



UNIVERSIDADE FEDERAL DE OURO PRETO – UFOP
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA MECÂNICA



FRANCO CERCEAU NEVES

**PROGRAMA *MACHINE LEARNING* NA LINGUAGEM PYTHON PARA
MANUTENÇÃO PREVENTIVA DE BRITADORES**

OURO PRETO - MG
2025

FRANCO CERCEAU NEVES
franco.neves@aluno.ufop.edu.br

**PROGRAMA *MACHINE LEARNING* NA LINGUAGEM PYTHON PARA
MANUTENÇÃO PREVENTIVA DE BRITADORES**

Monografia apresentada ao Curso de
Graduação em Engenharia Mecânica
da Universidade Federal de Ouro Preto
como requisito para a obtenção do
título de Engenheiro Mecânico.

Professora orientadora: Zirlene Alves da Silva Santos, PhD.

OURO PRETO – MG
2025

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

N513p Neves, Franco Cerceau.

Programa machine learning na linguagem python para manutenção preventiva de britadores. [manuscrito] / Franco Cerceau Neves. - 2025. 35 f.: il.: color., tab..

Orientadora: Profa. Dra. Zirlene Alves da Silva Santos.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Escola de Minas. Graduação em Engenharia Mecânica .

1. Manutenção - Manutenção Preventiva. 2. Minas e recursos minerais. 3. Britadores. 4. Python (Linguagem de programação de computador). 5. Aprendizado do computador. I. Santos, Zirlene Alves da Silva. II. Universidade Federal de Ouro Preto. III. Título.

CDU 621

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



FOLHA DE APROVAÇÃO

Franco Cerceau Neves

PROGRAMA MACHINE LEARNING NA LINGUAGEM PYTHON PARA
MANUTENÇÃO PREVENTIVA DE BRITADORES

Monografia apresentada ao Curso de Engenharia Mecânica Universidade Federal
de Ouro Preto como requisito parcial para obtenção do título de Engenheiro Mecânico

Aprovada em 12 de Agosto de 2025

Membros da banca

PhD. - Zirlene Alves da Silva Santos - Orientador(a)
UNIVERSIDADE FEDERAL DE OURO PRETO

Dra. - Margarida Marcia Fernandes
UNIVERSIDADE FEDERAL DE OURO PRETO

Dr. - Diogo Antônio de Sousa
UNIVERSIDADE FEDERAL DE OURO PRETO

Zirlene Alves da Silva Santos, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 16/08/2025



Documento assinado eletronicamente por Zirlene Alves da Silva Santos, PROFESSOR DE MAGISTERIO SUPERIOR, em 16/08/2025, às 16:12, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador 0961391 e o código CRC A772B050.

AGRADECIMENTO

Agradeço, primeiramente, aos meus pais, Celso e Denise, por todo amor, dedicação e suporte ao longo da minha vida. Foram eles que me proporcionaram educação, valores e oportunidades que tornaram possível a concretização deste sonho. Aos meus irmãos, Bárbara e Arthur, minha eterna gratidão pelo carinho, companheirismo e incentivo constantes.

A minha orientadora, professora Zirlene, deixo um agradecimento especial por sua paciência, disponibilidade e orientação cuidadosa durante todo o desenvolvimento deste trabalho. Sua contribuição foi essencial para que este projeto se tornasse realidade.

Aos colegas do curso de Engenharia Mecânica, que compartilharam comigo os desafios e conquistas desta caminhada, e aos amigos do meu primeiro período de Engenharia Urbana que marcaram o início dessa trajetória acadêmica com apoio e amizade, deixo meu sincero reconhecimento.

Por fim, agradeço à Universidade Federal de Ouro Preto, instituição que possibilitou minha formação e crescimento pessoal e profissional. Sou grato por cada oportunidade, conhecimento e experiência proporcionados ao longo dessa jornada.

“A educação tem raízes amargas, mas os seus frutos são doces.”

Aristóteles

RESUMO

A adoção de novas tecnologias ou o aprimoramento das já existentes, por meio de pesquisas, tem se mostrado uma estratégia eficaz para que as indústrias aumentem sua produtividade, competitividade e reduzam custos operacionais. Neste contexto, o presente estudo propõe o desenvolvimento de um programa computacional para apoio à manutenção preventiva de britadores na indústria de mineração, utilizando técnicas de aprendizado de máquina (*Machine Learning*) implementadas na linguagem de programação Python. Trata-se de um estudo aplicado, de caráter exploratório e experimental, fundamentado em revisão bibliográfica e desenvolvimento prático de um sistema de apoio à decisão. O problema abordado refere-se à dificuldade de se realizar diagnósticos rápidos e confiáveis sobre o estado de operação de equipamentos críticos, como os britadores, cuja falha pode comprometer significativamente a produtividade da planta. A solução proposta baseia-se na coleta de dados operacionais reais, processamento das variáveis técnicas por meio das bibliotecas *Pandas* e *NumPy*, e aplicação do algoritmo *ExtraTreesClassifier*, da biblioteca *Scikit-learn*. O sistema foi treinado e demonstrou ser efetivo e com acurácia alta. Após o treinamento, o programa permite que o usuário insira novos dados para que o modelo realize a predição do status operacional do equipamento. Os resultados indicam que o sistema é eficaz na identificação de condições fora do padrão, contribuindo para a antecipação de falhas, otimização dos planos de manutenção e aumento da disponibilidade operacional. Conclui-se que o *Machine Learning* utilizando a linguagem Python contribui de forma eficaz para a manutenção preventiva de britadores. Representa um avanço significativo, é adaptável e de fácil implementação para as empresas do setor mineral.

Palavras-chave: Manutenção Preventiva. Mineração. Britadores. Python. Aprendizado de Máquina.

ABSTRACT

The adoption of new technologies or the improvement of existing ones through research has proven to be an effective strategy for industries to increase productivity, enhance competitiveness, and reduce operational costs. In this context, the present study proposes the development of a computational program to support the preventive maintenance of crushers in the mining industry, using Machine Learning techniques implemented in the Python programming language. This is an applied study, with an exploratory and experimental nature, based on bibliographic review and practical development of a decision support system. The addressed problem concerns the difficulty of performing fast and reliable diagnostics on the operational status of critical equipment, such as crushers, whose failure can significantly compromise plant productivity. The proposed solution is based on the collection of real operational data, processing of technical variables using the Pandas and NumPy libraries, and application of the ExtraTreesClassifier algorithm from the Scikit-learn library. The system was trained and proved to be effective and highly accurate. After training, the program allows the user to input new data so that the model can predict the operational status of the equipment. The results indicate that the system is effective in identifying out-of-standard conditions, contributing to the anticipation of failures, optimization of maintenance plans, and increased operational availability. It is concluded that Machine Learning using the Python programming language contributes effectively to the preventive maintenance of crushers. It represents a significant advancement, is adaptable, and is easily implementable for companies in the mineral sector.

Key-words: Preventive Maintenance. Mining. Crushers. Python. Machine Learning.

LISTA DE FIGURAS

Figura 1 - Etapas da metodologia.	17
Figura 2 - Fluxograma de funcionamento do programa.	22
Figura 3 - Escolha do período de verificação.	23
Figura 4 - Exemplo da coluna adicional "Status"	23
Figura 5 - Exemplo de treinamento do modelo <i>Machine Learning</i>	24
Figura 6 - Interface do terminal exibindo o processo de entrada de dados e o resultado da predição.....	26

LISTA DE TABELAS

Tabela 1 - Variáveis e Indicadores.....	18
---	----

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Formulação do Problema	1
1.2	Justificativa	4
1.3	Objetivos	4
1.3.1	Geral	4
1.3.2	Específicos	4
1.4	Estrutura do Trabalho	5
2	REVISÃO BIBLIOGRÁFICA	6
2.1	Manutenção.....	6
2.1.1	Manutenção preventiva.....	6
2.1.2	Manutenção preditiva.....	7
2.1.3	Manutenção corretiva.....	7
2.1.4	Planejamento e Controle da Manutenção – PCM.....	8
2.2	Equipamentos críticos utilizados no processo de mineração	8
2.2.1	Britadores	8
2.3	<i>Machine Learning</i>	10
2.4	Linguagem Python.....	10
2.4.1	Módulos do Python.....	11
3	METODOLOGIA	15
3.1	Tipos de pesquisa	15
3.2	Materiais e métodos	16
3.3	Variáveis e indicadores	17
3.4	Instrumentos de coleta de dados	19
3.5	Tabulação e análise de dados.....	19
3.6	Considerações finais	19
4	RESULTADOS E DISCUSSÕES	20
4.1	Seleção e caracterização dos equipamentos analisados	20
4.2	Desenvolvimento do programa em Python.....	21
4.2.1	Estrutura geral do programa	21
4.3	Funcionamento Detalhado do Programa.....	22
4.3.1	Etapa 1 – Escolha do Período de Verificação	23

4.3.2	Etapa 2 – Leitura da Planilha e Pré-processamento	23
4.3.3	Etapa 3 – Treinamento do Modelo de <i>Machine Learning</i>	24
4.3.4	Etapa 4 – Entrada dos Dados do Usuário e Predição do Resultado	25
4.4	Resultados Obtidos e Desempenho do Modelo	26
4.4.1	Acurácia do Modelo.....	27
4.4.2	Predições Realizadas.....	27
4.4.3	Interpretação dos Resultados	27
4.5	Vantagens, limitações e possíveis melhorias	27
5	CONCLUSÃO E RECOMENDAÇÕES.....	29
5.1	Conclusão.....	29
5.2	Recomendações.....	30
6	REFERÊNCIA BIBLIOGRÁFICA	31

1 INTRODUÇÃO

1.1 Formulação do Problema

A mineração desempenha um papel vital, tanto na economia brasileira, quanto na economia mundial. O setor mineral é um dos principais pilares da economia do Brasil, contribuindo significativamente para a geração de empregos, arrecadação de impostos e desenvolvimento socioeconômico do país (IBRAM, 2021).

A indústria da mineração desempenha um papel crucial na produção de recursos minerais essenciais para uma ampla gama de setores incluindo construção civil, indústria siderúrgica, energia, agricultura, entre outros. No entanto, para que a mineração seja realizada de forma eficiente e sustentável, é essencial considerar a importância dos equipamentos utilizados nesse setor. Os equipamentos desempenham um papel crucial em todas as etapas do processo de mineração, desde a extração até o beneficiamento dos minerais. Eles são responsáveis pela movimentação de materiais, transporte, britagem, classificação e outras operações fundamentais para a obtenção dos minerais desejados (HUSTRULID, 2001).

Os equipamentos utilizados na indústria de mineração são frequentemente submetidos a esforços intensos, operando geralmente em sua capacidade máxima de carga. Diante dessa realidade, é de extrema importância que os planos de manutenção desses equipamentos sejam cuidadosamente desenvolvidos, a fim de evitar interrupções não programadas na produção e o desgaste prematuro de seus componentes (SUZUKI, 2013).

A manutenção é um processo crítico que está incluído na área de engenharia. Conforme a Associação Brasileira de Normas Técnicas (ABNT), por meio da NBR 5674 de 1999, define a manutenção como um conjunto de ações que visam manter ou restabelecer um item em condições adequadas de funcionamento, conforme suas características originais. A norma estabelece diretrizes para a elaboração de um plano de manutenção, o qual deve contemplar ações preventivas, corretivas e preditivas.

Segundo Xenos (2014), as atividades de manutenção devem ter uma abrangência que vai além da simples preservação das condições originais dos equipamentos. É importante reconhecer que, muitas vezes, apenas manter essas condições é insuficiente, e os departamentos de manutenção devem também se envolver na introdução de melhorias que visam aumentar a produtividade. Nesse sentido, as atividades de manutenção em qualquer empresa podem ser divididas em dois tipos: as atividades de manutenção em si e as atividades de melhoria.

Conforme Kardec (2012), são reconhecidos 6 tipos de manutenção. São elas: a corretiva não planejada, a corretiva planejada, a preventiva, preditiva, a detectiva e a engenharia de manutenção.

Dentre as estratégias de manutenção, destaca-se a manutenção preventiva. Conforme Xenos (2014), a manutenção preventiva desempenha um papel fundamental nas empresas, sendo considerada a atividade principal de manutenção. A manutenção preventiva consiste na realização periódica de tarefas sistemáticas, como inspeções, reformas e trocas de peças, visando evitar falhas e prolongar a vida útil dos equipamentos. Embora possa apresentar um custo inicial maior, a manutenção preventiva traz consigo benefícios significativos.

Os equipamentos críticos são aqueles cuja falha pode levar a paradas significativas na produção ou a consequências graves em termos de segurança e impacto ambiental. Conforme indicado por Smith e Hinchcliffe (2004), a seleção destes equipamentos envolve análises de confiabilidade e impacto, considerando fatores como frequência de falhas, tempo de reparo e consequências de falhas operacionais. Na mineração, esses equipamentos incluem, por exemplo, transportadores de correia, moinhos, bombas de lama e britadores. A manutenção preventiva nesses equipamentos é essencial para garantir a eficiência e segurança das operações.

Britadores são equipamentos cruciais na mineração, essenciais no processo de fragmentação de minérios. Lindqvist e Evertsson (2003) enfatizam a importância da manutenção preventiva destes equipamentos para evitar falhas que possam interromper a produção. A manutenção regular, incluindo a substituição de peças e a lubrificação, é fundamental para a eficiência e sustentabilidade operacional. Evertsson (2000) destaca em seu estudo sobre a performance de britadores cônicos, que a otimização desses equipamentos melhora não apenas a produtividade, mas também a qualidade do produto final. Portanto, a atenção aos britadores é essencial para o sucesso da mineração.

O desenvolvimento acelerado de novas tecnologias tem o potencial de promover mudanças em toda a indústria, inclusive nos setores de mineração, considerados tradicionais (CARVALHO *et al.*, 2016). Esses setores encontram-se diante de pressões de mercado, pressões ambientais e desafios relacionados à incorporação de conhecimento e tecnologia. Espera-se, nos próximos anos, a elevação do conteúdo tecnológico aplicado a processos mais sustentáveis e produtos de alto desempenho para o atendimento a novos mercados.

Para Rezende *et al.* (1999), um programa de aprendizado baseia suas decisões em dados acumulados a partir de soluções bem-sucedidas de problemas anteriores. Atualmente, é evidente a crescente adoção de novas tecnologias, como *Business Intelligence* (BI), *Machine Learning* e programação, no sistema de produção e manutenção. Essas tecnologias têm desempenhado um papel crucial na tomada de decisão, permitindo uma análise mais precisa e ágil dos dados operacionais.

De acordo com Monard e Baranauskas (2003), um sistema de aprendizado é um programa de computador que utiliza experiências acumuladas por meio da solução bem-sucedida de problemas anteriores para tomar decisões. Esses sistemas são construídos com o objetivo de adquirir conhecimento automaticamente por meio de técnicas computacionais de aprendizado de máquina.

Para Mitchell (1997), o *Machine Learning* é altamente eficaz quando utilizado em conjunto com uma linguagem de programação. A combinação dessas duas ferramentas permite a implementação de algoritmos de aprendizado de máquina de maneira eficiente e acessível possibilitando a análise e extração de conhecimento a partir de grandes volumes de dados.

Na visão de Borges (2014), a linguagem de programação Python possui uma excelente aplicabilidade em programas de *Machine Learning*. Sua linguagem clara e concisa permite a leitura e compreensão eficiente do código-fonte, resultando em maior produtividade na implementação de algoritmos de aprendizado de máquina.

Diante do exposto pode-se inferir que o desenvolvimento de programas para tomadas de decisão é de suma importância para a manutenibilidade dos equipamentos.

Levando em consideração o contexto apresentado, a pergunta-problema do estudo é:

Como um programa de *Machine Learning* na linguagem Python pode contribuir para o processo de manutenção preventiva de britadores nas indústrias de mineração?

1.2 Justificativa

A adoção dessa abordagem tecnológica representa um avanço significativo, alinhado com as inovações da Indústria 4.0. O uso de tecnologias avançadas, como *Machine Learning*, possibilita a melhoria dos processos de manutenção preventiva permitindo a detecção precoce de possíveis problemas e a otimização dos intervalos de manutenção. Isso resulta em redução de custos operacionais, aumento da disponibilidade dos equipamentos, minimização de impactos ambientais e melhoria da eficiência global das operações.

As aplicações práticas utilizando programas de *Machine Learning* na manutenção preventiva de equipamentos demonstram os benefícios alcançados, como a redução de paradas não programadas e a maximização da produtividade (PEREIRA, 2022). Portanto, o desenvolvimento de um programa específico para a manutenção preventiva de equipamentos críticos na mineração, utilizando *Machine Learning* por meio da linguagem Python, apresenta-se como uma oportunidade para aprimorar os processos de manutenção e melhorar a eficácia das operações nas indústrias de mineração.

Portanto, esta pesquisa propõe o estudo de uma solução que contribui para a prevenção de falhas e a redução de custos gerando o aumento da eficiência e eficácia operacional.

1.3 Objetivos

1.3.1 Geral

Desenvolver um programa para melhorar a execução do plano de manutenção preventiva dos britadores na indústria de mineração utilizando o *Machine Learning* na linguagem Python.

1.3.2 Específicos

- Realizar fundamentação teórica sobre manutenção, processos de manutenção, equipamentos críticos utilizados na mineração, *Machine Learning* e Linguagem Python;
- Identificar dentro do processo de manutenção preventiva os parâmetros controláveis do equipamento crítico, britador, para a montagem do *data frame*;

- Desenvolver o algoritmo utilizando a biblioteca da linguagem Python e *Machine Learning*;
- Efetuar testes para verificar a acurácia do programa;
- Demonstrar vantagens e desvantagens da utilização do programa *Machine Learning* em linguagem Python para manutenção preventiva dos equipamentos críticos.

1.4 Estrutura do Trabalho

O trabalho está organizado em cinco capítulos. O primeiro capítulo aborda a introdução, incluindo a formulação do problema, a justificativa, os objetivos gerais e específicos, além da estrutura do trabalho. Em seguida, o segundo capítulo explora o embasamento teórico, abordando os fundamentos dos britadores, manutenção, *Machine Learning* e Python. Depois disso, o terceiro capítulo descreve a metodologia utilizada no estudo e no desenvolvimento do programa. Já o quarto capítulo apresenta os resultados e discussões das análises realizadas, bem como as vantagens e desvantagens identificadas. Por fim, o quinto capítulo traz as conclusões do estudo.

2 REVISÃO BIBLIOGRÁFICA

2.1 Manutenção

A manutenção, em seu contexto mais amplo, é um conjunto de ações que visam preservar ou restaurar a capacidade de um equipamento ou sistema, garantindo sua disponibilidade e confiabilidade (SLACK, *et al.* 2010). Esta atividade é fundamental em diversos setores industriais, pois influencia diretamente a eficiência operacional, segurança e qualidade dos processos. A abordagem estratégica para a manutenção, conforme discutido por Tsang (2002), envolve a identificação de práticas ótimas que equilibram custos, desempenho e riscos.

Conforme Schonberger (1986), a manutenção eficaz também está intrinsecamente ligada à melhoria contínua dos processos, contribuindo para a competitividade e sustentabilidade das organizações. A evolução da manutenção ao longo do tempo, integrando abordagens tradicionais e tecnologias avançadas, reflete a crescente complexidade e exigências dos sistemas produtivos modernos.

É crucial que as intervenções sejam realizadas de forma eficiente e ágil. Pinto e Nascif (2001) destacam a importância de reparos rápidos e efetivos em equipamentos, visando minimizar o risco de falhas futuras. Estas ações são essenciais não apenas para manter o funcionamento adequado dos equipamentos, mas também para prevenir interrupções inesperadas, que podem comprometer a confiabilidade dos sistemas.

Moubray (1992), por sua vez, define manutenção como um conjunto de técnicas destinadas a garantir que os ativos físicos de uma empresa, como equipamentos e máquinas, continuem a operar conforme o desempenho e as funções exigidos. O autor enfatiza ainda a relevância do conhecimento profundo dos colaboradores sobre as máquinas que operam. Este entendimento é vital para evitar que os equipamentos sejam submetidos a demandas além de suas capacidades projetadas reduzindo assim o risco de falhas.

2.1.1 Manutenção preventiva

Segundo Swanson (2001), a manutenção preventiva é uma abordagem proativa que se concentra na execução de tarefas de manutenção em intervalos regulares, independentemente do estado atual dos equipamentos. O objetivo é prevenir falhas antes que ocorram, o que é especialmente crucial para equipamentos críticos. Moubray (1997) realça que essa estratégia é

baseada na teoria de que a maioria das falhas é previsível e pode ser evitada com inspeções e reparos periódicos.

A implementação efetiva da manutenção preventiva, segundo Gits (1992), exige um planejamento cuidadoso e um entendimento detalhado do comportamento dos equipamentos ao longo do tempo. Isso inclui a análise de dados históricos e a aplicação de técnicas estatísticas para determinar os intervalos ótimos de manutenção equilibrando custos e riscos de falha.

Keller e Owen (2025) destacam, com base em análise de custo-benefício, que a adoção de estratégias preventivas resulta em ganhos financeiros e operacionais significativos. Esses autores reforçam a importância da manutenção preventiva como ferramenta de gestão industrial, ao evidenciarem sua contribuição na redução de paradas não planejadas, no aumento da vida útil dos equipamentos e na melhoria da produtividade organizacional.

2.1.2 Manutenção preditiva

A manutenção preditiva difere da preventiva por focar na condição real do equipamento para determinar a necessidade de manutenção (MOBLEY, 2002). Esta abordagem utiliza tecnologias avançadas de monitoramento, como a análise de vibrações e termografia, para identificar sinais de deterioração antes que falhas ocorram. Pintelon e Parodi-Herz (2008) enfatizam que a manutenção preditiva permite uma intervenção mais precisa e menos disruptiva.

Como observado por Tsang (2004), a implementação bem-sucedida da manutenção preditiva, requer um investimento significativo em tecnologia e treinamento, além de uma integração estreita com os sistemas de informação da empresa. Isso permite uma análise aprofundada e contínua dos dados operacionais, facilitando a tomada de decisão baseada em evidências.

2.1.3 Manutenção corretiva

Conforme definido por Higgins & Mobley (2002) é realizada após a ocorrência de uma falha, visando restaurar um equipamento ao seu estado normal de operação. Esta forma de manutenção pode ser tanto uma atividade planejada, como uma resposta a falhas iminentes identificadas, quanto uma reação a falhas inesperadas. Keeney (2004) salienta que, embora seja

uma parte inevitável de qualquer programa de manutenção, a dependência excessiva na manutenção corretiva pode ser um indicativo de falhas nos processos de manutenção preventiva e preditiva.

A gestão eficaz da manutenção corretiva, segundo Nakajima (1988), requer um sistema robusto para diagnóstico rápido de problemas e alocação eficiente de recursos. Isso minimiza o tempo de inatividade e maximiza a eficiência na resolução de problemas, sendo fundamental para manter a continuidade das operações em ambientes industriais.

2.1.4 Planejamento e Controle da Manutenção – PCM

O Planejamento e Controle da Manutenção (PCM) é um aspecto crítico na gestão de manutenção, como discutido por Duffuaa, *et al.* (1999). O PCM abrange a programação de atividades de manutenção, alocação de recursos, coordenação com as operações de produção e monitoramento do desempenho da manutenção. Wireman (2007) afirma que um PCM eficiente não apenas otimiza a utilização dos recursos, mas também melhora a confiabilidade e a segurança dos equipamentos.

Conforme destacado por Kelly (2006), o PCM desempenha um papel vital na redução de custos operacionais e na melhoria da qualidade do produto. A integração eficaz do PCM com outros sistemas de gestão empresarial, como a gestão da qualidade e gestão ambiental, é fundamental para alcançar a excelência operacional.

É importante ressaltar que o Planejamento e Controle da Manutenção (PCM) desempenha um papel crucial em diversos níveis da gestão de manutenção. Ele abrange tarefas tanto estratégicas, táticas quanto operacionais, todas voltadas para a otimização da administração da manutenção. Essas atividades visam aprimorar a qualidade dos processos e aumentar a confiabilidade, disponibilidade e desempenho dos ativos (FERREIRA, 2021).

2.2 Equipamentos críticos utilizados no processo de mineração

2.2.1 Britadores

Na etapa inicial da produção de britas, o processo se inicia com a detonação da rocha bruta por meio de explosivos. Em seguida, a rocha fragmentada é transportada para a central de

britagem, composta por uma calha vibradora e um britador (QUARESMA, 2009). O britador é um equipamento que realiza a redução grosseira de sólidos, como materiais rochosos, carvão e vidro, existindo vários tipos, como os de rolo, mandíbulas, giratório, impacto, cônico e martelo (AZEVEDO, *et al.* 2021).

Esses britadores são fundamentais na redução do tamanho de rochas e pedras, sendo empregados na produção de agregados, reciclagem de materiais de construção e em operações de mineração (BASTOS, 2015). Contudo, devido à diversidade físico-química entre os minérios e à busca constante por eficiência e redução de custos, o mercado mineral oferece hoje uma ampla gama de opções de britadores para atender às diferentes demandas.

Os britadores de rolo desempenham um papel crucial na britagem secundária, especialmente em minérios com baixa abrasividade. Eles são valorizados pela sua capacidade de gerar um produto com distribuição granulométrica uniforme e baixo consumo energético (WILLS e FINCH, 2016). Este tipo de britador é eficaz na redução de materiais a tamanhos intermediários e é especialmente útil quando se lida com materiais friáveis. Além disso, a sua capacidade de lidar com variações na dureza do material o torna adaptável a diferentes tipos de operações de mineração (WILLS e FINCH, 2016).

Como abordado por Napier-Munn *et al.* (1996), os britadores de mandíbulas são notáveis pela sua eficiência na primeira fase de britagem, lidando com rochas duras e grandes blocos. Estes britadores operam com uma ação de compressão reduzindo o material entre uma mandíbula fixa e uma móvel. A durabilidade e a eficiência operacional fazem deles uma escolha primária para operações de britagem iniciais, especialmente onde o desgaste é uma preocupação significativa (NAPIER-MUNN *et al.*, 1996).

Por fim, os britadores cônicos são preferidos para aplicações de britagem fina e são conhecidos pela sua capacidade de produzir produtos finais com boa forma e alta qualidade (EVERTSSON, 2000). Eles são particularmente úteis em estágios secundários e terciários de britagem, adaptando-se bem à variação nas características do material de alimentação. O design destes britadores permite uma distribuição de tamanho de produto mais uniforme e uma maior capacidade de processamento, comparado a outros tipos de britadores (EVERTSSON, 2000).

2.3 *Machine Learning*

Machine Learning (ML) é uma das áreas mais proeminentes e em rápida evolução dentro do campo da inteligência artificial. Conforme Alpaydin (2020), ML é definido como a habilidade de sistemas computacionais aprenderem e se adaptarem a novas situações sem intervenção humana explícita. Esta capacidade é alcançada através de algoritmos que podem processar e aprender com grandes conjuntos de dados, permitindo a automatização de decisões e previsões. Goodfellow, Bengio e Courville (2016) descrevem o ML como fundamental para resolver problemas complexos em diversos domínios, desde reconhecimento de padrões até análise preditiva.

O desenvolvimento do ML tem sido impulsionado pelo aumento massivo de dados disponíveis e avanços no poder computacional. Segundo Jordan e Mitchell (2015), a evolução do ML tem transitado de modelos mais simples, como árvores de decisão e máquinas de vetores de suporte, para técnicas mais complexas, como redes neurais profundas. Essa evolução permitiu aplicações revolucionárias em áreas como processamento de linguagem natural, visão computacional e sistemas autônomos.

Desafios éticos e de governança também são pontos de discussão no campo do ML. Russel e Norvig (2016) enfatizam a importância da ética na implementação de algoritmos de ML, destacando questões como viés de dados e privacidade. O rápido crescimento desta área exige uma constante avaliação dos impactos sociais e éticos das tecnologias desenvolvidas.

2.4 **Linguagem Python**

Segundo Van Rossum e Drake (2009), o Python foi projetado para ser facilmente compreensível, favorecendo uma curva de aprendizado suave e uma vasta aplicabilidade. Sua natureza interpretada e sua ampla biblioteca padrão o tornam uma escolha popular para desenvolvedores em diversas áreas, incluindo desenvolvimento web, automação de tarefas e análise de dados (LUTZ, 2013).

A popularidade do Python também se deve à sua comunidade ativa e ao ecossistema de módulos e frameworks. Summers (2009) destaca que essa riqueza de recursos e a capacidade de integração com outras linguagens e ferramentas expandem seu uso além dos limites convencionais da programação. Esse aspecto colaborativo e expansivo torna o Python particularmente adaptável a novas tendências e demandas do mercado.

Em particular, o Python se estabeleceu como uma linguagem fundamental no campo da ciência de dados e do *Machine Learning*. A facilidade de uso, juntamente com uma rica coleção de bibliotecas dedicadas a estas áreas, torna-o uma ferramenta essencial para cientistas de dados e pesquisadores (MCKINNEY, 2012).

2.4.1 Módulos do Python

De acordo com Borges (2014), os módulos em Python são definidos como arquivos-fonte que podem ser integrados a um programa por meio da importação. Esses módulos, que incorporam a estrutura da linguagem Python, são executados no momento em que são importados para o programa. Uma vez importados, os módulos são compilados e armazenados em arquivos com extensões `.pyc` ou `.pyo` e cada um deles possui um namespace distinto.

Conforme explicado por Coelho (2007), os módulos em Python correspondem a arquivos codificados nesta linguagem, projetados especificamente para serem importados. Sob a ótica do interpretador Python, qualquer arquivo que apresente a terminação `.py` é reconhecido como um módulo. Essa característica é fundamental para a modularidade e reutilização de código em projetos de *software* desenvolvidos em Python.

2.4.1.1 Pandas

Pandas é uma biblioteca de software de código aberto em Python, desenvolvida por Wes McKinney (2012), projetada para análise e manipulação de dados. Este módulo é amplamente reconhecido por sua capacidade de fornecer estruturas de dados rápidas, flexíveis e expressivas, destinadas a tornar o trabalho com dados “relacionais” ou “rotulados” intuitivo e fácil. McKinney (2012) salienta a importância do Pandas no fornecimento de ferramentas essenciais para a limpeza e transformação de dados fundamentais em análises de dados e ciência de dados.

A biblioteca Pandas é especialmente conhecida por suas estruturas de dados `DataFrame` e `Series`, que permitem a manipulação de dados tabulares de maneira eficiente e intuitiva. Grus (2015) destaca que essas estruturas oferecem funcionalidades robustas para indexação, alinhamento e tratamento de dados faltantes facilitando o gerenciamento de dados complexos.

Além disso, Pandas integra-se perfeitamente com outras bibliotecas de ciência de dados em Python, como NumPy e Matplotlib, permitindo uma análise de dados abrangente e

visualização eficiente. A interoperabilidade com outras ferramentas amplia seu uso em diversas áreas, desde a análise financeira até a bioinformática (MCKINNEY, 2012).

2.4.1.2 NumPy

O NumPy, uma biblioteca fundamental para a computação científica dentro da linguagem Python, é central para o trabalho com *arrays* multidimensionais. Oliphant (2006), um dos principais contribuidores do NumPy, descreve-o como uma biblioteca que fornece objetos de *array* poderosos e ferramentas para trabalhar com esses arrays. Seu desempenho otimizado e capacidades de manipulação de dados a tornam essencial para aplicações que requerem cálculos numéricos intensivos.

Além de sua eficiência em operações com arrays, NumPy é amplamente utilizado por fornecer uma ampla gama de funções matemáticas. Estas funções permitem operações complexas como transformadas de Fourier, álgebra linear e geração de números aleatórios, fundamentais em muitas áreas da ciência e engenharia (VANDERPLAS, 2016).

A compatibilidade do NumPy com outras bibliotecas, como Pandas e Matplotlib, e sua integração com linguagens de programação de baixo nível, como C e Fortran, reforçam seu papel como uma ferramenta indispensável no ecossistema de computação científica em Python (WALT, *et al.* 2011).

2.4.1.3 Array

Arrays são estruturas de dados fundamentais em Python usadas para armazenar coleções de itens geralmente de tipos semelhantes. De acordo com Downey (2015), *arrays* são úteis para a realização de operações matemáticas e lógicas em grandes conjuntos de dados de forma eficiente. Eles são especialmente importantes em contextos de computação científica e análise de dados quando o processamento de grandes volumes de dados é comum.

A eficácia dos *arrays* em Python é ampliada pelo uso de bibliotecas especializadas como *NumPy* que oferecem funcionalidades avançadas para manipulação de *arrays* multidimensionais. Oliphant (2006) argumenta que tais bibliotecas não apenas simplificam operações complexas, mas também melhoram significativamente o desempenho computacional, crucial em aplicações de alta performance.

A importância dos *arrays* estende-se além da manipulação de dados, desempenhando um papel vital em áreas como *Machine Learning* e processamento de imagens. *Arrays* fornecem uma maneira estruturada e eficiente de armazenar e manipular grandes conjuntos de dados facilitando a implementação de algoritmos complexos (MCKINNEY, 2012).

2.4.1.4 Scikit-Learn

Scikit-Learn, desenvolvido por Pedregosa *et al.* (2011), é uma biblioteca de *machine learning* para Python que se destaca pela sua acessibilidade e eficiência. A biblioteca é projetada para interoperar com as bibliotecas NumPy e Pandas oferecendo uma ampla gama de algoritmos de aprendizado supervisionado e não supervisionado, ferramentas para ajuste de modelos, pré-processamento de dados, seleção de modelos e avaliação.

A facilidade de uso e a diversidade de funcionalidades do Scikit-Learn o tornam uma ferramenta valiosa para profissionais e pesquisadores que trabalham com dados complexos e modelos de *machine learning*. Müller & Guido (2016) observam que a documentação abrangente e exemplos práticos facilitam a aplicação dessas técnicas em problemas do mundo real.

A constante atualização e aprimoramento da biblioteca, com contribuições da comunidade de código aberto, mantêm o *Scikit-Learn* na vanguarda das ferramentas de *Machine Learning*, adequando-se às tendências e desafios emergentes na área (PEDREGOSA *et al.*, 2011). O compromisso da comunidade com a qualidade e a usabilidade torna o *Scikit-Learn* uma escolha confiável para a implementação de soluções de *machine learning*, desde análises exploratórias até a implementação de sistemas complexos de aprendizado de máquina.

Neste capítulo observa-se que a compreensão aprofundada dos conceitos de manutenção, dos equipamentos críticos no processo de mineração e das ferramentas tecnológicas associadas ao *Machine Learning* e à linguagem Python constitui um alicerce essencial para o desenvolvimento de soluções inovadoras na gestão de ativos industriais. A integração entre práticas de manutenção bem estruturadas, conhecimento técnico sobre os equipamentos e a aplicação de técnicas avançadas de análise de dados potencializa a eficiência operacional, reduz custos e amplia a confiabilidade dos sistemas produtivos. Assim, o embasamento teórico apresentado neste capítulo fornece suporte sólido para a metodologia

adotada neste trabalho, permitindo a aplicação prática dos conceitos e ferramentas discutidos na busca por melhorias significativas nos processos de manutenção preventiva e preditiva.

3 METODOLOGIA

3.1 Tipos de pesquisa

De acordo com Gil (2008), a pesquisa é um processo sistemático e formal de desenvolver o método científico, cujo objetivo primordial é a descoberta de respostas para problemas por meio de procedimentos científicos. Creswell (2014) descreve a pesquisa como um empreendimento intelectual, que não apenas abrange a coleta de dados, mas também envolve a análise e interpretação dos mesmos em um contexto de questionamento crítico e reflexivo. Este aspecto reflete a natureza dinâmica da pesquisa em sua busca por compreender e interpretar a realidade.

As abordagens de pesquisa são comumente divididas em quantitativa e qualitativa. Segundo Bryman (2012), a pesquisa quantitativa enfatiza o raciocínio dedutivo, as regras de lógica e a mensuração objetiva de variáveis. Gil (2008) reforça que, por meio de testes estatísticos, esta abordagem quantitativa permite determinar a probabilidade e a precisão dos resultados obtidos, fundamentais para conclusões científicas.

Por outro lado, a pesquisa qualitativa, conforme descrito por Oliveira (2011), fundamenta-se na compreensão dos fenômenos dentro de seus contextos naturais. Denzin e Lincoln (2011) argumentam que esta abordagem se concentra mais na descrição e na compreensão das complexidades dos fenômenos, sem depender de medidas numéricas.

Gil (2008) classifica os objetivos das pesquisas em exploratórias, descritivas e explicativas. A pesquisa exploratória, como descreve, visa ao desenvolvimento, esclarecimento e modificação de conceitos e ideias, para a formulação de hipóteses mais precisas em estudos futuros. Técnicas como revisões bibliográficas e entrevistas não padronizadas são comuns nessa abordagem.

Em contrapartida, a pesquisa descritiva foca na caracterização de fenômenos ou populações e no estabelecimento de relações entre variáveis, frequentemente utilizando métodos padronizados de coleta de dados, como questionários e observações sistemáticas (GIL, 2008).

Finalmente, as pesquisas explicativas, segundo Lakatos e Marconi (2011), são baseadas em experimentos e dedicam-se a identificar os fatores que influenciam a ocorrência de fenômenos. Este tipo de pesquisa utiliza-se de registros detalhados, análises e interpretações para esclarecer as causas dos fenômenos estudados.

Considerando as abordagens apresentadas, este trabalho enquadra-se no caráter qualitativo, uma vez que não se baseia em métodos estatísticos para o desenvolvimento do programa. Além disso, pode ser classificado como exploratório, bibliográfico e experimental, dada a sua investigação sobre o desenvolvimento de programa em *machine learning* utilizando a linguagem Python.

3.2 Materiais e métodos

Para a realização desta pesquisa, foram empregados diversos materiais, incluindo o Manual Técnico da Metso, livros, artigos acadêmicos, dissertações e monografias.

A abordagem metodológica adotada caracteriza-se como métodos tecnológicos de inteligência artificial, com ênfase em aprendizado de máquina (*machine learning*), utilizando a linguagem de programação Python e suas bibliotecas relevantes. Dentre essas, destaca-se o Scikit-learn, biblioteca voltada especificamente para aplicações de *machine learning*, além do Pandas e NumPy, utilizadas para manipulação e análise de dados. Além disso, para o processamento de dados e documentação, empregou-se o pacote Office, com foco no Excel e no Word. A metodologia também envolveu pesquisa de campo, na qual foram realizadas coletas de dados para alimentar e testar os algoritmos desenvolvidos.

As etapas metodológicas estão representadas de forma esquemática na Figura 1, que resume o percurso adotado na realização desta pesquisa. A figura ilustra, em sete passos, a sequência de atividades que compreendem desde o estudo teórico e definição do equipamento crítico até o desenvolvimento, aplicação e avaliação de um programa computacional em Python voltado à manutenção preventiva. Tal representação gráfica visa facilitar a compreensão do processo metodológico adotado evidenciando a integração entre a revisão bibliográfica, a coleta de dados práticos e a aplicação de técnicas de *machine learning*.

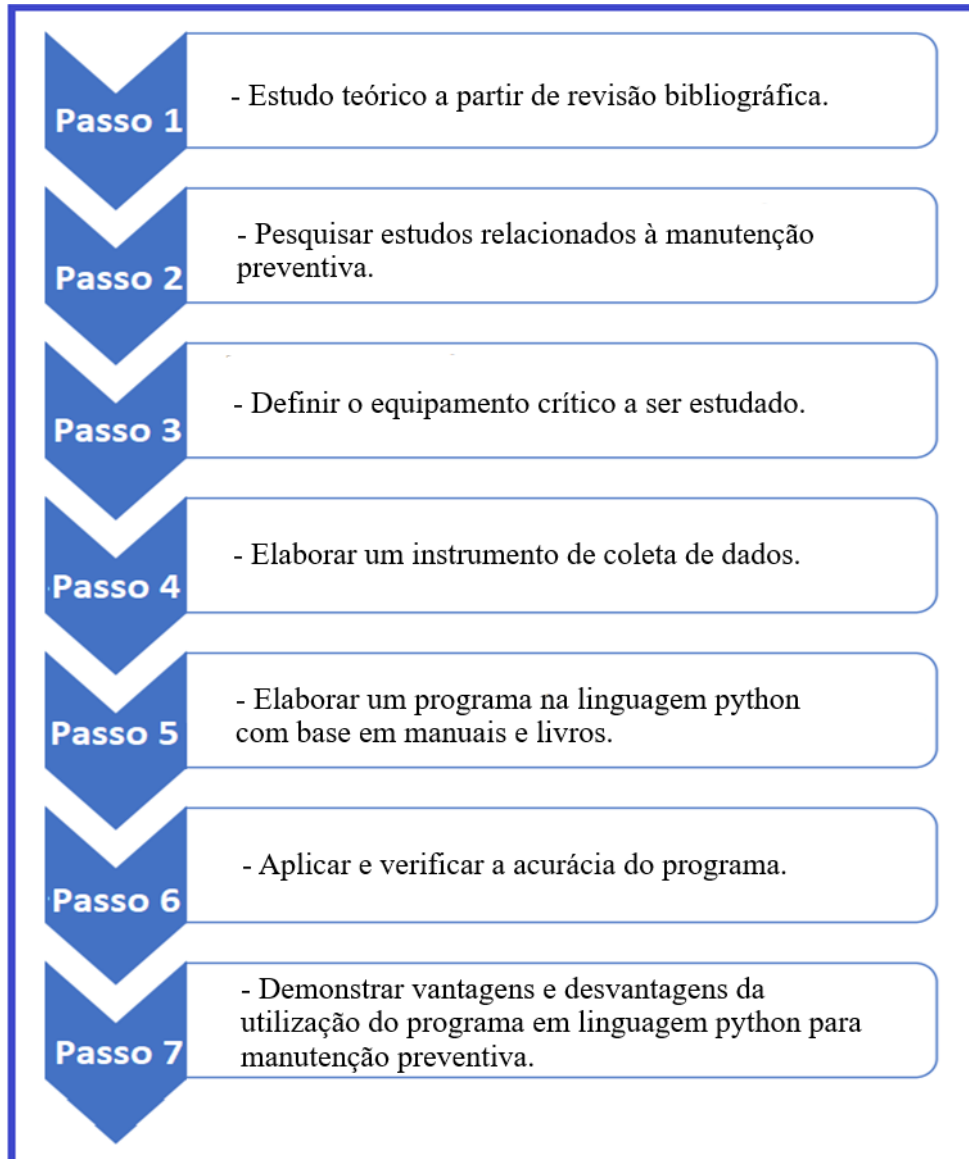


Figura 1 - Etapas da metodologia
Fonte: Pesquisa direta (2024)

3.3 Variáveis e indicadores

Para Gil (2008), o conceito de variável abrange diferentes aspectos e valores, modificando-se conforme as circunstâncias e casos específicos. As variáveis podem ser classificadas em dois grandes grupos: qualitativas, que se referem a qualidades e são expressas por atributos ou categorias, e quantitativas, que são mensuráveis e expressas numericamente (CRESWELL, 2014). Essa distinção é fundamental na pesquisa científica, pois orienta a escolha de métodos de coleta e análise de dados apropriados para cada tipo de variável.

Conforme apontam Tadachi e Flores (1997), os indicadores consistem em instrumentos que permitem expressar, de maneira mensurável, características relacionadas a produtos e

processos. Sua aplicação é recorrente nas organizações, visando monitorar e aprimorar continuamente a qualidade e a eficiência dos produtos ao longo do tempo. Gil (2008) acrescenta que os indicadores têm a função de quantificar variáveis, facilitando o acompanhamento e o controle dos resultados, de modo a torná-los claros e de fácil interpretação.

Na tabela 1 é possível observar as variáveis do estudo e seus respectivos indicadores, que posteriormente serão analisados de forma binária.

Tabela 1 - Variáveis e Indicadores

Variáveis	Indicadores
Britador x	Nível do Tanque do Óleo
Britador y	Temperaturas de Entrada e Saída do Óleo
Britador z	Pressão de Óleo na Carcaça
	Pressão Diferencial do Filtro de Óleo
	Pressão na Cavidade e Nível de Força
	Ajuste do Fechamento Lateral
	Pressão de Trava
	Pressão de Alívio da Cavidade
	Distribuição de Alimentação
	Revestimento e Cobertura do Contrapeso contra Desgaste
	Limpeza da Área de Descarga do Britador e Braços
	Tempo de Encosto Inferior
	Verificação de Fixações e Conexões
	Detecção de Ruídos Anormais, Desgaste ou Forças Irregulares
	Desgaste e Estado dos Revestimentos do Britador (Manta e Bojo)
	Movimento do Anel de Ajuste
	Fluxo de Óleo e Manutenção da Cesta do Filtro

Fonte: Pesquisa direta (2024)

3.4 Instrumentos de coleta de dados

Os métodos de coleta de dados empregados nesta pesquisa incluíram uma abordagem de pesquisa de campo. Para a organização e análise dos dados coletados, foi utilizado um questionário estruturado, desenvolvido e implementado no Excel. Este procedimento permitiu a sistematização eficiente das informações obtidas, facilitando a análise subsequente e a interpretação dos resultados.

3.5 Tabulação e análise de dados

A tabulação dos dados coletados foi realizada utilizando o pacote Microsoft Office, com ênfase nas ferramentas Word e Excel. A análise desses dados foi conduzida após a obtenção dos resultados do código e dos testes, utilizando o algoritmo que será desenvolvido para este propósito.

3.6 Considerações finais

O Capítulo 3 deste trabalho detalhou a metodologia adotada, incluindo o tipo de pesquisa realizada, as variáveis e indicadores usados, os métodos de coleta de dados, e os softwares empregados no estudo. Além disso, foram descritos os processos de coleta e análise de dados.

No próximo capítulo serão apresentados os resultados obtidos e discutidos enfocando as análises realizadas no programa desenvolvido. Também serão exploradas as vantagens e limitações do programa utilizado na manutenção preventiva de britadores.

4 RESULTADOS E DISCUSSÕES

Este capítulo descreve detalhadamente todas as etapas do desenvolvimento do programa proposto, desde a seleção dos equipamentos e indicadores da manutenção preventiva, estruturação e tratamento dos dados, até o teste do algoritmo de aprendizado de máquina e análise dos resultados. A elaboração deste capítulo busca demonstrar como os objetivos propostos neste trabalho foram alcançados, conforme definido no item 1.3.

Dentre os objetivos específicos listados, este capítulo evidencia: a identificação dos parâmetros controláveis dos britadores, a organização e estruturação do banco de dados, o desenvolvimento do algoritmo utilizando bibliotecas da linguagem Python com técnicas de *Machine Learning*, a realização de testes para verificação da acurácia do modelo e a análise das vantagens e limitações do sistema.

4.1 Seleção e caracterização dos equipamentos analisados

O presente trabalho tem como foco o desenvolvimento de um sistema computacional utilizando algoritmos de aprendizado de máquina para auxiliar na manutenção preventiva de equipamentos industriais. Para tanto, foi necessário selecionar um tipo de equipamento de alta criticidade para o sistema produtivo, frequência de falhas e possibilidade de monitoramento de parâmetros que indiquem desgaste ou anomalias funcionais. Dentre os diversos equipamentos presentes em plantas industriais, optou-se pelos britadores utilizados na indústria mineral.

Os britadores são equipamentos essenciais no processo de fragmentação de minérios, sendo responsáveis pela redução granulométrica de materiais extraídos. Estão presentes nas etapas iniciais do beneficiamento mineral, e sua correta operação tem impacto direto na produtividade da planta, no consumo energético e na eficiência global do processo. Por serem submetidos a condições severas de trabalho, como alto impacto mecânico, abrasividade dos materiais e operação contínua, esses equipamentos estão sujeitos a desgastes prematuros, falhas mecânicas e paradas não planejadas.

A seleção do britador como objeto de estudo justifica-se por diversas razões:

- **Criticidade operacional:** a falha de um britador pode comprometer toda a cadeia de produção, interrompendo o fluxo de matéria-prima para etapas subsequentes;

- **Elevado custo de manutenção:** intervenções corretivas nesses equipamentos envolvem substituição de componentes robustos, mão de obra especializada e tempo significativo de parada;
- **Potencial para aplicação de manutenção preditiva:** diversas variáveis podem ser monitoradas ao longo do tempo, como temperatura, vibração, pressão, consumo energético, folga de componentes e níveis de óleo lubrificante.

Dessa forma, a caracterização dos equipamentos analisados levou em conta parâmetros reais que são comumente utilizados no acompanhamento técnico dos britadores. As variáveis consideradas no banco de dados refletem condições operacionais típicas e foram padronizadas de modo a permitir a transformação dos dados brutos em algoritmo de *Machine Learning*.

4.2 Desenvolvimento do programa em Python

O programa criado tem como objetivo principal auxiliar na manutenção preventiva de britadores industriais, classificando automaticamente o status operacional do equipamento com base em parâmetros técnicos previamente definidos.

O código foi desenvolvido para operar em ambiente de linha de comando, de forma interativa, onde o usuário é orientado a seguir uma sequência lógica de passos, iniciando com a seleção do período de verificação desejado: diário (1), semanal (2), mensal (3) ou anual (4). Essa escolha determina qual aba da planilha será lida pelo código.

4.2.1 Estrutura geral do programa

O programa está dividido em cinco grandes blocos funcionais, descritos a seguir:

- **1. Seleção do período de análise:**

O usuário escolhe entre as quatro opções de periodicidade. Com base nisso, o programa carrega a aba correspondente da planilha Excel e direciona o fluxo para o método apropriado de pré-processamento.

- **2. Pré-processamento dos dados:**

O programa embaralha as linhas do conjunto de dados para evitar viés de ordenação e, no caso do modo “diário”, aplica transformações nas variáveis contínuas, convertendo-as em valores binários (0 ou 1) com base em faixas técnicas aceitáveis. Após isso, é

gerada uma nova coluna chamada “**Status**” que define se aquela entrada está “Conforme” ou “Não Conforme”.

- **3. Treinamento do modelo de *Machine Learning*:**

O algoritmo selecionado foi o *ExtraTreesClassifier*, pertencente à biblioteca *scikit-learn*, por sua robustez, capacidade de lidar com dados binários e bom desempenho em tarefas de classificação. Os dados são divididos em treino (70%) e teste (30%). O modelo é treinado repetidamente até atingir um valor mínimo de **acurácia de 90%**, garantindo um nível mínimo de confiabilidade antes da etapa de predição.

- **4. Entrada de dados pelo usuário:**

Após o treinamento bem-sucedido, o programa solicita ao usuário que insira os valores atuais dos parâmetros monitorados, com instruções claras baseadas nas faixas aceitáveis segundo o manual técnico do equipamento. Os dados digitados são convertidos automaticamente para binário e, em seguida, enviados ao modelo treinado para classificação.

- **5. Geração do resultado:**

Com base na entrada fornecida, o modelo realiza a predição e informa ao usuário o **status previsto do equipamento**, classificando como “Conforme” (caso os dados estejam dentro dos padrões) ou “Não Conforme” (caso alguma variável indique anomalia).



Figura 2 - Fluxograma de funcionamento do programa
Fonte: Pesquisa direta (2025)

4.3 Funcionamento Detalhado do Programa

Nesta seção, será apresentado um passo a passo detalhado da execução do programa desenvolvido em Python, desde a inicialização do script até a obtenção do status preditivo do equipamento. O objetivo é proporcionar uma visão clara e prática de como o sistema opera, reforçando sua aplicabilidade no processo de manutenção preventiva dos britadores.

4.3.1 Etapa 1 – Escolha do Período de Verificação

Ao iniciar o programa, o usuário é imediatamente solicitado a informar qual o período de verificação desejado. As opções disponíveis são: Diário (1), Semanal (2), Mensal (3), Anual (4).

O número digitado determina qual aba da planilha do *Data Frame* será utilizada.

```
import pandas as pd
Selecione o Período de Verificação que deseja (1 para diário, 2 para semanal, 3 para mensal, 4 para anual):
```

Figura 3 - Escolha do período de verificação.

Fonte: Pesquisa direta (2025)

4.3.2 Etapa 2 – Leitura da Planilha e Pré-processamento

Com o período definido, o programa acessa a aba correspondente do arquivo Excel. A estrutura da planilha contém colunas com variáveis técnicas como temperatura, pressão, nível de óleo, entre outros.

Como demonstrado na figura 4, o programa aplica faixas técnicas de referência (obtidas do manual do equipamento) para transformar os valores contínuos em valores binários (0 ou 1). Os dados são então randomizados para evitar viés no modelo de aprendizado. Em seguida, é gerada uma coluna adicional chamada "Status", que indica se a linha está "Conforme" ou "Não Conforme".

Britador	NO	TE	PO	PD	PC	AF	PA	PT	DA	LA	RC	TEI	VF	DR	DE	MA	FO	Status
BR 06	1	1	1.0	1.0	1	1	1	1	1	1	1	1	1	1	1	1	1	Conforme
BR 01	1	0	0.0	0.0	0	0	1	0	1	0	0	0	0	0	1	1	1	Não Conforme
BR 10	0	1	1.0	0.0	1	0	1	1	0	0	1	0	0	1	0	0	1	Não Conforme
BR 02	1	1	1.0	1.0	1	1	1	1	1	1	1	1	1	1	1	1	1	Conforme
BR 06	1	1	1.0	1.0	1	1	1	1	1	1	0	1	1	1	1	1	1	Não Conforme
BR 07	1	1	1.0	1.0	1	1	1	1	1	1	1	1	1	1	1	1	1	Conforme
BR 10	0	1	0.0	1.0	0	1	1	0	1	0	0	1	0	1	1	0	0	Não Conforme
BR 06	1	1	1.0	0.0	1	1	1	1	1	1	1	1	1	1	1	1	1	Não Conforme
BR 02	1	1	1.0	1.0	1	1	1	1	1	1	1	1	1	1	1	1	1	Conforme
BR 07	1	1	1.0	1.0	1	1	1	1	1	1	1	1	1	1	1	1	1	Conforme

Figura 4 - Exemplo da coluna adicional "Status"

Fonte: Pesquisa direta (2025)

A figura 4 apresenta o *data set* que foi utilizado no programa. Dessa forma, no período de verificação diário, os valores analisados pelo modelo incluem as seguintes variáveis operacionais: Nível do Reservatório de Óleo (NO), Temperaturas de Entrada e Saída do Óleo

(TE), Pressão de Óleo na Carcaça do Eixo (PO), Pressão Diferencial do Filtro de Óleo (PD), Pressão na Cavidade e Nível de Força (PC), Ajuste do Fechamento Lateral (AF), Pressão de Alívio na Cavidade (PA), Pressão de Trava (PT), Distribuição de Alimentação (DA), Limpeza da Área de Descarga do Britador e Braços (LA), Revestimento e Cobertura do Contrapeso contra Desgaste (RC), Tempo de Encosto Inferior (TEI), Verificação de Fixações e Conexões (VF), Detecção de Ruídos Anormais, Desgaste ou Forças Irregulares (DR), Desgaste e Estado dos Revestimentos do Britador (DE), Movimento do Anel de Ajuste (MA) e Fluxo de Óleo e Manutenção da Cesta do Filtro (FO). Esses dados operacionais são utilizados como entrada para o modelo com base nas faixas técnicas recomendadas pelo fabricante.

4.3.3 Etapa 3 – Treinamento do Modelo de *Machine Learning*

O algoritmo de aprendizado utilizado é o *ExtraTreesClassifier*, da biblioteca *scikit-learn*.

O modelo é treinado com 70% dos dados e os 30% restantes são utilizados para teste. O programa realiza o treinamento repetidamente até atingir pelo menos 90% de acurácia, garantindo confiabilidade nos resultados.

Durante essa etapa, o terminal exibe a evolução da acurácia a cada tentativa, informando o usuário sobre o progresso do treinamento, conforme demonstra a figura 5.

```

Selecione o Período de Verificação que deseja (1 para diário, 2 para semanal, 3 para mensal, 4 para anual): 1
Acurácia do modelo: 0.8974358974358975
A acurácia do modelo é menor que 0.9. Treinando o modelo novamente...
Acurácia do modelo: 0.8717948717948718
A acurácia do modelo é menor que 0.9. Treinando o modelo novamente...
Acurácia do modelo: 0.8974358974358975
A acurácia do modelo é menor que 0.9. Treinando o modelo novamente...
Acurácia do modelo: 0.9230769230769231

```

Figura 5 - Exemplo de treinamento do modelo *Machine Learning*.
Fonte: Pesquisa direta (2025)

A Figura 5 apresenta o processo de treinamento do modelo de aprendizado de máquina na interface do programa. Nessa etapa, o algoritmo *ExtraTreesClassifier* é aplicado ao conjunto de dados, previamente dividido em subconjuntos de treino e teste, com o objetivo de classificar as condições operacionais dos britadores. O programa é projetado para repetir automaticamente o processo de treinamento até que a acurácia mínima de 90% seja alcançada, assegurando um nível satisfatório de confiabilidade nos resultados. Durante a execução, o terminal exibe a acurácia obtida em cada tentativa, informando o progresso ao usuário e indicando se o modelo já está apto para realizar predições. Essa abordagem visa garantir que o sistema opere de

maneira eficaz, minimizando a possibilidade de erros de classificação durante o diagnóstico das condições de operação dos equipamentos.

4.3.4 Etapa 4 – Entrada dos Dados do Usuário e Predição do Resultado

Após o modelo *Machine Learning* ser treinado com sucesso e atingir a acurácia mínima desejada (90%), o programa avança para a etapa em que o usuário deve inserir os valores reais dos parâmetros do britador que está sendo analisado. Nesse momento, o sistema solicita que o usuário digite os valores de cada variável monitorada. Para facilitar esse processo, o programa exibe orientações detalhadas sobre os limites considerados ideais para cada variável controlável, com base nas recomendações técnicas do fabricante (como temperatura entre 38 °C e 54 °C ou pressão de óleo igual a 300, por exemplo). Isso ajuda o operador a entender o que é esperado e evita erros durante o preenchimento.

Uma vez que todos os valores são inseridos, o programa transforma esses dados em uma sequência binária (0 ou 1), indicando se cada variável está ou não dentro da faixa considerada adequada. Essa conversão é importante porque o modelo foi treinado com dados binários e precisa que a entrada siga esse formato para funcionar corretamente.

Em seguida, o modelo realiza a predição: ele compara os dados inseridos com os padrões que aprendeu durante o treinamento e classifica o status do equipamento em “**Conforme**” ou “**Não Conforme**”. O resultado é exibido diretamente na tela para o usuário, permitindo uma análise rápida e objetiva da condição atual do britador.

Esse processo simula uma situação real em que o operador insere os dados medidos no campo e o sistema fornece um diagnóstico imediato auxiliando a equipe de manutenção a tomar decisões mais precisas e ágeis.

Para ilustrar esse processo, a figura 6 apresenta um exemplo de execução real do programa, em que os valores inseridos para cada variável foram todos dentro das faixas técnicas recomendadas e resultaram na classificação “Conforme”. Esse cenário representa uma condição operacional adequada do equipamento, sem indícios de desgaste ou anomalias.

```

Selecione o Período de Verificação que deseja (1 para diário, 2 para semanal, 3 para mensal, 4 para anual): 1
Acurácia do modelo: 0.8974358974358975
A acurácia do modelo é menor que 0.9. Treinando o modelo novamente...
Acurácia do modelo: 0.8717948717948718
A acurácia do modelo é menor que 0.9. Treinando o modelo novamente...
Acurácia do modelo: 0.8974358974358975
A acurácia do modelo é menor que 0.9. Treinando o modelo novamente...
Acurácia do modelo: 0.9230769230769231
Digite o valor para Nível do Reservatório de Óleo (0 ou 1): 1
Digite o valor para Temperaturas de Entrada e Saída do Óleo (O manual indica 38 a 54): 45
Digite o valor para Pressão de Óleo na Carcaça do Eixo (O manual indica 1.4 a 2.8): 1.6
Digite o valor para Pressão Diferencial do Filtro de Óleo (O manual indica 0.3 a 2.5): 0.5
Digite o valor para Pressão na Cavidade e Nível de Força (O manual indica 300): 300
Digite o valor para Ajuste do Fechamento Lateral (0 ou 1): 1
Digite o valor para Pressão de Alívio na Cavidade (0 ou 1): 1
Digite o valor para Pressão de Trava (O manual indica 165 a 193): 170
Digite o valor para Distribuição de Alimentação (0 ou 1): 1
Digite o valor para Limpeza da Área de Descarga do Britador e Braços (0 ou 1): 1
Digite o valor para Revestimento e Cobertura do Contrapeso contra Desgaste (0 ou 1): 1
Digite o valor para Tempo de Encosto Inferior (O manual indica 30 a 60): 33
Digite o valor para Verificação de Fixações e Conexões (0 ou 1): 1
Digite o valor para Detecção de Ruídos Anormais, Desgaste ou Forças Irregulares (0 ou 1): 1
Digite o valor para Desgaste e Estado dos Revestimentos do Britador (Manta e Bojo) (0 ou 1): 1
Digite o valor para Movimento do Anel de Ajuste (0 ou 1): 1
Digite o valor para Fluxo de Óleo e Manutenção da Cesta do Filtro (0 ou 1): 1
Status previsto do equipamento: Conforme

```

Figura 6 - Interface do terminal exibindo o processo de entrada de dados e o resultado da predição.
Fonte: Pesquisa direta (2025)

A Figura 6 ilustra a interface do programa durante a execução do programa desenvolvido, na etapa em que o usuário realiza a inserção dos dados operacionais do britador a ser avaliado. Neste momento, o sistema solicita que o operador informe os valores correspondentes a cada variável monitorada, apresentando orientações sobre os intervalos aceitáveis, conforme especificações técnicas do fabricante.

Uma vez concluída a inserção, o modelo de aprendizado de máquina, previamente treinado, realiza a predição do status operacional do equipamento. O resultado é imediatamente exibido no terminal, indicando se a condição atual é classificada como “Conforme” ou “Não Conforme”. Na situação apresentada na figura todos os parâmetros informados estavam dentro das faixas técnicas recomendadas resultando em uma classificação final “Conforme”. Essa funcionalidade permite uma análise objetiva e ágil da condição do equipamento contribuindo significativamente para o processo de tomada de decisão na manutenção preventiva.

4.4 Resultados Obtidos e Desempenho do Modelo

A partir da execução do programa desenvolvido, foram realizados diversos testes com as quatro abas da planilha Data Frame.xlsx, correspondentes aos períodos de verificação: **diário, semanal, mensal e anual**. O objetivo desses testes foi avaliar a eficácia do modelo de

classificação baseado em aprendizado de máquina para prever corretamente o status dos britadores com base em parâmetros operacionais.

4.4.1 Acurácia do Modelo

Para garantir confiabilidade, o modelo foi configurado para repetir automaticamente o treinamento até que a acurácia mínima de 90% fosse atingida. Esse critério foi adotado como um padrão de validação, alinhado às boas práticas de projetos com dados binários e classificação supervisionada.

4.4.2 Predições Realizadas

Com o modelo treinado, foram inseridos diferentes conjuntos de dados simulando condições reais dos britadores. A maioria dos testes com dados operacionais dentro dos limites resultou em classificações como “**Conforme**”, enquanto pequenas alterações nas faixas aceitáveis de variáveis como temperatura ou pressão já foram suficientes para indicar “**Não Conforme**”.

Isso mostra que o sistema é sensível a pequenas variações técnicas, o que é desejável em contextos industriais, que exigem alta confiabilidade para evitar falhas.

4.4.3 Interpretação dos Resultados

A abordagem utilizada para converter dados contínuos em valores binários com base em faixas técnicas foi essencial para a correta classificação. O algoritmo *ExtraTreesClassifier*, por ser baseado em múltiplas árvores de decisão, mostrou-se adequado ao lidar com esse tipo de estrutura de dados.

Os resultados obtidos demonstram que o modelo consegue:

- Identificar padrões operacionais típicos dos britadores;
- Distinguir com clareza condições normais e anormais;
- Fornecer respostas rápidas e objetivas ao operador.

4.5 Vantagens, limitações e possíveis melhorias

O sistema desenvolvido apresenta diversas vantagens para aplicação na indústria:

- Automatização do processo decisório: elimina a necessidade de avaliações manuais para verificação da conformidade operacional;
- Redução de falhas inesperadas: ao antecipar situações de não conformidade permite agendamento prévio de manutenções;
- Flexibilidade e expansibilidade: o modelo pode ser facilmente adaptado para outros tipos de equipamentos ou novos parâmetros operacionais.

Contudo, também existem limitações:

- Dependência de dados de qualidade: se os dados de entrada estiverem desatualizados ou incorretos, o modelo poderá produzir resultados imprecisos;
- Interface limitada: a ausência de uma interface gráfica pode dificultar o uso por operadores com pouca experiência em sistemas baseados em texto;
- Necessidade de atualização periódica: novos dados devem ser incorporados ao sistema para que o modelo continue relevante e preciso.

Como possíveis melhorias futuras, sugerem-se:

- Desenvolvimento de uma interface gráfica amigável;
- Integração com sensores para alimentação automática dos dados;
- Implementação de módulos de relatórios automáticos e sugestões de ações corretivas.

5 CONCLUSÃO E RECOMENDAÇÕES

5.1 Conclusão

O presente estudo teve como objetivo geral responder à questão problema. Para tanto, foi desenvolvido e implementado um sistema computacional baseado em técnicas de aprendizado de máquina utilizando a linguagem de programação Python com a finalidade de aprimorar o processo de manutenção preventiva de equipamentos críticos utilizados na mineração, especificamente os britadores.

Ao longo deste trabalho, foi possível demonstrar que o programa proposto contribui significativamente para a melhoria da eficiência e eficácia dos processos de manutenção preventiva por meio da IA e otimização da análise das condições operacionais dos equipamentos. A abordagem utilizada proporcionou uma rápida identificação das condições operacionais dos britadores, permitindo antecipar eventuais falhas ou anomalias técnicas, contribuindo diretamente para a redução de custos operacionais e minimizando interrupções não planejadas na produção.

No que se refere aos objetivos específicos definidos, todos foram atingidos de maneira plena e satisfatória. A fundamentação teórica abrangente acerca de manutenção industrial, britadores, técnicas de *Machine Learning* e linguagem Python proporcionaram uma sólida base conceitual para o desenvolvimento prático do sistema proposto. Além disso, a identificação e seleção cuidadosa das variáveis controláveis operacionais críticas dos britadores possibilitou a criação de um banco de dados adequado e representativo, o que se revelou essencial para o sucesso do aprendizado automático.

O desenvolvimento do algoritmo em Python, bem como a sua integração com as principais bibliotecas de análise de dados e aprendizado de máquina permitiu a criação de uma solução funcional, eficiente e aplicável diretamente ao ambiente industrial. Adicionalmente, a realização de testes sistemáticos para avaliar a acurácia e performance do modelo corroborou sua aplicabilidade prática, comprovando que o sistema desenvolvido é capaz de fornecer resultados precisos e confiáveis, fundamentais no suporte à tomada de decisão na manutenção preventiva.

Por fim, a análise detalhada das vantagens e limitações do sistema revelou que os benefícios obtidos com a utilização do programa são evidentes, destacando-se principalmente

a capacidade de realizar diagnósticos rápidos, objetivos e eficazes. Ao mesmo tempo, foram identificadas oportunidades de melhorias e expansão da ferramenta desenvolvida, tais como integração com sensores industriais e criação de interfaces gráficas intuitivas.

Dessa forma, pode-se afirmar com segurança que a questão problema inicial foi efetivamente respondida pelo presente estudo. Conclui-se que o desenvolvimento e a implementação do programa *Machine Learning* na linguagem Python contribuiu decisivamente para o aprimoramento da manutenção preventiva dos britadores. Representando um avanço significativo, adaptável e de fácil implementação para as empresas do setor mineral.

5.2 Recomendações

Com base nos resultados obtidos e na experiência de desenvolvimento do programa, algumas recomendações são apresentadas para a continuidade e evolução de estudos:

- Integração com sensores industriais em tempo real: desenvolver uma versão do programa que receba os dados automaticamente via sensores, sem a necessidade de entrada manual dos parâmetros;
- Desenvolvimento de uma interface gráfica: criar uma interface visual amigável que facilite o uso por operadores que não têm familiaridade com a linha de comando;
- Expansão para outros tipos de equipamentos críticos: adaptar o sistema para ser utilizado também em outros equipamentos da planta de mineração, como moinhos, transportadores de correia ou peneiras vibratórias;
- Implementação de relatórios automatizados: incluir uma funcionalidade que gere relatórios em PDF com diagnósticos e recomendações de manutenção, prontos para consulta da equipe técnica.

6 REFERÊNCIA BIBLIOGRÁFICA

IBRAM - Instituto Brasileiro de Mineração. **Dados economia mineral**. 2021.

XENOS, H. G. **Gerenciando a Manutenção Preventiva: o caminho para eliminar falhas nos equipamentos e aumentar a produtividade**. Belo Horizonte: Editora de Desenvolvimento Gerencial, 2014

RACIA, Ismael Momade. **Desenvolvimento de um modelo de dimensionamento de equipamento de escavação e de transporte em mineração**. 2016.

SUZUKI, R. S. **Projeto e construção de um equipamento de ensaio de desgaste microabrasivo por esfera rotativa livre**. São Bernardo do Campo, SP, 2013. Projeto de pesquisa. Centro Universitário da FEI.

ABNT – Associação Brasileira de Normas Técnicas. NBR 5462: **Termos relacionados com a confiabilidade e manutenibilidade**. 1994.

RIBEIRO, Breno Gonçalves Cardozo. **Estudo de viabilidade econômica para a implantação de correias transportadoras de Rom de minério de ferro: estudo de caso da Mina Fábrica em Congonhas, Estado de Minas Gerais**. 2013.

CARVALHO, Pedro Sérgio Landim de; MESQUITA, Pedro Paulo Dias; CARDARELLI, Nicole Agostinho. **BNDES Panoramas Setoriais 2030**. Rio de Janeiro, 2017. Disponível em: https://www.bndes.gov.br/wps/wcm/connect/site/48dedb93-fb01-4b58-92de-4a5735669c86/BNDES_PANORAMAS+SETORIAIS+2030_completo.pdf?MOD=AJPERES&CVID=m3.O69v. Acesso em: 15 dez. 2023.

REZENDE, Solange O. et al. **Sistemas Inteligentes para Engenharia: Pesquisa e Desenvolvimento**. Anais III Workshop de Sistemas Inteligentes para Engenharia. Belo Horizonte: UFMG, 1999.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. **Conceitos sobre aprendizado de máquina**. In: CONTE, Tania et al. (Org.). **Mineração de Dados: Conceitos, Técnicas, Algoritmos, Aplicações**. Rio de Janeiro: Elsevier, 2003. p. 21-58.

MITCHELL, Tom M. **Machine Learning**. McGraw-Hill Education, 1997.

BORGES, Bruno. **Aprendendo Inteligência Artificial com Python**. São Paulo: Novatec, 2014.

HUSTRULID, William A.; HUSTRULID, William A.; BULLOCK, Richard L. (Eds.). **Underground mining methods: Engineering fundamentals and international case studies**. SME, 2001.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 6177: **Transportadores contínuos - transportadores de correia - terminologia**. Rio de Janeiro, 1999. 32 p.

PEREIRA, Márcio Filipe Godinho. **Manutenção preventiva na gestão de falhas em redes móveis usando machine learning**. 2022. Tese de Doutorado. Instituto Superior de Engenharia de Lisboa.

KARDEC, Alan; NASCIF, Julio. **Manutenção Função Estratégica**, 5ª edição. Rio de Janeiro: Quality Mark, 2012.

DE AZEVEDO, Marcelo Teixeira et al. **Transformação digital na indústria de mineração: contribuição com acompanhamento em tempo real para britadores de mineração**. Revista Científica UMC, v. 6, n. 3, 2021.

Ministério de Minas e Energia. **Perfil de brita para construção civil**. Brasília, DF, 2016. Disponível em: https://antigo.mme.gov.br/documents/36108/448620/P22_RT30_Perfil_de_brita_para_construxo_civil.pdf/0b657545-498a-46ee-b836-a974026d435a?version=1.0. Acesso em: 20 dez. 2023.

BASTOS, Patrícia Cardoso. **Análise comparativa entre o uso de métodos convencionais e o uso de softwares para a seleção de britadores e peneiras**. 2015.

SANTOS, D. A.; MALAGONI, R. A. **Projeto de correias transportadoras: um estudo computacional de comparação dos métodos CEMA e prático**. HOLOS, v. 3, p. 358-369, 2014.

SACRAMENTO, R. C. F. **Apostila de Transportadores de Correia**. Universidade Federal da Bahia – UFBA, pp. 20 – 47 Salvador – BA, 2010.

CARNIZELLO, Daniel Cardoso. **Transportador de correia: componentes e cálculos básicos para seu dimensionamento**. 2011.

PINTO, Paulo Douglas de Souza. **Importância de dispositivos de segurança na prevenção de acidentes envolvendo empilhadeiras**. 2018.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Operations Management**. Pearson Education, 2010.

TSANG, A. H. C. **Strategic dimensions of maintenance management**. Journal of Quality in Maintenance Engineering, v. 8, n. 1, p. 7-39, 2002.

SCHONBERGER, R. J. **World Class Manufacturing: The Lessons of Simplicity Applied**. Free Press, 1986.

MOUBRAY, J. **Reliability-centered Maintenance**. Industrial Press Inc., 1997.

SWANSON, L. **Linking maintenance strategies to performance**. International Journal of Production Economics, v. 70, n. 3, p. 237-244, 2001.

GITS, C. W. **Developing a predictive maintenance policy using risk and criticality assessment**. Maintenance Management International, n. 12, p. 19-29, 1992.

MOBLEY, R. K. **An Introduction to Predictive Maintenance**. Butterworth-Heinemann, 2002.

PINTELON, L.; PARODI-HERZ, A. **Maintenance: An Evolutionary Perspective**. In: **Complex System Maintenance Handbook**. Springer, 2008, p. 21-48.

HIGGINS, L. R.; MOBLEY, R. K. **Maintenance Engineering Handbook**. McGraw-Hill, 2002.

KEENEY, R. **Making better decision makers**. Decision Analysis, v. 1, n. 4, p. 193-204, 2004.

NAKAJIMA, S. **Introduction to Total Productive Maintenance (TPM)**. Productivity Press, 1988.

DUFFUAA, S. O.; RAOUF, A.; CAMPBELL, J. D. **Planning and Control of Maintenance Systems: Modeling and Analysis**. John Wiley & Sons, 1999.

WIREMAN, T. **Total Productive Maintenance**. Industrial Press Inc., 2007.

KELLY, A. **Maintenance Systems and Documentation**. Elsevier, 2006.

FERREIRA, P. H. A. **Estudo das contribuições da manutenção centrada na confiabilidade na implementação do perfil de perdas com auxílio do business intelligence: o caso da manutenção de equipamentos móveis de uma empresa de mineração**. 2021.

MOUBRAY, J. **Manutenção Centrada em Confiabilidade**. In: **Reliability-Centred Maintenance**. Aladon Ltd, Reino Unido, 2000.

ALPAYDIN, E. **Introduction to Machine Learning**. 4^a ed. MIT Press, 2020.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. Springer, 2006.

- JORDAN, M. I.; MITCHELL, T. M. **Machine learning: Trends, perspectives, and prospects**. Science, v. 349, n. 6245, p. 255-260, 2015.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016.
- MURPHY, K. P. **Machine Learning: A Probabilistic Perspective**. MIT Press, 2012.
- VAN ROSSUM, G.; DRAKE, F. L. **Python 3 Reference Manual**. CreateSpace, 2009.
- LUTZ, M. **Learning Python**. 5^a ed. O'Reilly Media, 2013.
- SUMMERS, A. **Python 3: The Next Generation**. IEEE Software, v. 26, n. 3, 2009.
- MCKINNEY, W. **Python for Data Analysis**. O'Reilly Media, 2012.
- DOWNEY, A. **Think Python: How to Think Like a Computer Scientist**. O'Reilly Media, 2015.
- OLIPHANT, T. E. **A guide to NumPy**. Trelgol Publishing, 2006.
- VANDERPLAS, J. **Python Data Science Handbook: Essential Tools for Working with Data**. O'Reilly Media, 2016.
- WALT, S. van der; COLBERT, S. C.; VAROQUAUX, G. **The NumPy Array: A Structure for Efficient Numerical Computation**. Computing in Science & Engineering, v. 13, n. 2, 2011.
- PEDREGOSA, F. et al. Scikit-learn: **Machine Learning in Python**. Journal of Machine Learning Research, v. 12, 2011.
- MÜLLER, A. C.; GUIDO, S. **Introduction to Machine Learning with Python: A Guide for Data Scientists**. O'Reilly Media, 2016.
- HUNTER, J. D. Matplotlib: **A 2D Graphics Environment**. Computing in Science & Engineering, v. 9, n. 3, 2007.
- TUFTE, E. R. **The Visual Display of Quantitative Information**. 2^a ed. Graphics Press, 2001.
- WASKOM, M. et al. **Seaborn: statistical data visualization**. Journal of Open Source Software, v. 9, n. 30, 2014.
- CRESWELL, J. W. Research Design: **Qualitative, Quantitative, and Mixed Methods Approaches**. Sage Publications, 2014.
- METSO MINERALS. **Manual de instruções: britadores cônicos Nordberg HP100, 200, 300, 400, 500.**: Metso Minerals, [2024].

- BRYMAN, A. **Social Research Methods**. Oxford University Press, 2012.
- DENZIN, N. K.; LINCOLN, Y. S. **The SAGE Handbook of Qualitative Research**. Sage Publications, 2011.
- GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. Atlas, 2008.
- LAKATOS, E. M.; MARCONI, M. A. **Fundamentos de Metodologia Científica**. Atlas, 2011.
- WILLS, B. A.; FINCH, J. **Wills' Mineral Processing Technology: An Introduction to the Practical Aspects of Ore Treatment and Mineral Recovery**. Elsevier, 2016.
- EVERTSSON, C. M. **Cone Crusher Performance**. Tese (Doutorado) - Chalmers University of Technology, 2000.
- NAPIER-MUNN, T. J.; MORRELL, S.; MORRISON, R. D.; KOJOVIC, T. **Mineral Comminution Circuits: Their Operation and Optimisation**. Julius Kruttschnitt Mineral Research Centre, 1996.
- SMITH, A. M.; HINCHCLIFFE, G. R. **Gateway To World Class Maintenance**, 2004.
- LINDQVIST, M.; EVERTSSON, C. M. **Liner wear in jaw crushers**. In: Minerals Engineering, v. 16, n. 1, p. 1-12, 2003. Publicado pela Chalmers University of Technology, Gothenburg, Sweden.
- KELLER, S.; OWEN, A. **A comprehensive cost-benefit analysis of preventive maintenance versus corrective maintenance: assessing the financial impact and operational benefits in engineering**. *ResearchGate*, 2025. Disponível em: <https://www.researchgate.net/publication/389501396>. Acesso em: 11 jul. 2025.
- TADACHI, N.T.; FLORES, M.C.X. **Indicadores da Qualidade e do Desempenho**. 1^a.ed. Rio de Janeiro: Qualitymark, 1997.