DE CASO EM UMA PENEIRA VIBRATÓRIA DO SEGMENTO DE MINERAÇÃO**

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia Elétrica, do Campus Universitário de Tucuruí, da Universidade Federal do Pará, como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica.

Orientador(a): Dr. Rafael Suzuki Bayma

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD  
Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

---

L131a Lacerda, Rickelle Moraes.  
Análise de dados de manutenção usando aprendizado de máquina - estudo de caso em uma peneira vibratória do segmento de mineração / Rickelle Moraes Lacerda. — 2021.  
79 f. : il. color.

Orientador(a): Prof. Dr. Rafael Suzuki Bayma  
Trabalho de Conclusão de Curso (Graduação) - Universidade Federal do Pará, Campus Universitário de Tucuruí, Faculdade de Engenharia Elétrica, Tucuruí, 2021.

1. Peneira. 2. FMEA. 3. Machine Learning. 4. PCA. 5. Clustering. I. Título.

CDD 006.31

---

À minha família e amigos, que sempre me apoiaram e estiveram ao meu lado durante toda essa jornada da graduação, e em especial à memória de meu Pai.

## AGRADECIMENTOS

Para a realização desse trabalho coloquei Deus a frente de tudo, e Ele tudo o fez. Obrigada, Senhor! O apoio da minha família sempre, não só durante a monografia, mas principalmente durante toda a minha graduação foi de suma importância. À minha mãe, Francisca Eliana, o meu muitíssimo obrigada por todo amor, carinho, preocupação, cuidado e dedicação em me acompanhar durante toda essa jornada, mesmo sendo muitas vezes apenas ligações e trocas de incansáveis áudios por telefone. Ouvir sua voz e um conselho seu me confortou milhares de vezes. Eu te amo muito, mamãe! Rita e Rizia, minhas irmãs queridas, obrigada por apostarem em mim e por me incentivarem a persistir e continuar em busca desta árdua conquista. Isso tudo é por vocês! E eu as amo muito.

Expresso aqui também minha sincera gratidão aos meus amigos Ingrid, Bárbara, Érika, Kissy e Leandro por terem me acompanhado durante toda a graduação, por terem sido mães, pais, amigos, filhos e irmãos para mim tantas vezes. Crescemos, evoluímos, aprendemos e amadurecemos muito juntos.

Agradeço também a parceria constante e diária da Távita, Lucas, Dariele, Gerônimo, Kácia, Luan, Gustavo e Wendria. Dividir, compartilhar e viver a graduação com vocês foi especial e único. Muito obrigada! Brenda e Thiago, muito obrigada pelo apoio e ajuda nesse importante trabalho, vocês fizeram a diferença!

Ter o professor Bayma como meu orientador neste trabalho é um grande privilégio, pois durante o curso ele me foi uma grande inspiração. Ter tido aulas e ensinamentos extraclasse ao lado do Lucas com ele me fez aprender coisas muito válidas e de grande importância dentro da Engenharia Elétrica. Sua sabedoria, paciência e dedicação em ensinar fez com que isso fosse possível.

Aos queridos senhores Edgar da Automação, Helayne, Ronaldo e equipe de Instrumentação, Gilberto, Dayana, Soraia, Uillian e Kleber da empresa onde estagiei e constantemente agrego muito conhecimento, o meu obrigada por seu costumeiro apoio e por me ajudarem de n formas a colher os dados, a obter informações acerca do problema que eu me propus a enfrentar nesse trabalho.

“A esperança é a única coisa mais forte que o medo” (Jogos Vorazes, 2008).

## RESUMO

Em busca de um problema recorrente em uma grande empresa de mineração que pudesse ser estudado e abordado, foram realizadas pesquisas e análises em sistemas supervisórios e de aquisição de dados referentes a equipamentos que estão inseridos no processo de beneficiamento do minério, e assim selecionou-se uma peneira para esse estudo que apresentou 109 eventos de falhas dos setores de Elétrica, Instrumentação e Automação durante todo o ano de 2019. A partir dessa escolha foram feitas análises quantitativas e qualitativas, investigações e pesquisas em campo para buscar justificativas para o número elevado de eventos que geraram manutenções. Um Perfil de Perdas, que consiste na estratificação das perdas do processo produtivo por meio de gráficos de Pareto, a fim de identificar quais são as maiores oportunidades de ganho no equipamento foi elaborado. Assim como se fez uso da ferramenta *FMEA* (Análise dos Modos e Efeitos de Falha) que apontou quais falhas são mais críticas e quais ações com certa prioridade devem ocorrer para que dessa forma se alcance uma maior Confiabilidade do ativo. Neste contexto, entendeu-se a importância de através da Inteligência Artificial e do Aprendizado de Máquina criar um código no *MATLAB* usando as técnicas *PCA* e *Clustering*. Sendo capazes de, a partir de amostras de dados referentes ao funcionamento da peneira, analisar o comportamento desses dados e descobrir o que seriam os que apresentam anomalias, se encaixando em grupos de classe de dados com defeito, e os que não possuem em grupos de classe de dados sem defeito. Para que dessa forma seja possível diagnosticar o equipamento e futuramente, melhorando o código, seja possível até mesmo prever falhas neste e em seus semelhantes, fazendo com que perdas no processo sejam mitigadas.

**Palavras-chave:** Peneira. *FMEA*. *Machine Learning*. *PCA* e *Clustering*.

## ABSTRACT

In search of a recurring problem in a large mining company, that could be studied and approached, research and analysis were carried out on supervisory and data acquisition systems referred to equipment that are inserted in the ore beneficiation process, and so a Screen was selected for this study, that presented 109 failure events in the departments of Electrical, Instrumentation and Automation throughout 2019. From now on, quantitative and qualitative analyzes, investigations and field research were made to seek justifications for the high number of events that generated maintenance. A Losses Profile, which consists of stratifying the losses of the production process by using Pareto charts, in order to identify which are the greatest gain opportunities in the equipment was elaborated. As well as the use of the FMEA tool (Failure Mode and Effect Analysis) that pointed out which failures are most critical and which actions with a certain priority must occur in order to achieve greater Reliability of the asset. In this context, it was understood the importance to, through Artificial Intelligence and Machine Learning, create a code in MATLAB, using the techniques: PCA and Clustering. Which was able to, from samples of data regarding the functioning of the Screen, to analyze the behavior of these data and find out what would be the ones that present anomalies, fitting in with defective data class groups, and those that do not have anomalies in non defective data class groups. So that it is possible to diagnose the equipment and in the future, improving the code, even predict faults in this equipment and its similars, causing losses in the process to be mitigated.

**Keywords:** Vibration Screen. FMEA. Machine Learning. PCA e Clustering.

## LISTA DE ILUSTRAÇÕES

Figura 1- Fluxograma típico de tratamento de minério.....	22
Figura 2 - Peneira vibratória do tipo TD. ....	23
Figura 3 - Estrutura de Classe de Falhas da CVRD .....	24
Figura 4 - Aplicação de classe de falha de um equipamento.....	24
Figura 5 - Esboço de componentes principais $e_1$ e $e_2$ e sua direção sobre uma dispersão. ....	30
Figura 6 - Equivalência entre a matriz inicial X e seu modelo PCA respectivo. ....	32
Figura 7 - Dendrograma, ligação completa com distância euclidiana, criado usando-se uma partição final de 4 agrupamentos, que ocorre em um nível de similaridade de aproximadamente 40.....	34
Figura 8. K-means algoritmo iterativo que particiona o conjunto de dados em “k” subgrupos distintos e não sobrepostos predefinidos.....	34
Figura 9. Método de <i>Ward Linkage</i> avalia o grau de relação entre os <i>clusters</i> através da distância geométrica espacial entre eles. ....	35
Figura 10. Distância euclidiana. ....	36
Figura 11. Carta $T^2$ Hotelling.....	37
Figura 12 - <i>Power BI</i> apresentado em seus três elementos. ....	39
Figura 13 - Composição das partes da peneira vibratória do tipo TD. ....	41
Figura 14 - Descrição das partes da peneira do tipo TD. ....	42
Figura 15 - Quantidade de eventos de falhas apresentadas nas dez peneiras em 2019, no qual destaca-se a peneira PN-03 com o maior número de falhas. ....	45
Figura 16 - Quantidade de horas paradas para manutenção das peneiras. ....	46
Figura 17 - Número de eventos por setor ao longo do ano de 2019.....	47
Figura 18 - Falhas em componentes por setor.....	47
Figura 19 - Perfil de Perdas da Peneira PN-03 em seus componentes.....	48

Figura 20 - Número de eventos de falhas e de horas paradas para manutenção corretiva por mês na peneira PN-03 em 2019.....	49
Figura 21 - 1° a 4 ° Nível de estratificação para se identificar falhas. ....	51
Figura 22 – Dispersão dos dados no plano P1-P2. ....	60
Figura 23 - <i>Biplot</i> no plano P1- P2. ....	61
Figura 24 - Carta $T^2$ de <i>Hotelling</i> com linha limite para $\alpha = 95\%$ . ....	64

## LISTA DE TABELAS

Tabela 1 - Modos de falhas em sistema de peneiras vibratórias. ....	25
Tabela 2 - Relação entre aceleração e velocidade de rotação.....	43
Tabela 3 - Pesquisa de avarias por tipos.....	44
Tabela 4 - Planilha para auxiliar na definição do valor da Ocorrência. De acordo com as características dos dados coletados referentes às falhas é atribuído o índice de ocorrência que varia de 1 a 10. Para definir o índice de ocorrência é analisada a probabilidade de falha e, a partir das taxas de falhas possíveis, atribui-se o índice.....	52
Tabela 5 - Planilha para definição do valor de severidade. O índice varia de 1 a 10, no qual o valor é atribuído a partir dos dados coletados referentes ao funcionamento do equipamento e, a partir das características do efeito da severidade, o índice é definido.	52
Tabela 6 - Planilha para auxiliar na definição do valor da Detecção. Os valores do índice variam de 1 a 10, no qual tais valores são atribuídos a partir da detecção das falhas, se estas são possíveis de detectar nas inspeções e conjunto com as faixas sugeridas dos métodos de detecção.....	53
Tabela 7- Vetores explained e cumexplained [%].....	58
Tabela 8 - Média e variância de $x$ .....	59

## LISTA DE ABREVIATURAS E SIGLAS

ACC	Acumulado
AM	Aprendizado de Máquina
BI	<i>Business Intelligence</i>
BL	Bomba de Lubrificação
CCM	Centro de Controle de Motores
CVRD	Companhia Vale do Rio Doce
DFMEA	<i>Design Failure Mode and Effects Analysis</i>
F	Força dinâmica
FMEA	<i>Failure Mode and Effect Analysis</i>
g	grama
Hz	Hertz
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia Estatística
iOS	<i>iPhone Operating System</i>
M	Massa desbalanceada
MATLAB	<i>MATrix LABoratory</i>
mm	Milímetro
MSD	<i>Multivariate Statistical Distance</i>
OCR	<i>Optical Character Recognition</i>
ONU	Organização das Nações Unidas
PCA	<i>Principal Component Analysis</i>
PFMEA	<i>Process Failure Mode and Effects Analysis</i>
PIMS	<i>Process Information Management System</i>
PLC	Controlador Lógico Programável
R	Excentricidade da massa desbalanceada
RGB	<i>Red Green Blue</i>
rpm	Rotação Por Minuto

RPN	<i>Risk Priority Number</i>
SCADA	<i>Supervisory Control and Data Acquisition</i>
SDCDs	Sistema digital de controle distribuído
SQL	<i>Structured Query Language</i>
SVM	<i>Support Vector Machine</i>
TD	<i>Tapped density</i>
VUR	Vida Útil Remanescente
W	Frequência circular de rotação

## LISTA DE SÍMBOLOS

%	Por cento
$\theta$	Direção sobre uma dispersão
$e_1 e_2, i$	Esboço de componentes principais
$X$	Matriz de covariância
$v$	Autovetor
$C_X$	Matriz quadrada
$\lambda$	Autovalor de $C_X$
$I$	Matriz identidade
$T$	Matriz de scores
$P$	Matriz transposta de <i>loadings</i>
$E$	Matriz de ruído
$\bar{m}$	Vetor de média de um <i>cluster</i> multidimensional,
$n$	Número de elementos do <i>cluster</i> multidimensional
$d$	Distância Euclidiana
$P$ e $Q$	Pontos para cálculo da distância euclidiana
$\lambda$	Matriz diagonal
$m$	Número de amostras
$h$	Número de componentes principais
$\alpha$	Porcentagem de confiança na Carta $T^2$ <i>Hotelling</i>
$T^2$	Gráfico da carta de <i>Hotelling</i>
$T_{lim}^2$	Linha limite do gráfico
$I$	Corrente
$T$	Torque
$v$	Velocidade
$M$	Motor
$P$	Componente Principal
$\bar{x}$	Média de valor das variáveis
$\sigma^2$	Variância das variáveis em relação à média

# SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	<b>19</b>
<b>2. REFERENCIAL TEÓRICO</b> .....	<b>21</b>
2.1. MINERAÇÃO .....	21
2.1.1. Tratamento de Minérios .....	21
2.1.2. Peneiramento .....	22
2.2. FALHAS .....	24
2.2.1. Tipos de falhas em Peneiras .....	24
2.2.1. FMEA ( <i>Failure Mode and Effect Analysis</i> ) .....	25
2.2.1.1. Tipos de FMEA .....	26
2.3. PERFIL DE PERDAS .....	27
2.4. INTELIGÊNCIA ARTIFICIAL .....	27
2.4.1. <i>Software</i> utilizado para o desenvolvimento do algoritmo .....	28
2.4.1.1. Aprendizado de Máquina ( <i>Machine Learning</i> ) e técnicas de Aprendizado Não Supervisionado PCA e <i>Clustering</i> .....	28
2.4.1.2. PCA ( <i>Principal Component Analysis</i> ) .....	29
2.4.1.3. <i>Clustering</i> .....	32
2.4.2. Carta $T^2$ <i>Hotelling</i> .....	36
<b>3. METODOLOGIA</b> .....	<b>38</b>
3.1. SOFTWARES E SISTEMAS UTILIZADOS .....	38
3.1.1. <i>Microsoft Power BI</i> .....	38
3.1.2. PIMS .....	39
3.1.3. MATLAB .....	40
3.2. ÁREA DE ESTUDO .....	40
3.3. CARACTERÍSTICAS DA PENEIRA ESTUDADA .....	41
3.4. PESQUISA DE AVARIA .....	44
3.5. LEVANTAMENTO DE DADOS .....	45
3.5.1. Exportação de dados .....	50
3.5.2. Elaboração do FMEA .....	51
3.6. ELABORAÇÃO DO MODELO MATEMÁTICO UTILIZANDO PCA E <i>CLUSTERING</i> .....	54
<b>4. RESULTADOS E DISCUSSÕES</b> .....	<b>56</b>
4.1. ELABORAÇÃO DO FMEA .....	56
4.2. MODELO MATEMÁTICO UTILIZANDO PCA E <i>CLUSTERING</i> .....	57

4.2.1.	Variância explicada pelo modelo .....	57
4.2.2.	Classificação dos <i>clusters</i> .....	58
4.2.3.	Gráficos .....	59
4.2.3.1.	Dispersão 2-D com formação de <i>clusters</i> .....	59
4.2.3.2.	Gráficos <i>Biplot</i> .....	60
4.2.3.3.	Carta $T^2$ de <i>Hotelling</i> .....	64
<b>5.</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>66</b>
	<b>REFERÊNCIAS .....</b>	<b>68</b>
	<b>APÊNDICE 1 .....</b>	<b>75</b>
	<b>APÊNDICE 2 .....</b>	<b>78</b>

## 1. INTRODUÇÃO

O beneficiamento do minério consiste em diversas etapas que tem por finalidade modificar a granulometria, a concentração relativa das espécies minerais presentes ou a forma, todavia, sem modificar a identidade química ou física dos minerais (LUZ; SAMPAIO; FRANÇA, 2010). Diversos equipamentos são utilizados durante as etapas do processo, sendo de grande importância o seu contínuo funcionamento para não interromper o fluxo e, desse modo, evitar perda de produção. Neste contexto, encontra-se a peneira classificadora, pertencente ao processo de beneficiamento do minério e a linha de produção denominada de classificação. Nessa linha, demais equipamentos dependem do funcionamento da peneira como os britadores, os transportadores de correia, silos e alimentadores. Se a peneira ou algum outro ativo da linha apresentar falhas, todo o processo sofre impacto devido às paradas para manutenções.

A manutenção preditiva é uma técnica de análise de dados para detectar anomalias em operações e possíveis defeitos em equipamentos e processos para serem corrigidos antes que resultem em falha, possibilitando o aumento da confiabilidade do ativo e a utilização deste até o final de sua vida útil. Logo, a utilização desta técnica possibilita a redução de custo, redução de manutenções corretivas, eficiência no processo de produção, redução de danos e perda de recursos por falhas na linha de produção.

A Inteligência Artificial (IA) tem sido uma grande aliada na manutenção preditiva ao prever eventos como, por exemplo, falhas. A IA consiste na programação de computadores com capacidade de aprender, através da técnica de aprendizado de máquinas (AM), que viabilizam, ao final, tomada de decisões, estimativas futuras e até reorganização dos processos baseadas nos dados fornecidos (DAMACENO; VASCONCELOS, 2018 p. 12). O que é notável neste contexto é a possibilidade do computador aprender a resolver problemas sem ser explicitamente programado para esta finalidade. Desde a década de 1980, várias aplicações da IA foram desenvolvidas em quase todos os campos da engenharia e gestão.

Aprendizado de Máquina (AM) é um campo de pesquisa da IA que estuda o desenvolvimento de métodos capazes de resolver problemas (conhecimento) a partir de amostras de dados (MITCHELL, 1997 p. 870). Algumas técnicas são utilizadas para auxiliar o AM com objetivo de reduzir o número de dados, deixando apenas os componentes principais, como a ferramenta *Principal Component Analysis* (PCA) que

se torna útil no AM por reduzir a dimensionalidade dos dados. Além do PCA, o AM também se utiliza de técnicas para categorizar e agrupar dados de um conjunto baseado na construção de *cluster*.

Neste contexto, o presente trabalho realizou um levantamento das grandezas da peneira classificadora pertencente ao processo de beneficiamento de minério e a partir dos dados obtidos, foi criado e aplicado um algoritmo de aprendizado de máquina baseado em *PCA* e *Clustering*, para definir as classes em que as amostras de variáveis referentes ao equipamento pertencem.

Desse modo, o presente trabalho tem como Objetivo Geral: Desenvolver uma análise de dados de manutenção por meio do aprendizado de máquina a fim de evitar paradas excessivas da peneira de beneficiamento de minério. E como Objetivos Específicos: Analisar o histórico de falhas do equipamento no período escolhido; elaborar o Perfil de Perdas da peneira de acordo com seus componentes; elaborar um FMEA e propor uma solução que aumente a confiabilidade do equipamento; por fim, aplicar o aprendizado não supervisionado (*Machine Learning*) - usando as técnicas de *PCA* e *Clustering* para eliminar redundâncias nas amostras e descobrir em quais classes, com ou sem defeito, esses dados se encaixam.

Sendo assim, este trabalho está estruturado da seguinte forma: o primeiro capítulo demonstra a motivação do trabalho através da introdução, o segundo contextualiza a mineração, o equipamento estudado, os conceitos e técnicas necessários neste estudo; já o capítulo três mostra as metodologias utilizadas nas análises das falhas e a base de dados do algoritmo e o quarto apresenta os resultados e discussões acerca da implementação do *PCA* e *Clustering*. Por fim, no último capítulo, é dada a orientação dos passos iniciais para prever falhas na empresa onde ocorreu o trabalho, com essa abordagem.

## 2. REFERENCIAL TEÓRICO

### 2.1. MINERAÇÃO

Os minérios existem desde o princípio do mundo. Tais minerais são formados naturalmente e a exploração desses recursos naturais está intrinsecamente ligada à história da civilização humana desde a pré-história, sendo utilizados para criação de artefatos, objetos e na confecção de pigmentos, sobretudo em pinturas e inscrições rupestres. Assim, o início da evolução da civilização humana é observado pela necessidade de extração de recursos minerais e sua transformação em um bem útil à sua sobrevivência (PESSOA, 2006 p. 27).

A mineração pode ser definida como a extração, elaboração e beneficiamento de minerais que se encontram em estado natural: sólido, como o carvão e outros; líquido, como o petróleo bruto; e gasoso, como o gás natural. O conceito de mineração pode ser mais abrangente, e incluir

a exploração das minas subterrâneas e de superfície (ditas a céu aberto), as pedreiras e os poços, incluindo-se aí todas as atividades complementares para preparar e beneficiar minérios em geral, na condição de torná-los comercializáveis, sem provocar alteração, em caráter irreversível, na sua condição primária (CARVALHO; JÚNIOR, ABRAHIM, 2009, p.5)

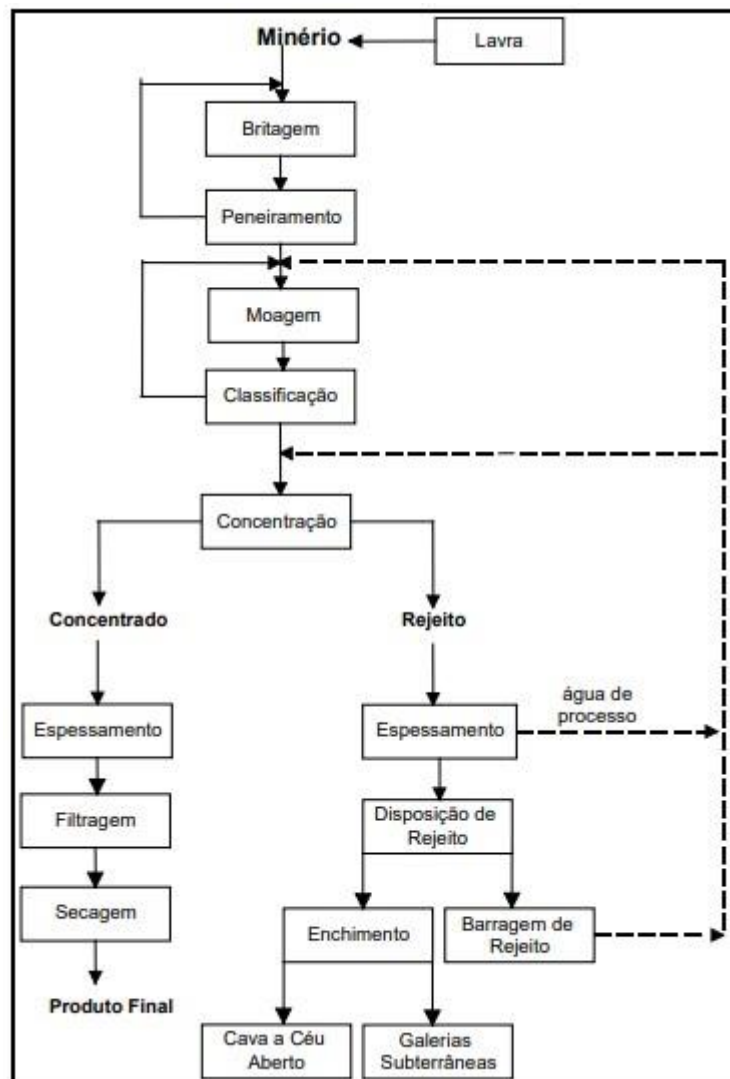
Historicamente no Brasil a indústria de extração mineral é responsável por grande porção da economia nacional devido à alta presença de recursos minerais, sendo uma das maiores potenciais mineradoras do planeta com aproximadamente 55 tipos de minerais que podem ser aproveitados para fins de exploração, como ferro, cobre, ouro, manganês, nióbio, entre outros (CARDOZO; PIMENTA; ZINGANO, 2016).

#### 2.1.1. Tratamento de Minérios

O beneficiamento de minérios é o tratamento industrial que consiste em transformar o minério bruto em concentrado por métodos físicos ou químicos para modificação da granulometria, da concentração relativa das espécies minerais presentes ou a forma, sem, contudo, modificar a identidade química ou física dos minerais (LUZ; SAMPAIO, J. A.; FRANÇA, 2010). É o primeiro processo pelo qual passa a maior parte

dos minérios após a mineração, a fim de fornecer um material mais concentrado para os procedimentos da metalurgia extrativa.

**Figura 1-** Fluxograma típico de tratamento de minério.



**Fonte:** LUZ; SAMPAIO, J. A.; FRANÇA, 2010.

### 2.1.2. Peneiramento


O peneiramento é uma operação unitária na indústria e trata da separação de sólidos granulados de diversos tamanhos através de uma superfície perfurada. As partículas com dimensões superiores à da abertura considerada tendem a ficar retidas na superfície, e as com dimensões inferiores tendem a atravessar a mesma separando os sólidos em duas ou mais porções uniformes em tamanho (ZONTA, 2013 p.87). Os mecanismos envolvidos compreendem basicamente estratificação e segregação. Os

equipamentos tradicionalmente utilizados são as peneiras vibratórias, rotativas e estáticas, e elas podem operar a seco e a úmido (DUTRA, 2008 p.5).

As peneiras vibratórias são empregadas para executar certas atividades na indústria através dos movimentos vibratórios. Os mecanismos podem executar movimentos circulares, elípticos ou lineares, a depender da finalidade empregada, e produzem amplitudes de vibrações que variam de 1,5 mm a 6 mm, com frequências de operação da máquina de 700 rpm a 1200 rpm (ASSUNÇÃO, 2009).

A Figura 2 apresenta uma peneira vibratória TD (*Tapped Density*) utilizada no processo de beneficiamento de minério. Esse modelo de peneira é inclinado e com movimento do tipo circular, sendo acionada por um eixo excêntrico com contrapesos, composta por dois módulos e cada um deles com dois decks de peneiramento (HAVER; BOECKER, 2010).

**Figura 2** - Peneira vibratória do tipo TD.

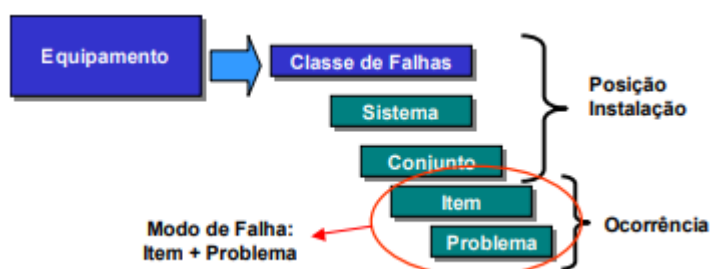


**Fonte:** HAVER; BOECKER, 2010.

## 2.2. FALHAS

Para comparar o desempenho dos diversos equipamentos das usinas e identificar quais classes de falhas, sistemas, conjuntos, itens ou modos de falhas que mais afetam a disponibilidade das usinas, na empresa utiliza-se a estrutura de classe de falha da CVRD (Companhia Vale do Rio Doce), que permite registrar todos os eventos de manutenção através de codificações hierárquicas padronizadas para equipamentos e componentes, divididos nos níveis: sistema, conjunto, item e problema (Figura 3) (ALMEIDA, 2006).

**Figura 3** - Estrutura de Classe de Falhas da CVRD



Fonte: BRAVIM; SOUZA, 2007.

Desse modo, é possível comparar o desempenho dos diversos equipamentos e identificar quais classes de falhas mais afetam a disponibilidade das usinas. A Figura 4 é um exemplo típico de classificação da falha de um equipamento (BRAVIM; SOUZA, 2007 p. 3).

**Figura 4** - Aplicação de classe de falha de um equipamento

CLASSE DE FALHA: VENTILADOR CENTRÍFUGO				
SISTEMA	CONJUNTO	ITEM	PROBLEMA	SOLUÇÃO
<b>Acionamento</b>	Acoplamento	Cabo/fiação	Ajuste	<b>Trocar</b>
Aspiração	Cascata subsíncrona	<b>Contator de média tensão</b>	Aterramento	Recuperar
Controle	Cobertura	Conversor CA-CC	Danificado	
Descarga	<b>Força</b>	Inversor	Desgaste	
Lubrificação	Motor elétrico	Painel CCM	<b>Isolação</b>	
Ventilação	Refrigeração	Painel de distribuição	Mau contato	
		Painel de força e comando		
		Partida compensada		
		Reostato líquido		
		Soft starter		

Fonte: BRAVIM ; SOUZA, 2007.

### 2.2.1. Tipos de falhas em Peneiras

Na indústria, relatos de falhas prematuras em equipamentos como a peneira vibratória são comuns de ocorrer devido ao carregamento e condição de operação,

ocasionando paradas inesperadas de manutenção e intervenções na operação gerando redução de confiabilidade do processo e perdas de produtividade (DINIZ *et al.*, 2016 p. 2). Para o ideal funcionamento da peneira vibratória, a frequência de operação deve estar distante das frequências naturais do mesmo, pois, se a frequência estiver próxima à ressonância haverá aumento na amplitude das tensões (deformações) da estrutura, resultando em falha (IIZUKA, 2006 p.149). Na Tabela 1 estão descritos os principais modos de falha, por tipo de sistema de peneiras vibratórias segundo Amaral (2016).

**Tabela 1** - Modos de falhas em sistema de peneiras vibratórias.

Acionamento	Motor elétrico	Falha do rolamento Falha elétrica
	Cardam	Quebra dos parafusos Quebra dos componentes internos
	Acionamento por polia e correia	Desgaste dos canais Rompimento das correias
Estrutura	Trincas, fissuras e rompimento das chapas internas. Deformação excessiva por erro de ajuste de contrapesos. Fixação inadequada e quebras das vigas e fixadores. Quebra, trinca e fissura dos quadros. Soltura de parafusos e fixadores.	

**Fonte:** AMARAL, 2016.

### 2.2.1. FMEA (*Failure Mode and Effect Analysis*)

O FMEA é uma técnica de Engenharia utilizada para definir, identificar e eliminar falhas conhecidas ou potenciais de sistemas, projetos, processos e/ou serviços antes que estas atinjam o cliente (STAMATIS, 2003 p. 15). Primordialmente, a técnica de FMEA foi criada para novos produtos e processos, entretanto, como apresenta diversos benefícios para a organização, passou-se a usá-la em diversas áreas e ambientes.

Utilizada para aumentar a confiabilidade durante a fase de projeto ou processo, documentando de forma organizada os modos e efeitos de falhas de componentes, incluindo possíveis falhas humanas, que possam interromper ou prejudicar o

funcionamento ou o sistema do qual este componente faça parte (SIMÕES, 2004 *apud* DE MELO PARANHOS *et al.*, 2016 p. 447).

A aplicação do FMEA consiste em duas etapas. Na primeira, utiliza-se uma tabela para a identificação dos possíveis modos de falhas e os efeitos prejudiciais. Na segunda etapa é atribuída a pontuação de risco RPN (*Risk Priority Number*) que determina o valor de avaliação de risco, no qual, quanto maior o valor do RPN, mais crítica é a falha, sendo priorizada na aplicação de ações de melhoria. Além da pontuação de risco RPN, Ermenegildo, (2005 p.28) aponta outros três fatores que ajudam na definição de prioridade de falhas, são eles: ocorrência (O), severidade (S) e detecção (D). A ocorrência define a frequência da falha, enquanto a severidade corresponde à gravidade do efeito da falha. A detecção é a habilidade para detectar a falha antes que ela atinja o cliente.

#### 2.2.1.1. Tipos de FMEA

Há dois tipos de FMEA, de projeto ou DFMEA (*Design Failure Mode and Effects Analysis*) e de processo ou PFMEA (*Process Failure Mode and Effects Analysis*). O DFMEA é utilizado para design de novos produtos com uma abordagem estruturada e detalhada de sistemas produtivos para prevenção de problemas relacionados ao projeto, bem como as suas causas e seus efeitos (SANTANA; MASSARANI, 2005 p.1).

O PFMEA é utilizado para analisar e superar as possíveis falhas de um processo específico de forma detalhada de sistemas produtivos que possam, ocasionalmente, afetar a confiabilidade prevista no produto. Nele, identificam-se cada componente do sistema e os possíveis modos de falha associados, bem como seus efeitos no sistema em questão e no produto como um todo (PALADY, 1997 p. 270). Com PFMEA, é possível proceder com as metodologias de correção de erros, além de analisar as aplicações de algum processo estrutural, de produção ou de transmissão de informações. Essa ferramenta deve ser iniciada a cada novo processo e mantido durante todo o ciclo de vida durante todo o processo.

De forma resumida, a diferença básica existente entre o DFMEA e o PFMEA é a origem da informação, pois, enquanto o DFMEA utiliza uma lista estruturada de materiais, o PFMEA faz uso de diagramas de fluxo de

processos como documento fonte de informações (DAILEY, 2004 *apud* DE MELO PARANHOS, *et al.*, 2016 p. 448).

### 2.3. PERFIL DE PERDAS

Perfil de perda consiste na análise estatística, por meio de gráficos de Pareto, relacionada às perdas de produção durante o processo e, desse modo, priorizar os problemas que causam as maiores perdas na produção. Sua elaboração inicial consiste em definir a natureza da perda, geralmente falhas, e a indisponibilidade física dos ativos. Através desses dois parâmetros identifica-se o perfil das paradas ocorridas e quais se repetem com mais frequência, além dos tipos responsáveis pela maior parte do tempo de parada das usinas e, desse modo, pode-se identificar o componente responsável pelas falhas (MACEDO FILHO, 2011 p.29).

Inicia-se a estratificação pela natureza da manutenção, após a qual é feita uma análise dos equipamentos que mais contribuíram para as perdas de produção no período, devido à interrupção da produção, e por fim, destaca-se qual o sistema ou componente que mais causou a parada do equipamento e por consequência, o que provavelmente causou as maiores perdas de produção (VILAÇA, 2014 p. 4).

Segundo Nakajima (1989 p. 106), há seis tipos de perdas na produção que são minimizadas para contribuir na evolução contínua das empresas, além de promover um crescimento sustentável: quebra de equipamento; ajustes nas preparações; parada temporária; queda da velocidade da produção; geração de produto defeituoso e retrabalho; entrada em regime de produção.

### 2.4. INTELIGÊNCIA ARTIFICIAL

Para alguns historiadores da ciência, o termo inteligência artificial (IA) é atribuído ao matemático e cientista da computação inglês Alan Turing, devido ao seu artigo "*Computing Machinery and Intelligence*" precursor no assunto. Entretanto, o estudo sobre IA advém desde a década de 1940 no desenvolvimento do computador, demonstrando que os computadores podem ser programados para realizar tarefas muito complexas. Além disso, o termo apareceu pela primeira vez no título do evento *Dartmouth Summer Research Project on Artificial Intelligence* (Projeto de Pesquisa de Verão de *Dartmouth* sobre Inteligência Artificial), realizado no *Dartmouth College* em *Hanover, New Hampshire*, EUA em 1956 (KAUFMAN, 2019 p.15).

IA é uma ciência multidisciplinar de conhecimento associado à linguagem, ao raciocínio, à aprendizagem e à resolução de problemas com objetivo de emular os processos de pensamento humano, a capacidade de aprendizagem e o armazenamento de conhecimento. Um sistema IA não é capaz somente de armazenar e manipular dados, mas também é capaz de adquirir, representar e manipular o conhecimento (SILVER; YANG 2013 p.49).

Para Luger (2014, p.49), algumas das áreas de aplicação e contribuições da Inteligência Artificial são jogos, compreensão da linguagem natural, modelagem semântica, modelagem do desempenho humano, planejamento e robótica, linguagens e ambientes para inteligência artificial, redes neurais e algoritmos genéticos.

#### 2.4.1. *Software* utilizado para o desenvolvimento do algoritmo

A inteligência artificial se concentra no uso de dados e algoritmos para imitar a forma como os humanos aprendem, melhorando gradativamente sua precisão, sistematizando e automatizando tarefas intelectuais. Desse modo, algoritmos são usados para cálculos, processamento de dados e raciocínio. Os *softwares* são produtos intangíveis e utilizam no seu processo de construção recursos intelectuais humanos, que vão desde sua especificação até sua distribuição e pleno funcionamento (SILVA, 2005, p.1).

##### 2.4.1.1. Aprendizado de Máquina (*Machine Learning*) e técnicas de Aprendizado Não Supervisionado PCA e *Clustering*

Aprendizado de Máquina (AM) é um campo de pesquisa da Inteligência Computacional que estuda o desenvolvimento de métodos capazes de extrair conceitos (conhecimento) a partir de amostras de dados (MITCHELL, 1997, p.11). A teoria de AM é baseada nos princípios do aprendizado indutivo, ou seja, modelos são determinados a partir de um conjunto de dados ou representações de experiências (RUSSEL; NORVIG, 1995 p.26).

O AM apresenta três paradigmas que podem ser utilizados na solução de problemas: supervisionado, não supervisionado e por reforço (HAYKIN, 1999, p.85). A escolha de um paradigma de aprendizado determina a maneira como o algoritmo de AM se relaciona com seu meio ambiente, ou seja, o modo como ocorrerá o seu aprendizado através de um conjunto de dados (LORENA; CARVALHO, 2003, p.44).

O aprendizado supervisionado ocorre quando há a tentativa de prever uma variável dependente a partir de uma lista de variáveis independentes através dos resultados pré-definidos por conjuntos de exemplos na forma entrada e saída desejada. O algoritmo de AM extrai a representação do conhecimento a partir desses exemplos, com objetivo de produzir saídas corretas para novas entradas não apresentadas previamente (BARRETO, 1999, p.291).

No aprendizado não supervisionado não há valores de saída desejada, desse modo, em vez de responder à programação de um operador, esse paradigma identifica semelhanças nos dados e reage com base na presença ou ausência de tais semelhanças em cada novo dado, desenvolvendo habilidades para formar representações internas capazes de codificar características da entrada e, portanto, criar novas classes automaticamente (BITTENCOURT; OSÓRIO, 2001, p. 14).

O aprendizado por reforço é uma forma de programar agentes utilizando recompensas e punições para resolver tarefas específicas através de interações com o ambiente, utilizando a técnica de tentativa e erro com objetivo de encontrar uma solução ao problema. Assim, o aprendizado por reforço é uma aprendizagem a partir de um mapeamento de entrada-saída alcançado através de interação contínua com o ambiente para minimizar um índice escalar de desempenho (BARTO; SUTTON, 1997, p.358).

#### 2.4.1.2. PCA (*Principal Component Analysis*)

A Análise de Componentes Principais, conhecida como *Principal Component Analysis* (PCA) é uma técnica estatística de aprendizado de máquina não supervisionado utilizada para condensar a informação contida em um conjunto de dados onde há muitas variáveis inter-relacionadas, com uma perda mínima de informação. Através da redução, tem-se um novo e reduzido conjunto de variáveis não correlacionadas, chamadas componentes principais. Esses componentes são organizados de forma que os primeiros armazenam a maior parte da variância presente nas variáveis originais. Trata-se de um extrator de característica não supervisionado, usado para identificar características entre classes que não têm uma definição prévia (SOUZA, 2011, p.2).


O método PCA é considerado exploratório por auxiliar na criação das hipóteses a partir dos dados obtidos e por conseguir separar informações importantes das repetidas. Em uma análise de componentes principais, o agrupamento das amostras define a estrutura dos dados pela construção de gráficos de *scores* e *loadings*, cujos

eixos são componentes principais (PCs) nos quais os dados são projetados (PANERO *et al.*, 2009, p.34).

A análise de componentes principais tem como finalidade esclarecer a estrutura da variância e covariância de um vetor aleatório, composto de variáveis aleatórias, por meio de combinações lineares das variáveis originais. Essas combinações lineares são chamadas de componentes principais e são não correlacionadas entre si (SANDANIELO, 2008 *apud* HONGYU; SANDANIELO; DE OLIVEIRA JUNIOR, 2016, p.84). Essa técnica permite agrupar indivíduos a partir do comportamento dentro da população de acordo com a variação de suas características.

Conforme Nascimento e Guardani (2007, p.), a técnica de PCA pode ser mais facilmente compreendida através da interpretação geométrica. A qual consiste em criar um novo sistema de coordenadas ortogonais a partir de um plano inicial representado pelas variáveis  $X_1$  e  $X_2$ , que deve ser rotacionado até certa direção  $\theta$ , de modo que a variação total extraída da distribuição será máxima (Figura 5).

**Figura 5** - Esboço de componentes principais  $e_1$  e  $e_2$  e sua direção sobre uma dispersão.



**Fonte:** Nascimento e Guardani (2007).

$$e_{1,i} = X_{1,i} \cos \theta + X_{2,i} \sin \theta \quad (1)$$

$$e_{2,i} = -X_{1,i} \sin \theta + X_{2,i} \cos \theta \quad (2)$$

Assim, os eixos  $e_1$  e  $e_2$  correspondem às componentes principais, que podem ser determinadas de acordo com as eq. (1) e (2), respectivamente, para observação  $i$

qualquer. A projeção dos pontos originais no novo sistema de coordenadas corresponde aos *scores* (losangos azuis da figura 5), que traduzem a composição das componentes em relação às amostras, ou seja, é o valor que será projetado sobre as componentes principais, são esses novos valores após a aplicação do PCA nos dados. Os *loadings* ou pesos (setas de direção de  $e_1$  e  $e_2$  na figura 5), por sua vez, fornecem essa mesma composição a respeito das variáveis/colunas, é o quanto o eixo das variáveis está relacionado as componentes principais (NASCIMENTO; GUARDANI, 2007; VASCONCELOS, 2011 p.3).

A forma de determinar algebricamente o vetor de pesos inicia-se encontrando a matriz de covariância de  $X$ , que depois de centrada na média, pode ser calculada através do produto dela mesma pela sua transposta. Então sendo a matriz inicial  $X$ , logo  $\bar{X}$  representa  $X$  centrada na média (VASCONCELOS, 2011 p.5):

$$C_X = \bar{X}'\bar{X} \quad (3)$$

Por conseguinte,  $C_X$  sendo uma matriz quadrada, o vetor de *loadings* será igual ao autovetor  $v$  da respectiva matriz de covariância, de maneira que o produto  $vC_X$  resulta em  $\lambda v$ , sendo  $\lambda$  o autovalor de  $C_X$  associado ao autovetor  $v$ , conforme a eq. (4). Vale ressaltar que na análise de componentes principais, haverá um autovalor da matriz de covariância relacionado a cada componente, de sorte que os autovalores de maiores índices representam as componentes que retém as maiores parcelas de informação dos dados, isto é,  $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_p$  (VASCONCELOS, 2011, p.6; VARELLA, 2008, p.8).

$$C_X v = \lambda v \quad (4)$$

Ainda de acordo com Varella (2008, p.6), os autovalores  $\lambda_p$  podem ser determinados de acordo com a equação característica da matriz de covariância, sendo que  $I$  é a matriz identidade, de maneira que para cada autovalor encontrado existe um autovetor associado.


$$|C_X - \lambda I| = 0 \quad (5)$$

Segundo Duarte (1998, p.2), a variância total é igual ao traço da matriz  $C_X$ , o qual é utilizado de referência para determinação da representatividade de cada componente principal. Diante disso, para Hongyu, Sandanielo e Oliveira Junior (2016, p. 86) o percentual de explicação é dado por:

$$c_p = 100 \frac{\lambda_p}{tr(C_X)} \quad (6)$$

Para consolidar, Esbensen e Geladi (1987, p. 37) esclarecem que no tocante a análise de componentes principais, a matriz original  $X$  equivale ao produto entre a matriz de *scores* “T” e a transposta de *loadings* “P”, somado depois à matriz de ruído “E” (dados não captados pelo modelo PCA), conforme o esquema da Figura 6, sendo assim, os dados obtidos são a decomposição de matrizes.

**Figura 6** - Equivalência entre a matriz inicial X e seu modelo PCA respectivo.



**Fonte:** Adaptado de Esbensen e Geladi (1987).

$X$  é a representação da matriz de dados inicial,  $t_1$  e  $t_2$  representam cada coluna da matriz de *scores*, enquanto  $p_1'$  e  $p_2'$  retratam cada coluna da matriz de *loadings*, já a matriz  $E$  reproduz aquelas variáveis restantes que não foram consideradas nas componentes principais.

#### 2.4.1.3. Clustering

*Clustering*, agrupamento em português, é um conjunto de técnicas aplicadas para categorizar e formar conjuntos de dados semelhantes, denominados *clusters*. Esse agrupamento de dados é feito automaticamente por algoritmos de AM dividindo os elementos pertencentes a um mesmo conjunto que apresentam maior semelhança entre

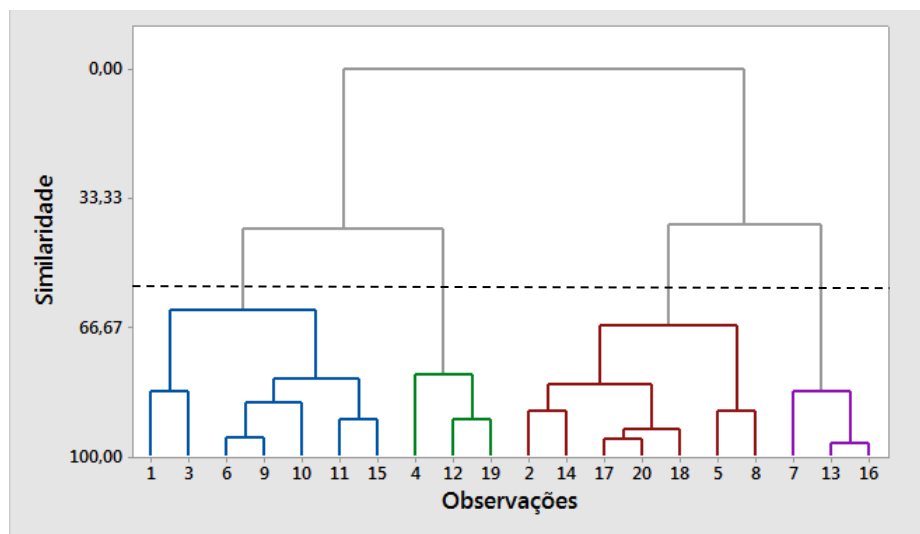
si dos elementos pertencentes a qualquer outro conjunto com relação a certo critério de similaridade (LACHI; ROCHA, 2005, p.4).

Essa técnica é utilizada em diversas áreas de trabalho como, por exemplo, recuperação de informação, aprendizagem por observação, classificação de padrões e segmentação de imagens. Diversos estudos sugerem que agrupamentos mais representativos são obtidos quando um conjunto reduzido de variáveis é utilizado, visto que a inserção de variáveis ruidosas pode degradar significativamente a qualidade do procedimento (CERVO; ANZANELLO, 2015, p. 826).

Algumas observações devem ser feitas ao aplicar a técnica de *Clustering*, tais como definir a forma de representação dos dados de entrada que serão agrupados e a medida adequada de aproximação entre os dados. Deve-se escolher a técnica de *clustering* a ser aplicada para a construção dos *clusters* e a abstração dos dados que consiste em uma representação simples e compacta do conjunto de dados tanto do ponto de vista humano quanto da máquina. E por último, a avaliação do resultado do *clustering* para verificar a qualidade do agrupamento dos dados conseguido pela técnica (YOSHIMITANAKA *et al.*, 2015, p.36).

Os algoritmos de *clustering* são classificados em quatro classes principais: particionais; hierárquicos; baseados em modelo e baseados em redes. Os algoritmos particionais, ou não hierárquicos, separam os registros do conjunto de dados em “k” grupos por meio de similaridade ou dissimilaridade. Os hierárquicos baseiam-se na construção de uma hierarquia entre os indivíduos e subgrupos, sendo graficamente representada através de uma estrutura chamada dendrograma, semelhante a uma árvore. Cujas linhas verticais representam os *singletons/clusters*, e as linhas horizontais ligam os mesmos e indicam o grau de similaridade ou dissimilaridade entre eles. Para destacar um número limitado de *clusters*, é comum determinar um valor crítico de similaridade, a partir do qual é traçada uma linha horizontal que intercepta todas as linhas verticais do dendrograma. O número de linhas verticais “cortadas” determina a quantidade de *clusters* gerada. Na Figura 7 observa-se uma linha pontilhada transversal que parte de um valor crucial aleatório de similaridade, de maneira que quatro linhas perpendiculares foram bloqueadas, formando assim quatro grupos. E por último os baseados em redes neurais, que encontram grupos aplicando os conceitos de redes neurais no conjunto de dados (ROKACH; MAIMON, 2005, p.336; YOKOMIZO *et al.*, 2021, p.3).


**Figura 7** - Dendrograma, ligação completa com distância euclidiana, criado usando-se uma partição final de 4 agrupamentos, que ocorre em um nível de similaridade de aproximadamente 40.



**Fonte:** MINITAB, 2019 (Adaptado).

Uma das técnicas mais comumente utilizadas em *clustering* é a *k-means*, classificado como não hierárquico. *k-means* é um algoritmo iterativo que particiona o conjunto de dados em “k” subgrupos distintos e não sobrepostos predefinidos (*clusters*), onde cada ponto de dados pertence apenas a um grupo. Ele tenta tornar os pontos de dados *intracluster* tão semelhantes quanto possível, enquanto também mantém os *clusters* os mais diferentes (o mais longe) possíveis. Essa técnica atribui os pontos de dados a um *cluster* de forma que a soma da distância quadrada entre os pontos de dados e o centroide do *cluster* (média aritmética de todos os pontos de dados que pertencem a esse *cluster*) seja mínima. Quanto menor a variação dentro dos *clusters*, mais homogêneos serão os pontos de dados dentro do mesmo *cluster* (CERVO; ANZANELLO, 2015, p.827).


**Figura 8.** K-means algoritmo iterativo que particiona o conjunto de dados em “k” subgrupos distintos e não sobrepostos predefinidos.



**Fonte:** SANTANA, 2020.

Para desenvolver o agrupamento de dados é necessário escolher o método adequado ao objetivo da análise, pois existem diversos métodos que utilizam diferentes formas para combinar grupos ou amostras baseados na similaridade entre eles. O método *single linkage*, por exemplo, liga os pontos/grupos mais próximos; ao passo que *complete linkage* associa aqueles que se apresentam mais distantes mutuamente (MARQUES; NETO, 2009, p.1).

**Figura 9.** Método de *Ward Linkage* avalia o grau de relação entre os *clusters* através da distância geométrica espacial entre eles.



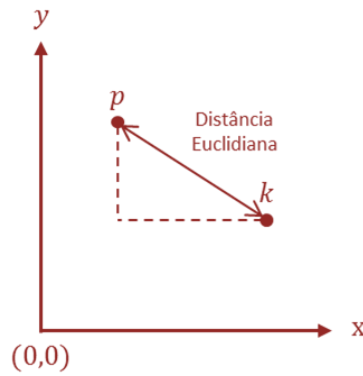
Fonte: ANINDITA, 2021.

O método de *Ward Linkage* foi desenvolvido por Ward em 1963, e consiste em realizar todas as possibilidades de aglomeração de um conjunto de dados, e por fim define como melhor resultado aquele que apresenta menor erro relativo. Isso porque tal metodologia leva em consideração o quadrado da soma de erros, isto é, a variância acumulada por grupo. Portanto, o método *Ward Linkage* promove distintos padrões de agrupamento dos dados, cada qual apresentando seu próprio índice de erro. Ao final, o objetivo do método é criar um modelo cujo quadrado da soma de erros seja o menor possível. Dessa forma, dados dois *clusters* K e L,

$$G = \frac{n_K n_L}{n_K + n_L} \|\bar{m}_K - \bar{m}_L\|^2 \quad (7)$$

Sendo que  $\bar{m}$  descreve o vetor de média de um *cluster* multidimensional, e  $n$  representa o número de elementos do mesmo (RANDRIAMIHAMISON; VIALANEIX; NEUVIAL, 2021; CARVALHO *et al.*, 2009, p.8).

**Figura 10.** Distância euclidiana.



**Fonte:** AUTORA, 2021.

Sobretudo, vale ressaltar que o método *Ward Linkage* avalia o grau de relação entre os *clusters* através da distância geométrica espacial entre eles. E dentre as diversas métricas existentes, como *Mahalanobis*, *City-Block (Manhattan)*, *Minkowski*, a Distância Euclidiana é a mais apropriada para a metodologia de *Ward*. (MARQUES; NETO, 2009, p.2; VIJAYA; SHARMA; BATRA, 2019, p.571). Portanto, de acordo com Torelli (2005, p.6), considerando um espaço euclidiano n-dimensional, em que há dois pontos  $P = (p_1, p_2, \dots, p_n)$  e  $Q = (q_1, q_2, \dots, q_n)$ , a distância euclidiana entre ambos é descrita como:

$$d = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (8)$$

#### 2.4.2. Carta $T^2$ Hotelling

A detecção de dados discrepantes de uma distribuição multivariada também tem sido amplamente verificada através da análise estatística  $T^2$  de *Hotelling*, que consiste no valor da distância de *Mahalanobis* de determinada amostra ou subgrupo do centro da distribuição dos dados, ou seja, aponta alterações em relação a média de várias variáveis simultaneamente. A eq. (9) descreve a distância de *Mahalanobis* (HARDIN; ROCKE, 2002, p.626; HADI, 1992, p.762):

$$MSD = (x_i - \mu_0)' C_x^{-1} (x_i - \mu_0) \quad (9)$$


Simplificadamente, no âmbito da Análise de Componentes Principais, o valor de  $T^2$  pode ser determinado pela soma do quadrado dos *scores* “T” normalizados, onde  $\lambda$  representa a matriz diagonal com os autovalores associados aos autovetores relativos às componentes principais retidas no modelo:

$$T^2 = T\lambda^{-1}T' \quad (10)$$

Enfim, para constatação de certa amostra como um *outlier* através da Carta  $T^2$ , geralmente aponta-se os pontos que apresentam maiores distâncias para o centro da distribuição, isto é, maiores desvios. Além disso, pode-se optar pela determinação de um valor crítico de referência, de modo que a comparação de cada amostra com o valor crítico permite observar se a mesma ultrapassa o limite tolerável, destacando-se como registro anormal. Assim, o limite de  $T^2$  de *Hotelling* pode ser calculado com base na distribuição  $F$ , conforme a eq. 11 a seguir. Sendo que  $m$  é o número de amostras e  $h$  é o número de componentes principais. Enquanto  $\alpha$  na distribuição  $F$  assume valores  $\alpha < 1$  e significa que quanto mais próximo de “1” o valor de  $\alpha$ , menores as chances de observar um valor acima do valor crítico (limite). Por exemplo, para um limite calculado com 95% de confiança, os valores da distribuição que ultrapassariam este limiar seriam de apenas 5% das vezes ao acaso. Dessa maneira, quanto mais distante está  $\alpha$  de “1”, o valor do limite diminui, aproximando-se da média dos dados, destacando maior número de *outliers* (OLIVEIRA; SANTOS; MUNITA, 2005, p.1):

$$T_{lim}^2 = \frac{(m-1)h}{m-h} F(\alpha, h, m-h) \quad (11)$$

**Figura 11.** Carta  $T^2$  Hotelling.



**Fonte:** RIUT, 2021.

### 3. METODOLOGIA

#### 3.1. SOFTWARES E SISTEMAS UTILIZADOS

Com a evolução tecnológica, a coleta de dados e observações foi melhorada através de *softwares*, onde é possível recolher e armazenar dados qualitativos e quantitativos, além de organizar, transcrever, ordenar e categorizar as informações, visando uma análise mais profunda e rápida.

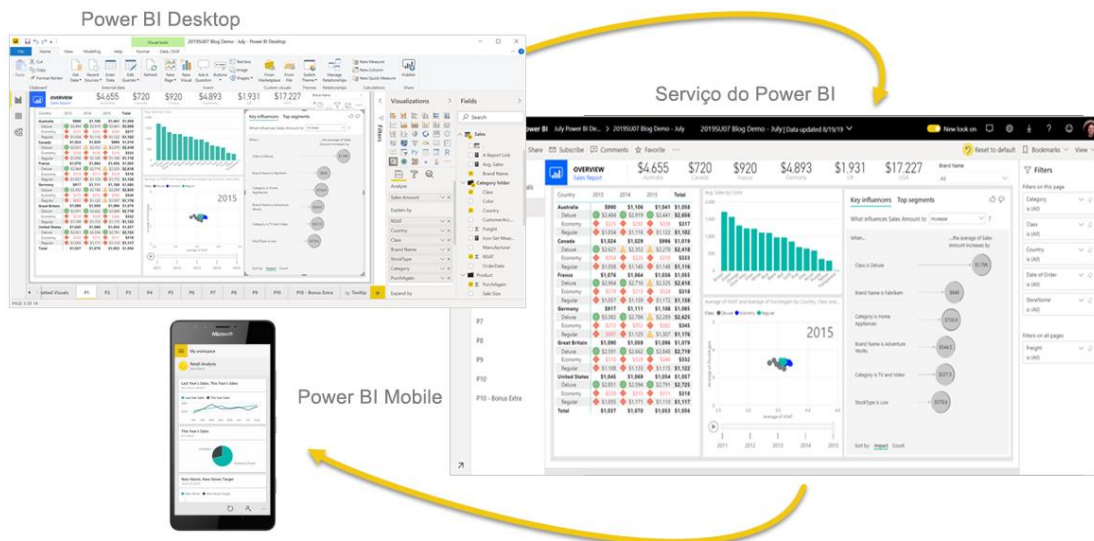
##### 3.1.1. *Microsoft Power BI*

O *Microsoft Power BI* é uma ferramenta de *Business Intelligence* da *Microsoft* para apresentação de informações por meio da criação de painéis e *dashboards*. Através dessa ferramenta é possível a obtenção de dados a partir de diversas fontes de informação, como planilhas, e até de pacotes de dados maiores, armazenados online em nuvens ou no dispositivo local, criando um ambiente integrado para obtenção de relatórios de forma rápida e com inúmeros indicadores personalizados para destacar as informações mais relevantes, podendo ser compartilhados com outros usuários (*MICROSOFT*, 2018).

Sua aplicação tem sido útil em diversos empreendimentos por auxiliar o tratamento de dados, suportando análises e tomadas de decisão. Além disso, sua versatilidade permite o desenvolvimento e manutenção de sistemas de monitoramento de performance, através de indicadores de desempenho (*BECKER; GOULD*, 2019, p.4).

Pode-se dizer que a ferramenta consiste em três grandes partes: uma aplicação para área de trabalho chamada *Power BI Desktop*, que é onde o desenvolvimento e design dos relatórios acontecem e definem-se as interações e bases de dados; a segunda parte é o *Power BI Service*, plataforma online em que é possível ver seus relatórios e os relatórios compartilhados com você, publicar os seus relatórios e até mesmo executar algumas edições; e a terceira parte são os aplicativos móveis, onde se pode consumir todo o conteúdo produzido, que estão disponíveis em dispositivos e *tablets Windows*, e também para dispositivos *iOS* e *Android*. (*RAMALHO*, 2019).

**Figura 12 - Power BI** apresentado em seus três elementos.



**FONTE: MICROSOFT, 2019.**

### 3.1.2. PIMS

PIMS (*Plant Information Management Systems*) são sistemas de aquisição de dados que recuperam informação do processo residente em fontes distintas. Essas informações são armazenadas em um único banco de dados, sendo disponibilizadas através de vários meios, podendo visualizá-las em tempo real ou o histórico da planta. A partir do PIMS, é possível criar relatórios dinâmicos, gráficos, tabelas, integrando os dados para uma visão mais consolidada de todo o processo (CARVALHO *et al.*, 2003, p.1).

Os dados do processo podem ser obtidos de um sistema supervisorio, *SCADA* (*Supervisory Control and Data Acquisition*), ou diretamente de CLPs (Controlador Lógico Programável) e SDCDs (Sistema Digital de Controle Distribuído). O controlador CLP define variáveis a serem usadas nos processos. Ele apresenta maior confiabilidade se comparado ao SCADA, bem como menor atraso na coleta de dados. O sistema SCADA realiza o controle dos dados dos equipamentos na indústria em tempo real, além de extrair as informações em formato de variáveis e utilizá-las diretamente como fonte de dados. Ademais, algumas variáveis derivadas da manipulação dos sistemas supervisorios só existem no SCADA (SEIXAS, 2014, p.7).

Os dados de tempo real apresentados no PIMS mostram o valor instantâneo da variável sendo, portanto, mais utilizados para monitoramento do processo. A pesquisa desses dados pode ser feita através de uma linguagem de consulta a banco de dados como, por exemplo, *SQL Server*, *Access* e *MySQL* (SOUSA, 2014, p.19). A implantação de um sistema PIMS apresenta diversos benefícios, tais como: centralização de dados de processo; democratização da informação; visualização do processo produtivo em tempo real; maior interatividade com os dados do processo; histórico de dados; e receita de processo. Todos estes benefícios combinados entre si permitem que, tanto o engenheiro de processo quanto o operador da planta, encontrem respostas para o comportamento positivo ou negativo do processo e alcancem o pleno conhecimento de sua planta, podendo assim atuar de forma a buscar os melhores resultados (CARVALHO *et al.*, 2003, p.5).

### 3.1.3. MATLAB

O MATLAB é um *software* proprietário com linguagem orientada a matrizes (*Matlab* = *MATrix LABORatory*) desenvolvido pela *MathWorks*. O MATLAB possui uma variedade de aplicações na indústria e na academia, incluindo AM, processamento de sinais e comunicações.

O MATLAB conta com a ferramenta *Predictive Maintenance Toolbox*, que permite analisar e rotular os dados importados de arquivos. Os métodos de processamento de sinal e modelagem dinâmica que se baseiam em técnicas como análise espectral e análise de série temporal permitem o pré-processamento dos dados e extrair recursos que podem ser usados para monitorar a condição da máquina. Usar modelos de sobrevivência baseados em tendências para prever a análise da Vida Útil Remanescente (VUR) ajuda a estimar o tempo até a falha de uma máquina (VEDALDI; LENC, 2015 p.1).

## 3.2. ÁREA DE ESTUDO

O presente estudo foi realizado em uma Usina de Tratamento de Minérios de uma grande empresa de mineração localizada no município de Parauapebas – Pará, pertencente à mesorregião do Sudeste Paraense. O município conta com uma população estimada de 208.273 habitantes (IBGE, 2019). Tal cidade localiza-se em uma província mineral e, em vista disso, sua principal fonte econômica advém da exploração de

minérios. A geração de riquezas que decorrem dessa atividade transformou o cenário econômico de Parauapebas, gerando grande número de empregos através de diversas empresas prestadoras de serviços (LEITE, 2011, p.7). A escolha dessa usina se deu devido a ser uma das instalações atuais com mais tecnologia, além de conter todos os processos pelo qual o minério é processado.


### 3.3. CARACTERÍSTICAS DA PENEIRA ESTUDADA

A peneira vibratória é projetada para a classificação de material a granel (minérios e agregados), podendo ser finos, médios ou grossos, e o peneiramento pode ser feito com via úmida ou seca. De acordo com o fabricante, HAVER & BOECKER (2010), a peneira abordada no estudo possui as seguintes características:

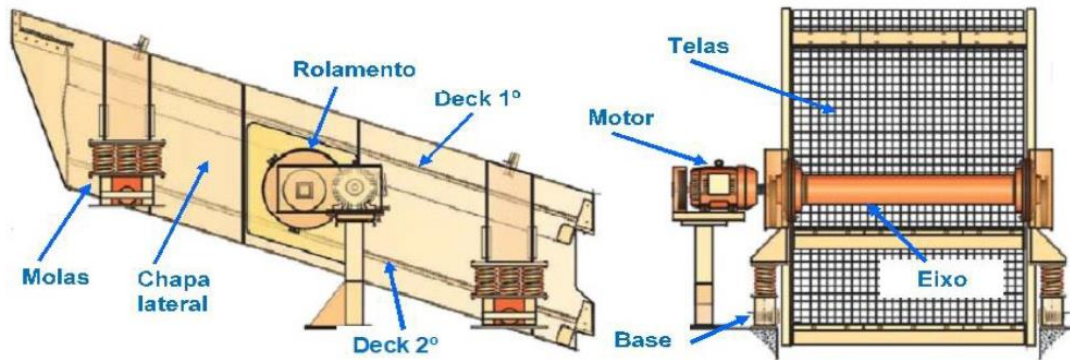
- Acionamento livre circular ou circular excêntrico ou linear;
- Amplitude variável ou constante do seu movimento;
- Frequência ajustável;
- Tamanho customizável;
- Totalmente blindada, para a captação de pó em projetos para materiais pulverulentos (opcional).

A peneira vibratória é dividida nas seguintes partes: base inferior, caixa com armação do primeiro módulo, caixa com armação do segundo módulo, bases de acionamento, motores elétricos com acoplamento e cruzeta de borracha, eixos de comprimento variável, amortecedores e molas de borracha e proteções.

**Figura 13** - Composição das partes da peneira vibratória do tipo TD.



**Figura 14** - Descrição das partes da peneira do tipo TD.



FONTE: HAVER; BOECKER, 2010.

A motorização do equipamento é feita de forma direta conectando (acoplando-se) o motor ao eixo excêntrico através de um eixo de comprimento variável e acoplamentos de borracha. O acionamento das peneiras do tipo TD é sempre feito por um eixo excêntrico suportado por dois mancais internos e dois externos e balanceado com contrapesos. Já a suspensão é sempre feita por molas de borracha. Sendo dezesseis grandes entre as caixas e as armações e vinte e quatro pequenas entre as armações e a base inferior.

Para as superfícies de peneiramento o equipamento apresenta dois tipos diferentes de telas: a *Ty-Snap* para o primeiro *deck* dos dois módulos e a *Ty-Wire* para o segundo *deck* dos dois módulos. Ambas, porém, são aplicáveis para o peneiramento de minérios. Sendo assim, elas estão preparadas para resistir à umidade natural característica do minério e para trabalhar em todas as épocas do ano, seja ela chuvosa ou de estiagem. As telas *Ty-Snap* são feitas em poliuretano e sua forma de fixação é do tipo *snap deck*. Já as telas *Ty-Wire* são feitas de um material especial, composto de poliuretano suportado por um tecido em arame customizado. E sua forma de fixação também é do tipo *snap deck*.

As peneiras do tipo TD são equipadas com um sistema de lubrificação contínua, a fim de manter os mancais externos e internos sempre lubrificados. Nesse sistema de lubrificação existe um sensor de nível mínimo que indica quando o reservatório deve ser completado com graxa.

Durante as inspeções devem ser observadas as partes vibrantes da peneira, pois elas não devem tocar em partes fixas dos periféricos. Recomenda-se um distanciamento

mínimo de 80 a 100 mm entre estas partes, de acordo com o fabricante. Fenômenos de ressonância podem ser observados como vibrações diferentes no equipamento, dependendo de sua rotação. Quando a frequência de rotação da peneira coincide com a frequência natural da estrutura há o aumento excessivo da vibração que pode não ser contido pelos amortecedores. O inversor de frequência é imprescindível para o funcionamento da peneira, devendo ser ajustado para operar somente entre 37,5 e 42,0 Hz (que resulta em rotações na peneira de 750 e 850 rpm) e deve ser inspecionado.

O comando que dá início ao processo de peneiramento é feito por uma chave geral via painel de controle que libera o fornecimento de energia para os motores elétricos. A partir disso, a peneira iniciará seu movimento, demorando certo tempo para estabilizar sua rotação funcional. Quando a rotação estiver estabilizada, o operador deverá ligar, ou verificar se estão funcionando os equipamentos que sucedem a peneira. Somente após isso poderá liberar a alimentação do material a ser peneirado.

Para o desligamento da peneira, o operador deve, primeiramente, interromper o fluxo de material a ser peneirado. Após isso, deve-se esperar certo tempo para escoamento final de material, paralisar os equipamentos posteriores à peneira e, somente após isso, desligar a peneira.

Sobre sua frequência operacional, a máxima rotação para os motores das peneiras TD é 850 rpm. A *Haver Screening Group* estabeleceu que a frequência de operação mínima fosse de 750 rpm. Já a frequência de operação nominal da peneira TD é 800 rpm. Operar na condição nominal garante boas condições dinâmicas da peneira e vida útil dos componentes. A tabela abaixo apresenta dados teóricos que relacionam a aceleração e a velocidade de rotação.

**Tabela 2** - Relação entre aceleração e velocidade de rotação.

Frequência da peneira [RPM]	Frequência elétrica do variador [Hz]	Aceleração teórica [g]	
		Módulo A	Módulo B
750	37,5	3,80	3,85
760	38,0	3,90	3,95
770	38,5	4,00	4,05
780	39,0	4,10	4,15
790	39,5	4,20	4,25
800	40,0	4,30	4,35

810	40,5	4,40	4,45
820	41,0	4,50	4,55
830	41,5	4,60	4,65
840	42,0	4,70	4,75
850	42,5	4,80	4,85

FONTE: HAVER; BOECKER, 2010.

A aceleração da peneira irá aumentar levemente ao longo do tempo devido ao desgaste de seus componentes (superfície de peneiramento chapa de desgaste, borrachas etc.). Ao contrário disso, a massa vibrante irá reduzir levemente.

### 3.4. PESQUISA DE AVARIA

Avaria é a impossibilidade de um bem realizar uma função predeterminada, podendo ser equipamentos ou sistemas. Na indústria, a análise das avarias tem um importante papel para reduzir e até eliminar problemas e suas consequências, pois permite conhecer melhor o comportamento dos equipamentos e agir de modo preventivo (CARDOSO, 2018, p.4). Para a manutenção da peneira, a pesquisa de avaria por tipos é realizada em diferentes partes do equipamento, além disso, são explanadas as prováveis causas e a sua correção.

**Tabela 3** - Pesquisa de avarias por tipos.


TIPOS DE AVARIAS	CAUSA PROVÁVEL	CORREÇÃO
<b>Motor não parte</b>	Ligação elétrica incorreta	Verificar os sistemas de proteção
	Travamento mecânico	Verificar se o eixo de transmissão está livre
<b>Lateral da peneira oscilando</b>	Caixa de peneira bate em partes fixas (chutes e funis)	Modificar e afastar as partes fixas causadoras
<b>Ruído nos mancais de rolamento</b>	Falta de graxa	Lubrificar o mancal
	Rolamento defeituoso	Substituir o rolamento
<b>Ruído excessivo na máquina</b>	Elementos de união soltos	Conferir todas as junções com parafusos e apertar novamente
<b>Ruído no motor</b>	Falta de óleo	Corrigir o nível de óleo
	Rolamento defeituoso	Substituir o rolamento
<b>Desgaste unilateral ou pontual das telas na parte de alimentação da peneira</b>	Alimentação da peneira não está sendo efetuada corretamente	Modificar a alimentação da peneira
		Alterar os chutes
		Distribuir melhor o material

FONTE: HAVER; BOECKER, 2010.

### 3.5. LEVANTAMENTO DE DADOS


O levantamento de informações sobre as falhas dos setores Elétrica, Instrumentação e Automação referentes a todas as dez peneiras existentes ocorreu na Usina de Beneficiamento de Minério durante o período de janeiro a dezembro de 2019. As informações obtidas foram alcançadas em duas plataformas distintas ofertadas pela empresa, o *Power BI* (Versão 2.76.5678.782 – Ano 2019) e o PIMS (Versão 11 – Ano 2019). As dez peneiras da usina apresentaram cerca de 499 apropriações de falhas e geraram juntas 315,1 horas paradas para manutenção corretiva. A figura 15 mostra a quantidade de eventos de falha de cada uma das dez peneiras. As peneiras denominadas PN-03 e PN-08 apresentam um número relativamente alto de falhas, totalizando 109 e 84 respectivamente. Em relação à quantidade de horas paradas (figura 16), a peneira PN-08 ficou à frente com 63,7 horas paradas e, em seguida, a peneira PN-10 com 56,4 horas paradas.

**Figura 15** - Quantidade de eventos de falhas apresentadas nas dez peneiras em 2019, no qual destaca-se a peneira PN-03 com o maior número de falhas.



Fonte: AUTORA, 2020.

**Figura 16 - Quantidade de horas paradas para manutenção das peneiras.**




**Fonte:** AUTORA, 2020.

As peneiras PN-03 e PN-08 apresentaram valores à frente das demais peneiras. Na indústria e na visão da manutenção um equipamento que consta repetidas falhas é mais preocupante para o processo do que aquele que teve um maior tempo gasto para solucionar um defeito. Dessa maneira, a peneira PN-03 foi escolhida como objeto de estudo deste trabalho.

De acordo com os dados da empresa, as dez peneiras tiveram sua operação iniciada no ano de 2014 e durante seu tempo de uso, em algum momento, apresentaram alto índice de falhas. Apesar das peneiras PN-03 e PN-08 terem registrado números elevados de falhas, esse comportamento não é típico uma vez que cada ano diferentes peneiras também apresentaram valores discrepantes. Não se sabe o motivo específico de tal comportamento, já que essa variação depende de vários fatores.


A partir das plantas na plataforma *Power BI*, das 109 falhas da peneira PN-03, o setor de elétrica apresentou mais da metade do percentual de falhas (60% das 109 falhas), o setor de automação representou 25%. Já o setor de instrumentação foi o que menos impactou dentre esses setores, com apenas 15%, e isso se deve ao fato de os números de componentes elétricos na peneira serem maiores em relação aos demais (figura 17).

**Figura 17 - Número de eventos por setor ao longo do ano de 2019.**



**Fonte:** AUTORA, 2020.

**Figura 18 - Falhas em componentes por setor.**



**Fonte:** AUTORA, 2020.

A figura 18 mostra os componentes dentro do setor em que se encaixam e as falhas que estes apresentaram no período definido. O componente “PLC e Remota” do setor de automação apresentou o maior número de falhas (27) sendo todas classificadas pelo sistema como “Erro de Parâmetros/Configurações”. Tal resultado ocorreu devido a falha na placa de comunicação do inversor, causando alterações e perdas de parâmetros indevidamente.

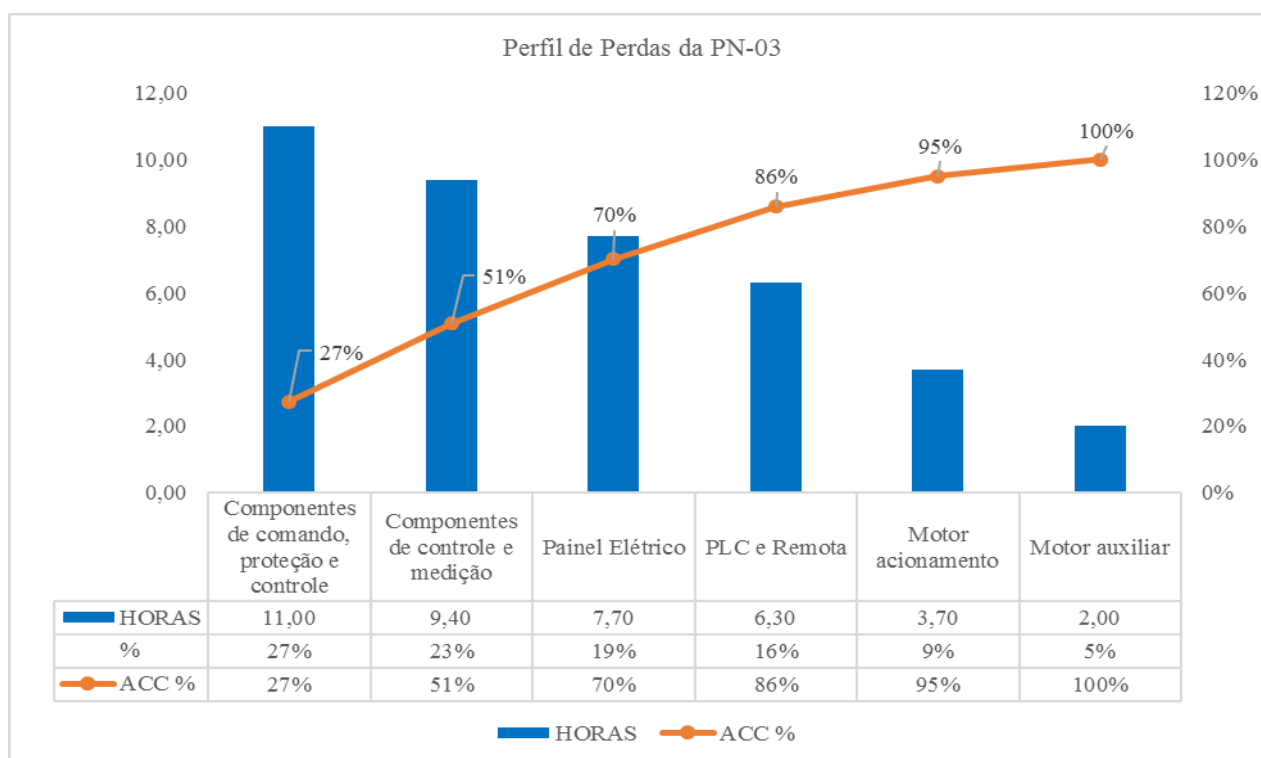
O componente “Painel Elétrico (CCM, gaveta, força, comando, etc)” (22) foi o segundo a apresentar maior quantidade de falhas, no qual a mais recorrente foi “Proteção Atuada” (20) causada pelo desarme do disjuntor de comando devido a vibração da peneira que com o tempo danifica o cabo de controle.

No “Motor auxiliar” o maior número de eventos foi “Sobrecorrente” (18). Durante as manutenções, verificou-se que o travamento nos mancais e bolsas da peneira estavam com falta de graxa provocando a sobrecorrente, além disso, durante este período houve também sobrecarga de material na peneira agravando o número de paradas por falhas.

O componente “Painel Elétrico (CCM, gaveta, força, comando, etc.)” apresentou “Bloqueio / Desbloqueio” como falha, porém essa é apenas uma solicitação por parte dos operadores para realizar atuações no equipamento devido a algum evento atípico. Assim, o evento “Bloqueio / Desbloqueio” não se caracteriza como falha.

Para a elaboração do Perfil de Perdas da Peneira, que consiste na estratificação das perdas do processo produtivo por meio de gráficos de Pareto, também foram levados em consideração os dados de falhas obtidos nos relatórios do *Power BI*. O gráfico de Pareto em questão foi desenvolvido no programa *Microsoft Excel* a fim de identificar quais são as maiores oportunidades de ganho na PN-03. A figura 19 abaixo apresenta o gráfico elaborado.

**Figura 19** - Perfil de Perdas da Peneira PN-03 em seus componentes.



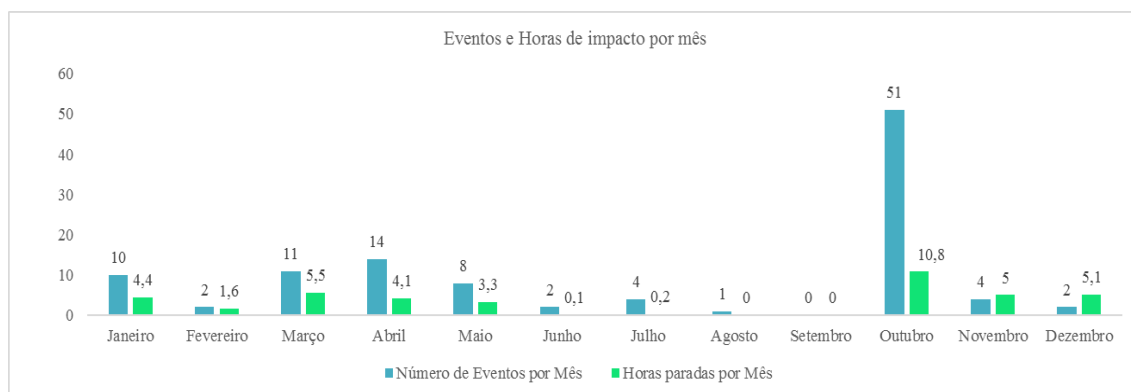
**Fonte:** AUTORA, 2020.

A figura 19 mostra a distribuição da quantidade de horas em relação a cada componente que foi responsável pela inativação do equipamento devido às falhas apresentadas durante o ano de 2019 em ordem decrescente, com uma linha cumulativa no eixo secundário com uma porcentagem do total.

Portanto pode-se concluir que, do ponto de vista financeiro, é necessário priorizar os “Componentes de comando, proteção e controle” em manutenções preventivas que devem ocorrer no ativo, já que estes têm apresentado um maior tempo gasto ao reparar falhas, fazendo com que o equipamento fique sem operar e, conseqüentemente, cause perdas na produção.

A partir das análises quantitativas das 109 falhas ocorridas durante o ano de 2019, 51 aconteceram somente no mês de outubro, apresentando uma diferença de 37 falhas quando comparado ao mês de abril, segundo mês que mais apresentou falhas (14 falhas), (figura 20).

**Figura 20** - Número de eventos de falhas e de horas paradas para manutenção corretiva por mês na peneira PN-03 em 2019.



Fonte: AUTORA, 2020.

Devido ao grande número de falhas em outubro, as grandezas físicas dos motores de acionamento e do motor da bomba de lubrificação da peneira escolhida, tais como corrente elétrica, velocidade de rotação, amplitude do movimento vibratório, torque e aceleração referentes a este mês foram levantadas no PIMS e utilizados na realização do código, os quais foram analisados pela máquina e definidos como “dados com defeito” e “dados sem defeito”.

Após essa descoberta percebeu-se a necessidade de ir a campo para investigar o que fez com que esse mês, de forma discrepante, apresentasse tantos eventos de falhas. Desse modo, com as informações coletadas foi descoberto que, anteriormente, quando o

sistema de comunicação pontuava falta de lubrificação dos rolamentos da peneira, esta ainda operava por cerca de 40 minutos antes de parar e apontar a falha, o que conseqüentemente causava quebras nesses rolamentos de forma frequente. Por esse motivo, decidiu-se realizar nos sistemas de rede *Profibus* o intertravamento da bomba de lubrificação com os motores de acionamento da Peneira.

Assim, a partir do início do mês de outubro, foi decidido que quando o tanque de graxa está vazio e o motor da bomba não trabalha, não conseguindo realizar a lubrificação dos rolamentos, a Peneira também para de operar. A decisão tomada solucionou alguns problemas mecânicos, mas desencadeou durante o restante do mês de outubro problemas nos setores de Elétrica e Automação, porque como o sistema de lubrificação não estava adequado para manter estes rolamentos lubrificados 100% do tempo, o motor da bomba e a peneira acabavam parando, o que justifica a elevada quantidade de falhas no mês de outubro.

Como ação para solucionar esse problema, no início do mês de novembro foi decidido e colocado nos sistemas de comando que o conjunto de lubrificação da Peneira mandasse graxa no intervalo de 2 em 2 horas para os rolamentos, o que justifica o número de falhas ter diminuído a partir desse mês.

No PIMS, sistema supervisor, foram coletados os valores de grandezas intrínsecas dos motores de acionamento e do motor da bomba de lubrificação da peneira escolhida, tais como corrente elétrica, velocidade de rotação, amplitude do movimento vibratório, torque e aceleração.

### 3.5.1. Exportação de dados

Os dados do PIMS foram exportados para o programa *Microsoft Office Excel* (Versão 1708 – Ano 2016) de forma quantitativa e objetiva, visando clarificar o que é útil ou não no estudo para aplicabilidade do algoritmo de PCA e *Clustering*, tornando-se a fonte de informações do banco de dados do código. Com a coleta das informações advindas do *Power BI* foram gerados gráficos referentes à quantidade de eventos de falhas, horas paradas para manutenção de cada peneira na usina, número de eventos por setor ao longo do ano de 2019, tipos de falhas por setor, número de eventos de falhas e de horas paradas para manutenção corretiva por mês na peneira selecionada, perfil de perdas da peneira através do gráfico de Pareto para descobrir qual componente deveria ser priorizado durante as manutenções, como visto na seção anterior.

### 3.5.2. Elaboração do FMEA

De acordo com os dados de falhas obtidos no relatório “Engenharia Manutenção Usina” foi feito o preenchimento da planilha em Equipamento, Função, Componente e Modos de Falhas, pois os sistemas da empresa só conseguem estratificar até o 4º nível de falhas.

Como o processo ocorre na Usina de Beneficiamento de minério, este é o primeiro nível de estratificação para se detectar as falhas. O ativo por sua vez, pertence ao segundo nível, o terceiro nível contempla os componentes da peneira e por fim, as falhas fazem parte do quarto nível de estratificação. A figura 21 retrata os níveis e suas interrelações.

**Figura 21** - 1º a 4º Nível de estratificação para se identificar falhas.



**Fonte:** AUTORA, 2020.


Para preencher os campos de Efeitos de Falha, Causas da Falha, a Avaliação de Risco (Ocorrência, Severidade, Detecção e o valor de RPN) foi preciso realizar visitas em campo para consultar executantes de manutenções preventivas e corretivas que conhecem e lidam com as falhas de perto a fim de auxiliarem na construção da ferramenta. A planilha preenchida no anexo 1 apresenta as informações colhidas nos sistemas de dados e em campo.

Para a análise das falhas apropriadas aos setores Elétrica, Instrumentação e Automação da peneira selecionada, usou-se como base uma planilha específica para a

elaboração do FMEA. Nessa planilha foi realizada a transformação de informações qualitativas em dados quantitativos que apontaram quais as falhas mais críticas, gerando um ponto de atenção que teria como solução efetiva a elaboração de um Plano de Manutenção.

O RPN, que é o valor do risco calculado, está vinculado a cada tipo de falha e o seu cálculo se dá através do produto entre o valor definido de Ocorrência (Tabela 4), Severidade (Tabela 5) e Detecção (Tabela 6) de cada modo de falha. É ele quem define qual falha deve ser tratada com caráter de prioridade dentro de um Plano de Manutenção que deve ser levantado com base no FMEA elaborado neste trabalho.

**Tabela 4** - Planilha para auxiliar na definição do valor da Ocorrência. De acordo com as características dos dados coletados referentes às falhas é atribuído o índice de ocorrência que varia de 1 a 10. Para definir o índice de ocorrência é analisada a probabilidade de falha e, a partir das taxas de falhas possíveis, atribui-se o índice.

 <b>OCORRÊNCIA</b>		
<b>Probabilidade de Falha</b>	<b>Taxas de falha possíveis</b>	<b>Índice de Ocorrência</b>
<b>Remota:</b> Falha é improvável	Chance Remota de Falha	1
<b>Baixa:</b> Relativamente poucas falhas	Frequência muito baixa: 1 vez a cada 5 anos	2
	Pouco Frequente: 1 vez a cada 2 anos	3
<b>Moderada:</b> Falhas ocasionais	Frequência baixa: 1 vez por ano	4
	Frequência ocasional: 1 vez por semestre	5
	Frequência moderada: 1 vez por mês	6
<b>Alta:</b> Falhas frequentes	Frequente: 1 vez por semana	7
	Frequência elevada: algumas vezes por semana	8
<b>Muito Alta:</b> Falhas Persistentes	Frequência muito elevada: 1 vez ao dia	9
	Frequência máxima: várias vezes ao dia	10

**Fonte:** ENGETELES (2017)


**Tabela 5** - Planilha para definição do valor de severidade. O índice varia de 1 a 10, no qual o valor é atribuído a partir dos dados coletados referentes ao funcionamento do equipamento e, a partir das características do efeito da severidade, o índice é definido.

 <b>SEVERIDADE</b>	
---	--

Severidade	Efeito da Severidade	Índice de Severidade
Nenhum	Sem efeito identificado.	1
Muito menor	Itens de Ajuste, Acabamento/Chiado e Barulho não-conformes. Defeito evidenciado por clientes acurados (menos que 25%).	2
Menor	Itens de ajuste, Acabamento/Chiado e Barulho não-conformes. Defeito evidenciado por 50% dos clientes.	3
Muito baixo	Itens de Ajuste, Acabamento/Chiado e Barulho não-conformes. Defeito notado pela maioria dos clientes (mais que 75%).	4
Baixo	Equipamento operável, mas item(s) de Conforto/Conveniência operável(is) com níveis de desempenho reduzidos.	5
Moderado	Equipamento operável, mas item(s) de Conforto/Conveniência inoperável(is). Cliente insatisfeito.	6
Alto	Equipamento inoperável, mas com níveis de desempenho reduzido. Cliente muito insatisfeito.	7
Muito alto	Equipamento inoperável (perda das funções primárias).	8
Perigoso com aviso prévio	Índice de severidade muito alto quando o modo de falha potencial afeta a segurança na operação do equipamento com aviso prévio.	9
Perigoso sem aviso prévio	Índice de severidade muito alto quando o modo de falha potencial afeta a segurança na operação do equipamento sem aviso prévio.	10

Fonte: ENGETELES (2017)

**Tabela 6** - Planilha para auxiliar na definição do valor da Detecção. Os valores do índice variam de 1 a 10, no qual tais valores são atribuídos a partir da detecção das falhas, se estas são possíveis de detectar nas inspeções e conjunto com as faixas sugeridas dos métodos de detecção.

		Tipos de Inspeção			Faixas Sugeridas dos Métodos de Detecção	Índice de Detecção
		A	B	C		
Quase impossível	Certeza absoluta da não detecção.			x	Não pode detectar ou não é verificado.	10
Muito remota	Controles provavelmente não irão detectar.			x	Controle é alcançado somente com verificação aleatória ou indireta.	9
Remota	Controles têm pouca chance de detecção.			X	Controle é alcançado somente com inspeção visual.	8
Muito Baixa	Controles têm pouca chance de detecção.			x	Controle é alcançado somente com dupla inspeção visual.	7
Baixa	Controles podem detectar.		X	x	Controle é alcançado com métodos gráficos, tais como CEP (Controle Estatístico do Processo).	6

Moderada	Controles podem detectar.		X		Controle é baseado em medições por variáveis depois que as peças deixam a estação, ou em medições do tipo passa/não-passa feitas em 100% das peças depois que deixam a estação.	5
Moderadamente alta	Controles têm boas chances para detectar.	X	X		Detecção de erros em operações subsequentes, OU medições feitas na preparação de máquina e na verificação da primeira peça (somente para casos de preparação de máquina).	4
Alta	Controles têm boas chances para detectar.	X	X		Detecção de erros na estação, ou em operações subsequentes por múltiplos níveis de aceitação: fornecer, selecionar, instalar, verificar. Não pode aceitar peça discrepante.	3
Muito alta	Controles quase certamente detectarão.	X	X		Detecção de erros na estação (medição automática com dispositivo de parada automática). Não pode passar peça discrepante.	2
Quase certamente	Controles certamente detectarão.	X			Peças discrepantes não podem ser feitas porque o item foi feito a prova de erros pelo projeto do processo/produto.	1

**Tipos de Inspeção:**

A - Prova de Erro

B - Medição

C - Inspeção Manual/Visual

**Fonte:** ENGETELES (2017)

### 3.6. ELABORAÇÃO DO MODELO MATEMÁTICO UTILIZANDO *PCA* E *CLUSTERING*

Para a elaboração do modelo matemático visando o diagnóstico do equipamento quanto a análise dos dados e identificação dos que apresentaram defeito e os que não apresentaram, utilizou-se o software *MATLAB*, versão R2019a.

A base de dados foi construída considerando-se a captura das variáveis de minuto a minuto de um período de trinta e um dias (mês de outubro). Foram extraídos os dados da peneira através do PIMS referente às variáveis corrente elétrica - dos dois motores de acionamento, M1 e M2, e do motor da bomba de lubrificação, M3 -, torque dos motores de acionamento, velocidade de rotação e aceleração dos dois motores, e também a data e o horário de cada linha de dados, sendo assim, conseguiu-se uma matriz de 10 colunas por 44.640 linhas.

O equipamento possui 4 diferentes status de funcionamento, são eles: Status 0 – com defeito, Status 1 – sem defeito, Status 2 – permissão e Status 3 – funcionando normalmente. As 44640 linhas de dados abrangem os 4 status de funcionamento da peneira, porém, para se estudar os fenômenos e anomalias no comportamento das variáveis entendeu-se a necessidade de apenas abordar as informações da peneira no status 3, que é de quando ela se encontra em operação, dando assim, abertura para a identificação de possíveis sintomas de falhas. Esse grupo de dados nos status 3 totaliza cerca de 9882 linhas.

O algoritmo empregado foi desenvolvido através das técnicas de aprendizado não supervisionado de máquina, PCA e *Clustering*, uma auxiliando a outra. Para efetuar a análise de PCA foi preciso declarar como dados de entrada a matriz  $x$  com os dados coletados da peneira operando (status 3) de 9882 linhas (registros) e 10 colunas (variáveis). Contudo, não foi necessário incluir as colunas 8 e 9 correspondentes aos dados de aceleração dos motores 1 e 2, respectivamente, devido estes terem se apresentado constante durante a análise e a coluna 10, por representar as datas e horários em que aquelas variáveis se apresentaram. Em função disso, como entrada para a função PCA no MATLAB, foram utilizadas apenas as colunas de 1 a 7 da matriz  $x$ , relativas às correntes (I), torques (T) e velocidades de rotação ( $v$ ) dos motores 1 e 2, além da corrente da bomba de lubrificação, dessa maneira, gerando os *scores* que são os dados de entrada para o *Clustering*.

O método *Ward Linkage* foi escolhido para a categorização do conjunto de dados em *clusters*, especialmente, em função dos dados originais corresponderem à peneira em Status 3 (funcionando normalmente). Porquanto, a maioria dos registros apresentaram-se em torno da média, pois representam a extrema maioria dos dados. Logo o previsto é de que todos deveriam fazer parte do mesmo grupo, sobretudo apresentando este o menor ruído admissível. Nesse sentido, a metodologia de *Ward* criou um modelo de agrupamento cujo *cluster* principal (que contém a maioria dos

registros), possuiu a menor variância possível, comparada a de outros métodos testados. Diante disso, os demais pontos fora do *cluster* principal foram analisados visando investigar os motivos que os destacaram como anômalos.

Desse modo, foi possível obter os componentes principais e a separação em grupos de dados anômalos (defeito da peneira) e de pleno funcionamento do equipamento. Esse resultado fornecido pelo código foi analisado e assim, sua eficiência em identificar sintomas dos motores que indicam possíveis defeitos foi comprovada.

## **4. RESULTADOS E DISCUSSÕES**

### **4.1. ELABORAÇÃO DO FMEA**

A partir dos dados de falhas obtidos no relatório Engenharia Manutenção Usina foi feito o preenchimento da planilha em Equipamento, sua Função, Componente e Modos de Falhas. Já para preencher os campos de Efeitos de Falha, Causas da Falha, a Avaliação de Risco (Ocorrência, Severidade, Detecção e o valor de RPN) as informações foram coletadas através das visitas em campo.

De acordo com os dados da planilha preenchida (APÊNDICE 1), pode-se notar, como foi relatado pelos executantes, algumas falhas são erroneamente apropriadas, por exemplo, muitas vezes a falha “bloqueio/desbloqueio” é apontada no sistema como um evento que gera manutenção, mas na verdade é apenas uma espera por parte dos operadores para que os eletricitas bloqueiem ou desbloqueiem o funcionamento do equipamento, ou ainda quando algum componente deve receber manutenções de uma disciplina e a sua falha é apontada no sistema com outra disciplina responsável.

Outro problema que se mostrou recorrente foram alguns modos de falha que representam o mesmo tipo de falha dado em um instrumento, mas que se apresentam de diferentes formas nos sistemas gerando uma inconsistência que já vem desde a listagem dessas na árvore de falhas dos setores, como por exemplo os modos de falha: Falha Sensor de Velocidade, Falha Sensor e Ajuste Calibração Sensor, que representam o mesmo tipo de falha.

Concluiu-se também que muitas vezes agentes externos como falta de limpeza, excesso de material, travamentos mecânicos, oxidação, entre outros, levam o componente a apresentar falhas não sendo estas de origem elétrica.

Durante a elaboração da ferramenta foi pontuado pelos executantes duas falhas que, quando ocorrem, a rede aponta como erro E0068 que significa *Timeout* na Comunicação *Profibus*, são elas: Proteção Atuada em Painéis Elétricos; e Erro de Parâmetros/Configurações em PLC e Remota. Segundo os executantes, não se conhece o real motivo que gera essa falha no sistema.

Com base na média aritmética realizada com os valores do RPN e pela quantidade de modos de falhas, foi definido o valor referência como 144,91. Desse modo, valores acima deste receberam maior atenção e tempo em seus tratamentos.

Sendo assim, os modos de falha “Mau Contato Conexões” com valor de RPN igual a 175, “Proteção Atuada” com valor de RPN igual a 420 e “Erro de Parâmetros/Configurações” com também 420 são as falhas apontadas como as que devem ser tratadas com prioridade, principalmente porque essas duas últimas ainda precisam ter suas reais causas detectadas.

Também com o auxílio dos executantes de manutenções preventivas e corretivas foi possível definir Ações Preventivas Recomendadas a curto e longo prazo para cada uma das falhas apresentadas pela peneira no período escolhido, destacando-se ações não só para os componentes e instrumentos, mas também a revisão das árvores de falhas da empresa e a forma de apropriação nos seus sistemas supervisórios. Trocas de alguns componentes por modelos diferentes dos usados e mais atuais foram colocadas em pauta. Mas, o estudo de caso das falhas que eles ainda apresentam dificuldade em encontrar a causa raiz e a alteração da lógica do Relé Inteligente pela versão mais atual foi pontuado como as de caráter mais urgente a serem executadas.

## 4.2. MODELO MATEMÁTICO UTILIZANDO *PCA* E *CLUSTERING*

### 4.2.1. Variância explicada pelo modelo

Inicialmente aplicou-se a análise de componente principal à matriz de dados 9.882 linhas por 7 colunas, na tentativa de reduzir a dimensionalidade e fornecer uma visualização gráfica do problema.

Após a obtenção das componentes principais, julgou-se mais adequado reter no modelo as três primeiras componentes que, juntas, representam aproximadamente 99,5% da variância dos dados originais (Tabela 7). Dessa forma, a matriz obtida com o cálculo da PCA possui as mesmas 9.882 linhas da matriz inicial, porém com 3 colunas (uma coluna para cada

componente). Diante disso, apesar de terem sido adotadas apenas três componentes e suprimidas quatro delas, a perda de informação do modelo adotado não foi significativa. Nesse contexto, para obter um percentual de explicação parecido, HONGYU, *et al.*, (2015) precisou reter as primeiras seis componentes de seu modelo, ao passo que LEITE *et al.*, (2019) usou de oito.

**Tabela 7-** Vetores *explained* e *cumexplained* [%].

	P1	P2	P3	P4	P5	P6	P7
<i>Explained</i>	61,01	34,04	4,44	0,42	0,05	0,01	3,76e-3
<i>Cumexplained</i>	61,01	95,05	99,49	99,92	99,98	99,99	100

**Fonte:** AUTORA, 2021.

#### 4.2.2. Classificação dos *clusters*

A ferramenta utilizada para realizar o *Clustering* requer que seja informada a quantidade de *clusters* desejados ou apresentar um limiar de similaridade que poderá ser utilizada para realizar o corte no dendrograma, entretanto nesse trabalho optou-se por definir a quantidade de *clusters*.

Após sucessivas diligências em prol de decidir a quantidade de *clusters* ideal para classificar o conjunto de dados, verificou-se que o número de oito agrupamentos apresentou de forma mais adequada a detecção dos pontos discrepantes da distribuição, os quais foram contabilizados em 236 registros, que representam o número total de dados anômalos que foram identificados após o *Clustering* e que estão distribuídos nos *clusters* de 2 a 8. Isto é, somente o *cluster* 1 reúne as amostras normais, enquanto as 236 observações atípicas estão devidamente agregadas em diferentes grupos. Durante as tentativas com diferentes números de agrupamentos, averiguou-se que mesmo aumentando o número de *clusters* para dezessete, seriam formados novos grupos somente entre os dados considerados anômalos, enquanto o grupo principal (grupo 1) permanecia inalterado. E isso não seria útil para a análise, pois os *outliers* já podiam ser nitidamente observados com divisão em oito grupos.

Vale ressaltar, contudo, que a partir de dezoito grupos ocorreu o refinamento do *cluster* principal que, inicialmente (no modelo de oito *clusters*), possuía 9.646 registros (97,61% do total), passando a agrupar agora 6.491 registros. Assim, passaram a ser destacados como registros anômalos 3.391 pontos, ou seja, 34,31% do total. No entanto, o objetivo principal é destacar os pontos mais distantes em relação ao grupo principal, isto é, que apresentam comportamentos extremamente atípicos. Diante disso, concluiu-

se que a distância euclidiana de 907,5 entre o novo *cluster* principal, com 65,69% dos registros, e o seu *cluster* mais próximo, com 31,93%, não é tão considerável, principalmente se comparadas às distâncias de ambos em relação a amostras nitidamente atípicas, por exemplo, n° 136 e n° 5.482 que atingem distâncias 27 vezes maiores.

Em contraste, os agrupamentos obtidos especificando números inferiores de *clusters*, como sete, seis ou cinco, por exemplo, incluía no *cluster* principal registros que, apesar de não serem excessivamente anômalos, poderiam ajudar a entender melhor os efeitos da variação em diferentes variáveis dos dados iniciais. Por se tratar de um estudo, ponderou-se conveniente destacar como atípicos os pontos não demasiadamente anormais, buscando analisar com maior detalhamento a implicância das variáveis sobre os registros, separando-os em maior número de grupos. Todavia, caso o objetivo fosse identificar os *outliers* com a finalidade de basear critérios de paradas da máquina, poderia adotar-se um número menor de agrupamentos, uma vez que com apenas 4 grupos já seria possível contemplar satisfatoriamente os principais registros anormais.

A tabela 8 apresenta a média e a variância das variáveis, através da qual é possível verificar que as variáveis de maior peso no modelo PCA foram os torques dos motores e a velocidade do motor 1, em virtude de possuírem maiores variâncias relativas às demais variáveis.

**Tabela 8** - Média e variância de  $x$ .

	I(M1)	I(M2)	I(BL)	T(M1)	T(M2)	v(M1)	v(M2)
$\bar{x}$	53,47	47,33	0,45	59,25	43,94	851,19	854,60
$\sigma^2$	37,74	8,65	0,02	1,83x10 <sup>4</sup>	3,26x10 <sup>4</sup>	3,39x10 <sup>3</sup>	647,90

**Fonte:** AUTORA, 2021.


### 4.2.3. Gráficos

#### 4.2.3.1. Dispersão 2-D com formação de *clusters*

A figura 22 exibe a dispersão dos dados no plano das componentes principais P1 e P2 com formação de *clusters*. A mesma serviu como base para a análise da figura 23, visto que por diversas vezes determinados *clusters* foram mencionados, e para localizar corretamente um referido *cluster* é necessário observar a figura 22 para entender o conteúdo discutido sobre a figura 23. Além disso, a respeito da figura abaixo, convém destacar o *cluster* 1, tratado como grupo principal, que apesar de parecer misturar-se ao *cluster* 2 e 3 em certos momentos

sobre o plano P1-P2, na realidade diferem em virtude da variância ao longo de P3, que carrega 4,44% de informação de forma que a variável com maior peso sobre P3 é a Velocidade do Motor 1 com percentual de 92,67%. Assim, a principal diferença entre tais *clusters* está associada a diferentes variações de rotação do Motor 1.

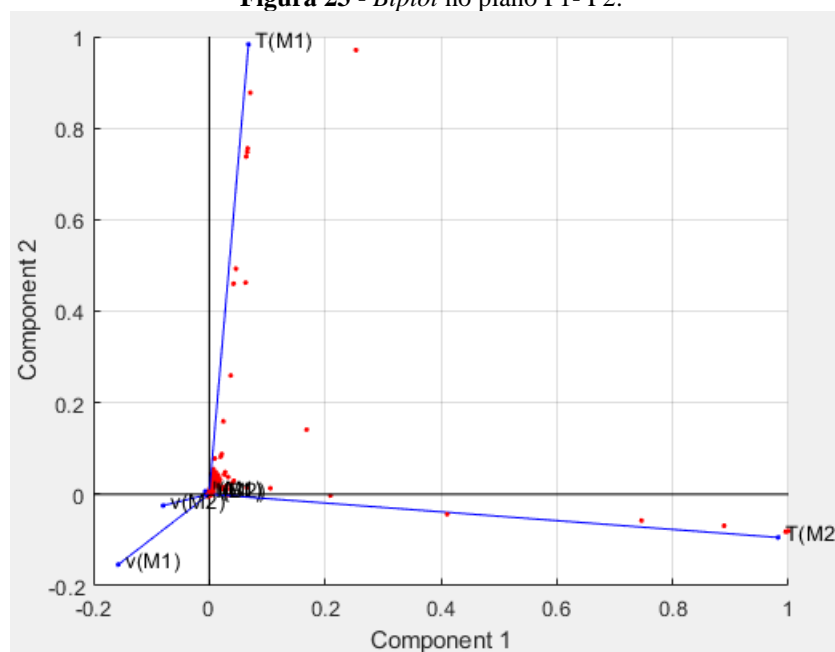
**Figura 22** – Dispersão dos dados no plano P1-P2.



Fonte: AUTORA, 2021.

#### 4.2.3.2. Gráficos *Biplot*

**Figura 23 - Biplot no plano P1- P2.**



**Fonte:** AUTORA, 2021.

A figura 23 corresponde à dispersão dos *scores* juntamente com as direções indicadoras dos *loadings* (pesos) referente a cada variável sobre as componentes principais, ou seja, a matriz de pesos fornecida pela função PCA do MATLAB descreve os percentuais de representatividade das variáveis ao longo das componentes principais. Dessa forma, avaliou-se que a escala positiva da Componente 1 corresponde aproximadamente à variação do Torque do Motor 2 “T(M2)”, uma vez que seu peso corresponde a 98,21%. Em contrapartida, a Componente 2, descreve a variação do Torque do Motor 1 “T(M1)”, cuja representatividade atinge 98,33%. Diante disso, os registros do *cluster 8* indicam que o Motor 2 desempenha um torque elevado ao mesmo tempo em que o Motor 1 encontra-se inativo. Esse comportamento converge para a situação física em que o rolamento do eixo do motor 2 está travado ou tendendo a travar mecanicamente, sobrecarregando o funcionamento do motor e gerando a falha “sobrecorrente” como constatado na figura 18 e provável falha na medição do torque do Motor 1, porque eles são mecanicamente independentes, porém sempre operam de forma conjunta. Porquanto o *cluster 8* exibe um padrão de extrema variação ao longo de P1, e pouca variância ao longo de P2. De fato, o valor do torque desenvolvido pelo Motor 2 nos registros do grupo 8, chegam a atingir valores de 100 vezes a média, enquanto os dados de Corrente, Torque e Velocidade do Motor 1 encontram-se nulos, reforçando a hipótese de falha de sinal no qual é identificada através da atuação da proteção que o sistema sinaliza como “Proteção Atuada”.

Contudo, constatou-se que apesar do valor de T(M1) ser nulo, os pontos do grupo 8 esboçam certa variância ao longo da P2. Isso ocorre devido aos pesos de P2 serem de aproximadamente -10% em T(M2) e -2,5% em V(M2), provocando flutuações no eixo vertical.

Vale destacar o comportamento do *cluster 5* (composto apenas pelo registro nº 6.188), que se encontra sobre a direção de T(M2), devido o mesmo apresentar, para todas as variáveis, valores próximos das respectivas médias, exceto em relação ao Torque do Motor 2, cujo valor varia em torno de 50 vezes o valor da média, significando que o Motor 2 está realizando grande esforço para operar devido ao excesso de carga material em seu *deck*. E por esta razão, o grupo 5 segue quase integralmente a tendência da reta T(M2).

Cabe mencionar que 88,71% dos dados projetam-se na escala negativa da P1, isto é, os *scores* de 8766 registros apresentam valores negativos sobre a Componente 1. Sendo que a maioria deles (8765 pontos) pertence ao *cluster* principal (grupo 1). Isso ocorreu porque as variáveis do *cluster 1* geralmente apresentam valores em torno da média. Além disso, neste caso, as dimensões que mais se afastam da média tendem a exercer maior influência sobre os dados, as quais correspondem às velocidades dos motores 1 e 2, com -15,68% e -7,95% de representatividade, respectivamente. Isso significa que durante o funcionamento normal da peneira, pela maior parte do tempo, ambos os motores apresentam, concomitantemente, altas velocidades e baixos torques. Provavelmente isso significa que a peneira se encontrava em processo de limpeza, pois esse processo acontece com o equipamento em funcionamento, opera a vazio ou pode estar com baixa carga. Outra hipótese é devido à alteração manual dos parâmetros de velocidade no inversor de frequência, por conta do atraso na produção, colocando a peneira para produzir mais e conseqüentemente, sobrecarregando-a. Essa manobra gera a falha de “Erro de Parâmetros/Configurações no PLC e Remota”, pois o tempo de pulso superou o que foi programado para velocidade de operação. Esta hipótese é confirmada ao verificar que a maioria dos registros anômalos – sobretudo aqueles mais afastados do *cluster 1* na direção de T(M2) – apresentam um comportamento antagônico, exibindo, simultaneamente, elevados torques e reduzidas velocidades dos motores, provavelmente por sobrecarga de material, motor exercendo muita força, mas gerando baixa velocidade.

Os *clusters 6 e 7*, por sua vez, acompanham uma tendência de variação análoga àquela dos *clusters 8 e 5*; embora, nesta ocasião, seguem o sentido de T(M1).

Observando o *cluster* 6, o qual é composto pelos pontos nº 57, 130 e 259, notou-se que efetivamente atingiram valores acima de 50 vezes a média de T(M1). A diferença principal foi que o Motor 2 estava atuando ao mesmo tempo. Por isso que o grupo 6 localiza-se no quadrante positivo, devido apresentar variâncias ao longo de T(M2) e sobretudo de T(M1). Inclusive, em virtude do registro nº 57 apresentar valor de T(M2) aproximadamente 5 vezes maior do que dos nº 130 e 259, o mesmo está mais deslocado para a direita do que os demais. Igualmente, o mesmo ocorre ao ponto nº 136 do grupo 7, ao passo que os demais pontos do mesmo grupo exibem menor variação relativa sobre P1, e considerável deslocamento em P2. Isso indica que ambos os motores da peneira estavam em pleno funcionamento, destacando-se o Motor 1 por desenvolver elevados torques e baixas velocidades de rotação.

Em relação a P3, destaca-se o ponto nº 5.492 (ao extremo da escala negativa), o qual representa a peneira completamente inativa, isto é, com dados de corrente, torque e velocidade nulos para ambos os motores, mas por estar com status 3 no sistema, isso significa “falha de comunicação”.

Sobre o *cluster* 4, convém destacar o registro nº 5.491, pois ele corresponde ao momento de desligamento do Motor 1, e continuidade do Motor 2, com torque de quase 30 vezes superior e velocidade cerca de 30 vezes inferior a suas médias, provável falha nos sensores de velocidade, pois uma velocidade nessa escala não é real fisicamente. Em virtude disso, a metodologia adotada promoveu precisamente o agrupamento desses dados fora do *cluster* principal.

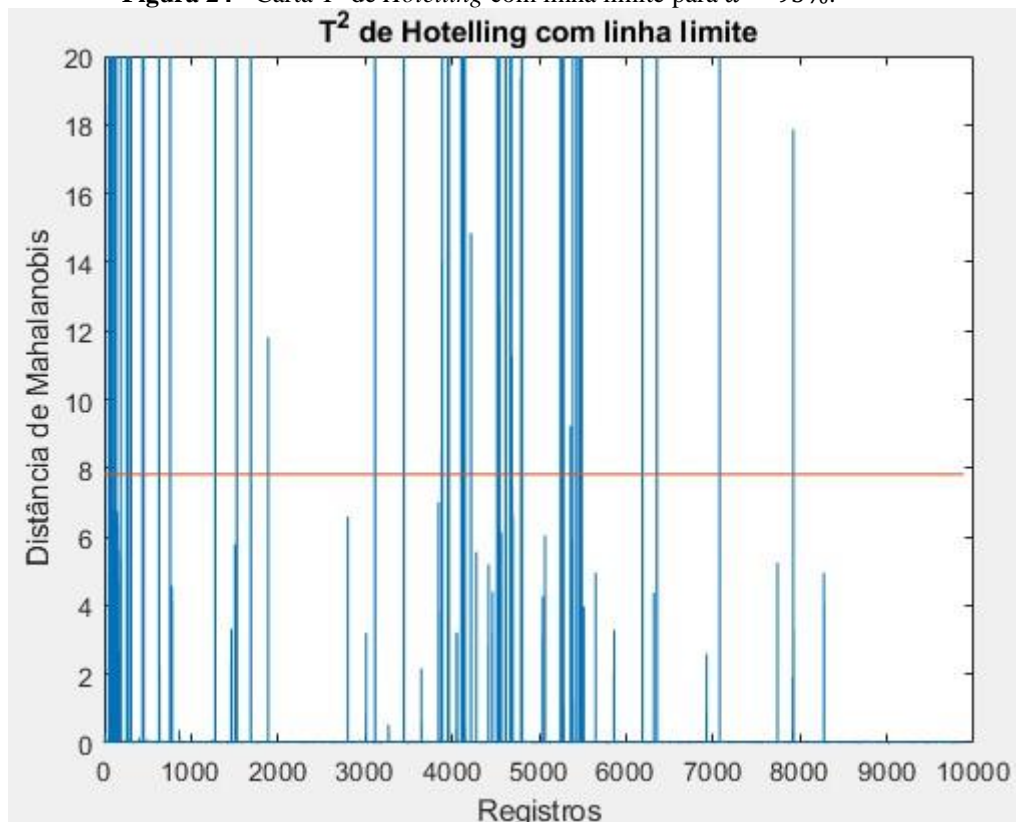
Relativo ao *cluster* 1, ele reúne quase 98% de todos os pontos, os quais registram baixas amplitudes em todas as sete variáveis, mantendo, geralmente, valores relativamente próximos de suas respectivas médias. Ademais, a magnitude da amplitude de *scores* do grupo 1 no subespaço principal corresponde a, no máximo, 50, 80 e 45 em P1, P2 e P3, respectivamente. Isso implica que nos registros do *cluster* principal não ocorrem abruptas paradas dos motores, nem sequer acontecem elevações extremas de torque ou reduções drásticas de velocidade de rotação, ou seja, a peneira opera normalmente. Ainda, observou-se que em pelo menos 32% dos dados atípicos, a elevação extrema do torque estava associada à queda abrupta de velocidade. Resta investigar o que tem causado a elevação do torque nesses motores, e se tal fenômeno pode ser considerado prejudicial para o processo. Assim, conforme os resultados obtidos, em regra, nas ocorrências de paradas em um dos motores, ou de amplas

variações de torque e rotação, esses dados foram categorizados como registros anômalos.

#### 4.2.3.3. Carta $T^2$ de *Hotelling*

Finalizando, foi esboçado o gráfico  $T^2$  de *Hotelling*, que também ajudou a visualizar de outra forma os registros anômalos, uma vez que tal gráfico apresenta a distância de *Mahalanobis* de cada amostra em relação ao centro da distribuição dos dados no subespaço das componentes. De outro modo, o gráfico é hábil em destacar quais os elementos que estão mais afastados, com maiores variâncias ao longo das componentes principais. Como resultado, a figura 24 apresenta a distância de *Mahalanobis* que cada amostra possui do centro da distribuição no subespaço das componentes.

**Figura 24** - Carta  $T^2$  de *Hotelling* com linha limite para  $\alpha = 95\%$ .



**Fonte:** AUTORA, 2021.

Portanto, através do gráfico da figura 24 foi possível verificar que os pontos que apresentaram maiores distâncias de *Mahalanobis* (que estão mais afastados do centro da distribuição de dados no subespaço principal) foram os mesmos detectados pelo método *Linkage Ward* como registros anômalos. Diante disso, o método *Ward* convergiu com o resultado alcançado com a Carta  $T^2$ , separando em *clusters* de objetos atípicos justamente os

pontos de maiores distâncias no gráfico da figura 24, embora *Ward Linkage* tenha destacado 236 amostras como anormais, a Carta  $T^2$  encontrou 91 deles para  $\alpha = 95\%$ . Ou seja, 91 registros apresentaram-se acima do valor crítico calculado de  $T_{lim}^2 = 7,82$ . Todavia, todos esses 91 registros anômalos detectados pela estatística  $T^2$  de *Hotelling* estão inclusos nos 236 encontrados pelo método *Clustering* de *Ward*. Dessa maneira, para a Carta separar maior número de amostras anormais, seria preciso reduzir o limiar crítico “ $T_{lim}^2$ ” (linha limite do gráfico), operando com  $\alpha$  abaixo de 95%, provando que é possível se chegar ao mesmo resultado e a mesma conclusão com métodos diferentes.

## 5. CONSIDERAÇÕES FINAIS

No presente trabalho, realizou-se um estudo de falhas na peneira, considerado um importante equipamento no processo da mineração. A peneira da empresa em questão apresentou diversos eventos de falhas elétricas, de instrumentação e automação ao longo do ano de 2019. Desse modo, resolveu-se atacar tal problema do ponto de vista do aprendizado de máquina e análise de dados.

Como produto do FMEA, uma média aritmética foi realizada com os valores do RPN e quantidade de modos de falhas para definir o valor referência como 144,91. Desse modo, valores acima deste receberam maior atenção e tempo em seus tratamentos. Como visto e sugerido, é necessário revisar a árvore de falhas da empresa, investir em componentes de modelos mais atuais, revisar os planos de manutenção do PLC e do Relé Inteligente, orientar mantenedores para a realização da manutenção de qualidade seguindo o passo a passo do procedimento da tarefa, orientar equipe que apropria falhas para o correto apontamento da causa e setor responsável, além realizar um estudo de caso para as falhas em que ainda não é possível detectar sua real causa.

Através do PIMS, foram extraídas informações de minuto a minuto dos motores da PN-03 do mês de outubro e foram considerados os dados em que a peneira estivesse funcionando normalmente para a obtenção dos dados anômalos através do código de PCA e *Clustering*.

Com isso, foi possível realizar uma análise exploratória e separar os dados anômalos em 8 *clusters*, sendo o 1 caracterizado pelos dados de pleno funcionamento dos motores e os outros 7 pelos dados anômalos em que foi possível separá-los em vários *clusters*, considerando que eles foram influenciados por diferentes níveis de variação, sobretudo de velocidade de rotação e de torque. Assim, foi verificado que a metodologia empregada mostrou alta precisão na criação dos *clusters*, de modo que se observou *outliers* sendo agrupados devido à elevada correlação entre eles, apesar de serem poucos em número (*clusters* 5 e 6, por exemplo).

Como foi possível notar, os fatores mecânicos, de operação ou limpeza do equipamento frequentemente são as causas fundamentais das anomalias encontradas nos *clusters*, gerando possivelmente também algumas falhas que são apontadas como de natureza elétrica erroneamente, como no caso de “Proteção Atuada” e “Sobrecorrente”. Também foi possível constatar que a necessidade de aumento da produção gera

variações nos valores das variáveis, e quando temos a ocorrência da “Falha de comunicação” os dados não se tornam confiáveis e são conotados como anômalos.

Assim, como ganho, se esse sistema fosse implementado, a Carta  $T^2$  de *Hotelling* auxiliaria o operador a interpretar o seu resultado de forma direta, fornecendo uma rápida instrução para decidir se é preciso parar a máquina ao expressar visualmente os dados anômalos dos motores acima da linha limite. Já no caso do *Clustering*, permitiria a extração das informações e, além disso, faria uma análise mais detalhada do que poderia estar ocorrendo naquele instante, principalmente em relação as causas físicas do estranho comportamento das variáveis.

Sendo assim, para implantar um produto em tempo real em uma planta da usina que capture os dados diferentes dos nominais de diversos equipamentos, como transportadores de correias, demais peneiras, silos de carregamento, britadores, entre outros, esse é o primeiro passo, onde o seu núcleo consistirá em realizar a análise de componentes principais (PCA), aplicar esse modelo de agrupamento através do *Clustering* ou traçar a linha limite com a carta  $T^2$  de *Hotelling* detectando os pontos que estiverem acima dessa linha, para assim, emitirem um alerta visual ou sonoro que deverá ser avaliado pelo operador quanto a sua veracidade e variação temporal para gerar a tomada de decisão: parar o funcionamento do equipamento e solucionar o problema ou não, assim podendo antever falhas.

## REFERÊNCIAS

- ANINDITA, S. **Ward's Hierarchical Clustering Method using R Studio**. Disponível em: <<https://medium.com/@sukmaanindita/wards-hierarchical-clustering-method-using-r-studio-a47b5a79cb4d>>. Acesso em: 21 de dez. 2019.
- ALMEIDA, S. N. **Elaboração do Perfil de Perdas**. Vitória: Companhia Vale do Rio Doce, 2006.
- AMARAL, A. J. R; FILHO, C. A. L. **Índice de Geologia e Mineração – Mineração**. Recife, Pernambuco, 2007. Disponível em: <http://www.dnpm-pe.gov.br/Geologia/Mineracao.php>. Acesso em: 30 de dez. de 2019.
- AMARAL, R. V. O Uso de Orbitas na Análise de Vibrações de Peneiras Vibratórias. **LinkedIn**. Osasco, 18 de julho de 2016. Disponível em: <<https://www.linkedin.com/pulse/o-uso-de-orbitas-na-an%C3%A1lise-vibra%C3%A7%C3%B5es-peneiras-vieira-do-amaral/?originalSubdomain=pt>>. Acesso em: 15 de fevereiro de 2020.
- ASSUNÇÃO, T. M. R.C; DE PAULA, F. A. **Análise dos Efeitos Dinâmicos Induzidos por Peneiras Vibratórias em Estruturas Industriais**. Departamento de Engenharia de Estruturas – UFMG. Belo Horizonte, Minas Gerais. 2010. Disponível em: <<https://docplayer.com.br/amp/20438306-Analise-dos-efeitos-dinamicos-induzidos-por-peneiras-vibratorias-em-estruturas-industriais.html>>. Acesso em: 31 de dez. de 2019.
- BARRETO, J. M. **Inteligência artificial no limiar do século XXI**. Florianópolis: PPP edições, v. 97, 1999.
- BARTO, A. G. & SUTTON, R., S. Reinforcement learning in artificial intelligence. **Advances in Psychology**. North-Holland, 1997. p. 358-386.
- BECKER, L. T.; GOULD, E. M. Microsoft power BI: extending excel to manipulate, analyze, and visualize diverse data. **Serials Review**, 2019, v.45.3, p. 184-188.
- BITTENCOURT, J.; OSÓRIO, F. ANNeF–Artificial Neural Networks Framework: Uma Solução Software Livre para o Desenvolvimento, Ensino e Pesquisa de Aplicações de Inteligência Artificial Multiplataforma. In: **Anais do II Workshop sobre Software Livre**. Porto Alegre: SBC. sn, 2001. p. 13-16.
- BRAVIM, V. D. & SOUZA, M. S. Perfil de Perdas de Produção Relacionado a Falhas Elétricas: Estudo de Caso das Usinas de Pelotização da CVRD do Complexo de Tubarão, 2007.
- CARDOSO, K. L. Revisão do plano de manutenção numa fábrica de rolhas de cortiça. 2018. Disponível em: <<https://repositorio-aberto.up.pt/bitstream/10216/115204/2/281525.pdf>>. Acesso em 21 de Julho de 2021.
- Rio de Janeiro, 2006. Dissertação (Mestrado em Gestão Empresarial) - Escola Brasileira de Administração Pública e de Empresas, Fundação Getúlio Vargas, Rio de Janeiro.

CARDOZO, F. A. C.; PIMENTA, M. M.; ZINGANO, A. C.. Métodos construtivos de barragens de rejeitos de mineração—uma revisão. **Holos**, v. 8, p. 77-85, 2016.

CARVALHO, A. X. Y. *et al.* Spatial Hierarchical Clustering. **Revista Brasileira de Biometria**, São Paulo, ano 2009, p. 411-442, 5 jun. 2009.

CARVALHO, Fábio *et al.* Sistemas PIMS: conceituação, usos e benefícios. Anais do Seminário de Automação de Processos, Santos, 2003.

CARVALHO, F. F.; JÚNIOR, A. A. C.; ABRAHIM, G. S. Mineração sustentável: os desafios de conciliar a exploração de recursos não-renováveis a uma prática sustentável geradora de desenvolvimento econômico. In: XXIX ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO-A ENGENHARIA DE PRODUÇÃO E O DESENVOLVIMENTO SUSTENTÁVEL: INTEGRANDO TECNOLOGIA E GESTÃO. Salvador, BA, Brasil, v. 6, n. 09, 2009.

CERVO, V. L.; ANZANELLO, M. J. Seleção de variáveis para clusterização de bateladas produtivas através de ACP e remapeamento kernel. **Production**, v. 25, p. 826-833, 2015.

DAMACENO, S. S.; VASCONCELOS, R. O. **Inteligência artificial: uma breve abordagem sobre seu conceito real e o conhecimento popular**. 2018. Trabalho de conclusão de curso (Graduação em Ciências Exatas e Tecnológicas) Departamento de tecnologia da Universidade Tiradentes – SE.

DE MELO PARANHOS, Mayara *et al.* Aplicação da análise de modo e efeitos de falha para o gerenciamento de riscos de um projeto. **Sistemas & Gestão**, v.11(4), p.444-454, 2016.

DINIZ, H. A. G., DUTRA, D. C., DE OLIVEIRA, N. C. G., BRAGA, G. G., PUJATTI, F. J. P. Análise dos modos e efeitos das falhas-FMEA em um transportador de correia. In: IX CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA. Fortaleza, Ceará, Brasil, 2016.

DUARTE, J. B. **Introdução à Análise de Componentes Principais: Com Aplicação do SAS ® - Statistical Analysis System**. Piracicaba: UFG - Universidade Federal de Goiás, 1998.

DUTRA, R. **Beneficiamento de Minerais Industriais**. 2008. Disponível em: <[http://www.pg.utfpr.edu.br/ppgep/anais/artigos/eng\\_civil/13%20BENEFICIAMENTO%20DE%20MINERA%20INDUSTRIAIS.pdf](http://www.pg.utfpr.edu.br/ppgep/anais/artigos/eng_civil/13%20BENEFICIAMENTO%20DE%20MINERA%20INDUSTRIAIS.pdf)>. Acesso em: 13 de dez. de 2019.

EBRAHIMIPOUR, V.; REZAIE, K.; SHOKRAVI, S. (2010), **An Ontology Approach to Support FMEA Studies**. Expert Systems with Applications. Vol. 37, n. 1, pp. 671-677.

ERMENEGILDO, I. M. **Aplicação da análise de modos e efeitos de falha – FMEA – para avaliação de situações de riscos no projeto de prevenção de incêndio da casa do estudante universitário (CEU-PR)**. 2014. 61 f. Monografia de especialização - Departamento acadêmico de construção civil, Curitiba, 2014.

ESBENSEN, Kim; GELADI, Paul. Principal Component Analysis. **Chemometrics and Intelligent Laboratory Systems**, Amsterdam: Elsevier Science Publishers B.V., ed. 2, ano 1987, n. 0169-7439/87/\$03.50, p. 37-52, 7 ago. 1987.

HADI, A. Identifying multiple outliers in multivariate data. **Journal Royal Statistics Society**, 54, 761- 771, 1992.

HARDIN, J., ROCKE, D. M. Outlier detection in multiple cluster setting using the minimum covariance determinant estimator. **Computational Statistics & Data Analysis**, v. 44, p.625-638, 2004.

HAVER E BOECKER – THE SCREENING GROUP. **Manual de Instruções – Peneira Vibratória do Tipo TD**. Parauapebas, Pará. 2010.

HAYKIN, S. **Neural Networks – A comprehensive foundation**. Prentice-Hall, New Jersey, edition, 1999.

HONGYU, K.; SANDANIELO, V., L., M.; DE OLIVEIRA JUNIOR, G. J. Análise de componentes principais: resumo teórico, aplicação e interpretação. **E&S Engineering and science**, v. 5, n. 1, p. 83-90, 2016.

IIZUKA, E. K. **Análise de tensões em peneiras vibratórias através de modelagem numérica utilizando o método dos elementos finitos e experimentalmente por extensometria**. Campinas, SP. 2006. Dissertação (mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

KAUFMAN, D. **A inteligência artificial irá suplantar a inteligência humana?** Barueri, SP. Estação das letras e cores edi.,2019. Disponível em: <<https://books.google.com.br/books?hl=pt-BR&lr=&id=Fh-WDwAAQBAJ&oi=fnd&pg=PT5&dq=inteligencia+artificial+&ots=ovQMBfF683&sig=oh7GGZFMCIJw1pnlQqRm3Rsw895c#v=onepage&q=inteligencia%20artificial&f=false>> Acesso em 22 março de 2020.

LACHI, R. L.; ROCHA, H. V. **Aspectos básicos de clustering: conceitos e técnicas**. Disponível em: <https://ic.unicamp.br/~reltech/2005/05-03.pdf>. Acesso em: 01 de março de 2020.

LEITE, A. M. C. *et al.* O Uso da Técnica de Análises de Componentes Principais como Ferramenta para Avaliar a Influência de Finos de Alumina e Manganês na Flotação Industrial. *In: ENCONTRO NACIONAL DE TRATAMENTO DE MINÉRIOS E METALURGIA EXTRATIVA*, 28., 2019, Belo Horizonte. **Anais [...]**. Belo Horizonte: UFMG - Universidade Federal de Minas Gerais, 2019.

LEITE, U. B. Política Nacional de Desenvolvimento Regional: experiência recente da política regional no Brasil. Santiago do Chile: CEPAL-CELADE. **Reunión de expertos sobre: “Población territorio y desarrollo sostenible”**. Santiago, p. 16-17, 2011.

LORENA, A. C.; CARVALHO, A. C. P. L. F. **Introdução às Máquinas de Vetores Suporte (Support Vector Machines)**. Disponível em: [http://conteudo.icmc.usp.br/CMS/Arquivos/arquivos\\_enviados/BIBLIOTECA\\_113\\_RT\\_192.pdf](http://conteudo.icmc.usp.br/CMS/Arquivos/arquivos_enviados/BIBLIOTECA_113_RT_192.pdf). Acesso em: 15 de jan. de 2020.

- LUGER, G. **Inteligência Artificial**. 6. ed., São Paulo: Pearson, 2014.
- LUZ, A. B.; SAMPAIO, J. A.; FRANÇA, S. C. A. Introdução ao tratamento de minérios. **Tratamento de Minérios - 5ª Edição** – Rio de Janeiro: CETEM/MCT, p.03, 2010.
- MACEDO FILHO, H., F., C. M. **Planejamento da manutenção mecânica no laboratório de vibrações mecânicas do CEPEL**. 2011. Trabalho de conclusão de curso (Graduação em Engenharia Mecânica) Departamento de Engenharia Mecânica da Universidade Federal do Rio de Janeiro – RJ.
- MARCHETTO, R. **Utilização do software MATLAB como recurso tecnológico de aprendizagem na transformação de matrizes em imagens**. 2016. Disponível em <https://periodicos.ufsc.br/index.php/revemat/article/download/1981-1322.2016v11n1p118/32132>. Acesso em: 28 de dez. de 2019.
- MARQUES, J. M.; CHAVES N., A. Introdução à Análise Multivariada. *In: UFPR - Universidade Federal do Paraná. Notas de Aula da Disciplina CE076. [S.l.]*. 8 nov. 2009. Disponível em: <https://docs.ufpr.br/~soniaisoldi/ce090/2INTRODUCAOMULTIVARIADA.pdf>. Acesso em: 3 dez. 2021.
- MICROSOFT. O que é Power BI. Novembro, 2018. Disponível em: <https://docs.microsoft.com/pt-br/power-bi/power-bi-overview>. Acesso em 26 de dez. 2019.
- MITCHELL, T. **Machine Learning**. McGraw Hill, 1997.
- NAKAJIMA, S. **Introdução ao TPM – Total Productive Maintenance**. São Paulo: IMC Internacional Sistemas Educativos Ltda, 1989.
- NASCIMENTO, Cláudio Augusto Oller do; GUARDANI, Roberto. **Análise estatística multivariada aplicada a processos químicos**. São Paulo: USP - Universidade de São Paulo, 2007.
- OLIVEIRA, P. T. M. S.; SANTOS, J. O.; MUNITA, C. S. **Identificação de valores discrepantes por meio da distância Mahalanobis**. 48 Reunião Anual da Região Brasileira da Sociedade Internacional de Biometria, Lavras, 2005.
- PALADY, P. **FMEA Análise dos Modos de Falha e Efeitos**. São Paulo: IMAN, 1997.
- PANERO, Francisco *et al.* **Aplicação da análise exploratória de dados na discriminação geográfica do quiabo do Rio Grande do Norte e Pernambuco**. Disponível em: <http://www.scielo.br/pdf/eq/v34n3/04.pdf>. Acesso em: 28 de fevereiro de 2020.
- PESSOA, G. A. **Avaliação de projetos de mineração utilizando a teoria das opções reais em tempo discreto: um estudo de caso**. Rio de Janeiro, 2006. Dissertação

(Mestrado em Gestão Empresarial) - Escola Brasileira de Administração Pública e de Empresas, Fundação Getúlio Vargas, Rio de Janeiro.

QUIMIOMETRIA. Construção de um script em Matlab: Calculando T2 de Hotelling e Q residual. YouTube, 2020. 1 vídeo (10 min 01 seg). Publicado pelo Paulo Filgueiras. Disponível em: <https://www.youtube.com/watch?v=CJrt-Hoc8c0>. Acesso em: 20 dez. 2021.

QUIMIOMETRIA. Construção de um script em Matlab: Cálculo dos limites para T2 e Q residual. YouTube, 2020. 1 vídeo (10 min 34 seg). Publicado pelo Paulo Filgueiras. Disponível em: <https://www.youtube.com/watch?v=-R9tThzzMF8>. Acesso em: 20 dez. 2021.

RAMALHO, A. V. O. **Automatização de Indicadores utilizando Software de Business Intelligence**. 2019. 58f (Monografia de Graduação em Engenharia de Controle e Automação pela Universidade Federal de Ouro Preto - UFOP), Ouro Preto, 2019.

RAMOS, E. F. (2006). **A gestão de Riscos usando FMEA**. Revista Mundo PM, n.10, p. 71-74.

RANDRIAMIHAMISON, N.; VIALANEIX, N.; NEUVIAL, P. **Applicability and interpretability of Ward's hierarchical agglomerative clustering with or without contiguity constraints**. Journal of Classification, Springer Verlag, 2021.

RIUT. **Controle estatístico multivariado de processos através do gráfico T<sup>2</sup> de Holtelling**. Disponível em: <[https://repositorio.utfpr.edu.br:8080/jspui/bitstream/1/16137/2/PG\\_DAENP\\_2017\\_2\\_11.pdf](https://repositorio.utfpr.edu.br:8080/jspui/bitstream/1/16137/2/PG_DAENP_2017_2_11.pdf)>. Acesso em 21 dez. de 2021.

ROKACH, L.; MAIMON, O. Clustering methods. **Data mining and knowledge discovery handbook**. Springer, Boston, MA, 2005. p. 321-352.

RUSSEL, S.; NORVIG, P. **Artificial Intelligence, a modern approach**. Series in Artificial Intelligence. Prentice Hall, 1995.

SANTOS, R. **Introdução ao MATLAB**. Apostila on-line. Disponível em <http://www.mat.ufmg.br/~regi> (11/05/04). Acesso em: 28 de dez. de 2019.

SEIXAS, F. C.; **PIMS - Process Information Management System**. Notas de Aula, Capítulo 6. Minas Gerais, 2014. Disponível em: <[www.cpdee.ufmg.br/~seixas/](http://www.cpdee.ufmg.br/~seixas/)>. Acesso em: 28 de dez. de 2019.

SATANA A; MASSARANI, M. Engenharia do valor associada ao DFMEA no desenvolvimento do produto. **Society of Automotive Engineers, Inc**. 2005. Disponível em: < <http://www.mecanica-poli.usp.br/05pesq/cont/pdf/712.pdf> >. Acesso 21 Março de 2020.

SANTANA, F. **Entenda o Algoritmo K-means e Saiba como Aplicar essa Técnica.** Minerando dados. Disponível em: < <https://minerandodados.com.br/entenda-o-algoritmo-k-means/> >. Acesso em: 21 de dezembro de 2021.

SEIXAS, F. C.; **PIMS - Process Information Management System.** Notas de Aula, Capítulo 6. Minas Gerais, 2014. Disponível em: <[www.cpdee.ufmg.br/~seixas/](http://www.cpdee.ufmg.br/~seixas/)>. Acesso em: 28 de dez. de 2019.

SILVA, R. A. C. **Inteligência Artificial Aplicada a Ambientes de Engenharia de Software: Uma Visão Geral.** Departamento de Informática – Universidade Federal de Viçosa. Viçosa, MG, 2005. Disponível em: <http://www.dcc.ufva.br/infocomp/index.php/INFOCOMP/article/view/109>. Acesso em: 06 de jan. de 2020.

SILVER, D. L.; YANG, Q.; LI, L.. Lifelong machine learning systems: Beyond learning algorithms. In: **2013 AAAI spring symposium series**, 2013.

SOUSA, S. M. **Desenvolvimento de um sistema PIMS com comunicação OPC e acesso por Navegador Web.** 2014. 67f. (Trabalho de Conclusão de curso - Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais). Formiga, 2014.

SOUZA, F. N.; COSTA, A. P.; MOREIRA, A. **Análise de Dados Qualitativos Suportada pelo Software WebQDA.** CIDTFF - Centro de Investigação Didática e Tecnologia na Formação de Formadores Departamento de Educação, Universidade de Aveiro. Aveiro, Portugal. 2011. Disponível em: <https://www.webqda.net/wp-content/uploads/2016/05/AnaliseDadosQualitativos.pdf>. Acesso em: 05 de janeiro de 2020.

STAMATIS, D.H. **Failure Mode and Effect Analysis: FMEA from theory to execution.** Milwaukee, Winsconsin: ASQ Quality Press, second edition, 2003.

TORELLI, J. C. **Implementação paralela da transformada de distância euclidiana exata.** Orientador: Prof. Dr. Odemir Martinez Bruno. 2005. Dissertação (Mestrado) - Curso de Ciências de Computação e Matemática Computacional, ICMC - Instituto de Ciências Matemáticas e de Computação, USP - Universidade de São Paulo, São Carlos, 2005.

VARELLA, C. A. A. **Análise Multivariada Aplicada às Ciências Agrárias: Análise de Componentes Principais.** Seropédica/RJ: UFRRJ - Universidade Federal Rural do Rio de Janeiro, 2008.

VASCONCELOS, S. Análise de Componentes Principais (PCA). In: Simone Vasconcelos. **Simone Vasconcelos e myself.** [S.l.]. 31 jan. 2011. Disponível em: <http://www.ic.uff.br/~aconci/PCA-ACP.pdf>. Acesso em: 3 dez. 2021.

VEDALDI, ANDREA & LENC, K. **Matconvnet: Convolutional neural networks for matlab.** In: **Proceedings of the 23rd ACM international conference on Multimedia.** 2015. p. 689-692.

VIJAYA; SHARMA, S.; BATRA, N. Comparative Study of Single Linkage, Complete Linkage, and Ward Method of Agglomerative Clustering. In: INTERNATIONAL

CONFERENCE ON MACHINE LEARNING, BIG DATA, CLOUD AND PARALLEL COMPUTING, 2019, India. **Anais** [...]. India: Com-IT-Con, 2019.

VILAÇA, A. F. **Perfil de perdas no processo da moagem de uma usina de pelotização de minério de ferro, Estudo de caso: Vale tubarão.** (Trabalho de conclusão de curso – FACULDADES INTEGRADAS ESPÍRITO – SANTENSES). Vitória, ES. 2014.

ZONTA, G. R. Proposta experimental para separação mecânica e análise granulométrica de materiais particulados. **Maiêutica-Engenharias**, v. 1, n. 1, 2013.

YOKOMIZO, G. K. I. *et al.* Dendrograma e GGE biplot uma combinação para estudo de estabilidade e adaptabilidade em açazeiro. **Revista de Biologia e Ciências da Terra**, Brasília: Embrapa, ed. 20, ano 2020, n. 2, p. 102-112, 7 out. 2020. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1128394>. Acesso em: 21 dez. 2020.

YOSHIMITANAKA, Oswaldo *et al.* **Uso da análise de clusters como ferramenta de apoio à gestão no SUS.** Disponível em: <http://www.scielo.br/pdf/sausoc/v24n1/0104-1290-sausoc-24-1-0034.pdf>. Acesso em: 28 de fevereiro de 2020.

## APÊNDICE 1

### Planilha FMEA (parte 1)

Ponto da Falha		
Equipamento	Função do Equipamento	Componente
PENEIRA CLASSIFICADORA - TAG: PN3011KN-03	Classificar material a granel (minérios e agregados), podendo ser finos, médios ou grossos, e peneiramento com via seca.	Componentes de Comando, Proteção e Controle
		Componentes de Controle e Medição
		Motor Acionamento
		Motor Auxiliar
		Painél Elétrico (CCM, gaveta, força, comando, etc)
		PLC e Remota

## Planilha FMEA (parte 2)

Análise da Falha		
Modos de Falha	Efeitos de Falha	Causa da Falha
Falha Botão de Emergência	Impede o acionamento e que o sistema rode normalmente	Mau contato, oxidação, atuação indevida, defeito no componente e travamento da botoeira por causa do minério
Falha Chave de Velocidade	Impede o acionamento e que o sistema rode normalmente	Ajuste da distância sensora, configuração do ajuste do monitor de velocidade, curto-circuito, condição física do sensor, emendas, quebra do plug, conector e o sensor pode ser danificado por condições externas
Falha Sensor de Velocidade	Impede o acionamento e que o sistema rode normalmente	Ajuste da distância sensora, configuração do ajuste do monitor de velocidade, curto-circuito, condição física do sensor, emendas, quebra do plug, conector e o sensor pode ser danificado por condições externas
Ajuste/Calibração Sensor	Impede o acionamento e que o sistema rode normalmente	Ajuste da distância sensora, configuração do ajuste do monitor de velocidade, curto-circuito, condição física do sensor, emendas, quebra do plug, conector e o sensor pode ser danificado por condições externas
Falha Sensor	Impede o acionamento e que o sistema rode normalmente	Ajuste da distância sensora, configuração do ajuste do monitor de velocidade, curto-circuito, condição física do sensor, emendas, quebra do plug, conector e o sensor pode ser danificado por condições externas
Sobrecorrente	Parada do equipamento	Travamentos mecânicos, falta de lubrificação, excesso de material, material úmido demais, falta de limpeza, levantamento falso, pois nem sempre é excesso de material
Mau contato conexões	Queima do componente, parada do equipamento e curto-circuito	Falta de aperto durante manutenção, gaveta mal inserida, boxe da gaveta e vibração da peneira
Sobrecorrente	Parada do equipamento	Travamentos mecânicos, falta de lubrificação, excesso de material, material úmido demais, falta de limpeza, levantamento falso, pois nem sempre é excesso de material
Bloqueio/Desbloqueio	Parada do equipamento	Falha no procedimento de inserção da gaveta, falta de rearme, falta de programação de bloqueio efetivo
Falha de Comunicação	Parada do equipamento	Plug solto gerado por bloqueio e desbloqueio, perda de comunicação da rede, falha de rede na rede de apontamento da falha
Proteção Atuada	Parada do equipamento	Quando ocorre a rede aponta: Timeout na comunicação Profibus (erro E0068), mas ainda não se sabe o real motivo
Erro de Parâmetros/Configurações	Parada do equipamento por causa dos relés	Quando ocorre a rede aponta: Timeout na comunicação Profibus (erro E0068), mas ainda não se sabe o real motivo

### Planilha FMEA (parte 3)

Avaliação de Risco				Ação Preventiva Recomendada
Ocorrência	Severidade	Deteção	RPN	
2	8	1	16	Reaperto, limpeza de contato, necessidade de troca do equipamento, troca por condição
8	8	1	64	Melhorar a sua fixação durante manutenção, melhorar o seu ajuste (Falha advinda do erro de apropriação de falha no sistema e de erro na Árvore de falhas da Planta)
8	8	1	64	Melhorar a sua fixação durante manutenção, melhorar o seu ajuste (Falha advinda do erro de apropriação de falha no sistema e de erro na Árvore de falhas da Planta)
8	8	1	64	Especificação de um sensor que possa mostrar um range melhor para o ajuste (sensor que deve ser pesquisado no mercado), (Falha advinda do erro de apropriação de falha no sistema e de erro na Árvore de falhas da Planta)
8	8	1	64	Melhorar a sua fixação durante manutenção, melhorar o seu ajuste (Falha advinda do erro de apropriação de falha no sistema e de erro na Árvore de falhas da Planta)
6	6	4	144	Análise gráfica do comportamento de funcionamento do equipamento através do PIMS para tomar devidas providências em relação a apropriação das falhas no sistema (Falha na rede de comunicação)
5	5	7	175	Manutenção Preventiva Efetiva
6	6	4	144	Análise gráfica do comportamento de funcionamento do equipamento através do PIMS para tomar devidas providências em relação a apropriação das falhas no sistema
8	8	2	128	Realizar a programação do bloqueio eficaz
6	6	1	36	Revisar o Plano de Manutenção dos equipamentos PLC até o Relé Inteligente (SRW01); substituir o Relé Inteligente por outro modelo mais atual
7	6	10	420	Estudo de caso para detectar o real motivo que acarreta esse apontamento; mapear qual a falha e/ou defeito faz com que a proteção atuada suba para o sistema; alterar a lógica do Relé Inteligente pela versão mais atual. (Não se sabe o real por quê desta falha ser apontada pelo sistema)
7	6	10	420	Estudo de caso para detectar o real motivo que acarreta esse apontamento; mapear qual a falha e/ou defeito faz com que a proteção atuada suba para o sistema; alterar a lógica do Relé Inteligente pela versão mais atual. (Não se sabe o real por quê desta falha ser apontada pelo sistema)

## APÊNDICE 2

### Algoritmo desenvolvido no MATLAB

```
clc,clear,close all
x=importdata('peneirarodando.csv');
x=x.data;
[coeff,score,latent,tsquared,explained]=pca(x(:,1:7),'NumComponents',3);
cumexplained=cumsum(explained);
tree=linkage(score,'ward');
clus=cluster(tree,'maxclust',8);
figure(1)
dendrogram(tree,8);
title('Dendrograma')
xlabel('Clusters')
ylabel('Distância Euclidiana')
figure(2)
gscatter(score(:,1),score(:,2),clus,'kbyrgcm','o+dhxs*>',10)
title('Dispersão dos registros no plano principal 2-D com formação de clusters')
xlabel('P1')
ylabel('P2')
figure(3)
scatter3(score(:,1),score(:,2),score(:,3),clus)
view(-30,10)
title('Dispersão dos registros no sub-espço principal 3-D')
xlabel('P1')
ylabel('P2')
zlabel('P3')
hc=histcounts(clus);
[~,normal]=max(hc);
registrosanomalos=find(clus~=normal);
figure(4)
tsqreduced = mahal(score,score);
```

```
plot(1:size(x,1),tsqreduced);
title('T^2 de Hotelling com linha limite')
xlabel('Registros')
ylabel('Distância de Mahalanobis')
hold on
alfa=0.95;
h=3;
m=size(x,1);
F=finv(alfa,h,m-h);
limT2=((h*(m-1))/(m-h))*F;
ppp=1:size(x,1);
YY=limT2-ppp+ppp;
plot(ppp,YY);
```