

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
MINAS GERAIS - *CAMPUS* AVANÇADO ARCOS
ENGENHARIA MECÂNICA

João Vitor Balduino Soares de Melo
Mateus Bernini

MACHINE LEARNING APLICADO À GESTÃO DE EQUIPAMENTOS
EM UMA INDÚSTRIA CIMENTEIRA: ANÁLISE DE PARÂMETROS
TRIBOLÓGICOS UTILIZANDO LINGUAGEM DE PROGRAMAÇÃO
PYTHON

Arcos - MG
2024

JOÃO VITOR BALDUINO SOARES DE MELO

MATEUS BERNINI

***MACHINE LEARNING APLICADO À GESTÃO DE EQUIPAMENTOS
EM UMA INDÚSTRIA CIMENTEIRA: ANÁLISE DE PARÂMETROS
TRIBOLÓGICOS UTILIZANDO LINGUAGEM DE PROGRAMAÇÃO
PYTHON***

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Mecânica do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais - *Campus* Avançado Arcos para a obtenção do título de Bacharel em Engenharia Mecânica.

Orientador: Prof. Msc. Maurício Lourenço Jorge

Arcos - MG
2024

Catálogo na Fonte Biblioteca IFMG - Campus Avançado Arcos

M528m Melo, João Vitor Balduino Soares de.

Machine Learning aplicado à gestão de equipamentos em uma indústria cimenteira: análise de parâmetros tribológicos utilizando linguagem de programação *Python*. / João Vitor Balduino Soares de Melo, Mateus Bernini. - Arcos, 2024.

72 f. : il. color.

Orientador: Prof. Maurício Lourenço Jorge.

Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) - Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais - *Campus Avançado Arcos*.

1. Tribologia. 2. Redes Neurais Artificiais I. Bernini, Mateus. II. Jorge, Maurício Lourenço (orientador). III. Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais - *Campus Avançado Arcos*. IV. Título.

CDD 671.35

Catálogo: Meriely Ferreira de Almeida - CRB-6/2760



MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS GERAIS
Campus Avançado Arcos
Diretoria de Ensino
Docentes Área Técnica
Av. Juscelino Kubitschek, 485 - Bairro Brasília - CEP 35588000 - Arcos - MG
3733515173 - www.ifmg.edu.br

ATA DE DEFESA DE TCC

Ata de Defesa de TCC do Curso de Bacharelado em Engenharia Mecânica, realizada em 12 de dezembro de 2024

Às dezenove horas do dia doze do mês de dezembro de dois mil e vinte e quatro, por meio da plataforma Google Meet, se reuniu a banca avaliadora composta pelo Professor Dr. **Alexandre Moura Giarola**, Professor Dr. **Marcelo Teodoro Assunção** e Professor Me. **Maurício Lourenço Jorge** (orientador), para avaliar o trabalho intitulado “Machine Learning Aplicado à Gestão de Equipamentos em uma Indústria Cimenteira: Análise de Parâmetros Tribológicos Utilizando Linguagem de Programação Python”, apresentado pelos alunos **João Vitor Balduino Soares de Melo** e **Mateus Bernini**, como parte dos requisitos para obtenção do título de Engenheiro Mecânico. Após apresentação e arguição, emitiu-se o parecer “aprovado”, sendo atribuída uma nota final de 89 pontos. A verificação das modificações sugeridas pela banca são de responsabilidade do orientador. Nada mais havendo a tratar, a defesa foi encerrada às vinte horas e cinco minutos e eu, Maurício Lourenço Jorge, lavrei a presente ata que, após lida e aprovada, foi assinada por todos os avaliadores.

Arcos, 12 de dezembro de 2024.



Documento assinado eletronicamente por **Mauricio Lourenco Jorge, Professor**, em 16/12/2024, às 07:24, conforme Decreto nº 10.543, de 13 de novembro de 2020.



Documento assinado eletronicamente por **Marcelo Teodoro Assunção, Professor**, em 16/12/2024, às 09:44, conforme Decreto nº 10.543, de 13 de novembro de 2020.



Documento assinado eletronicamente por **Alexandre Moura Giarola, Professor**, em 16/12/2024, às 17:48, conforme Decreto nº 10.543, de 13 de novembro de 2020.



A autenticidade do documento pode ser conferida no site <https://sei.ifmg.edu.br/consultadocs> informando o código verificador **2140443** e o código CRC **C4822042**.

RESUMO

A manutenção e gestão de ativos na indústria cimenteira apresentam desafios complexos devido ao desgaste intensivo de equipamentos como o moinho vertical de rolos, essencial na produção de cimento. Este trabalho aborda a aplicação de técnicas de *Machine Learning* para prever o desgaste e monitorar falhas no moinho, a fim de aumentar a disponibilidade e eficiência dos ativos. Foram desenvolvidos dois programas: um para análise de conformidade e falhas, e outro para controle do desgaste, utilizando Redes Neurais Artificiais (ANN) e redes *Long Short-Term Memory* (LSTM). As variáveis de entrada dos modelos foram obtidas a partir de manuais e planos de manutenção do equipamento, e os dados foram tratados e modelados em *Python* com o uso de bibliotecas específicas. Os resultados mostraram que o modelo LSTM apresentou melhor desempenho preditivo em várias posições dos rolos, com coeficientes de determinação (R^2) superiores e menor erro quadrático médio (MSE) em comparação ao modelo ANN. Esse sistema permite um monitoramento preditivo, que se alinha aos conceitos de Manutenção Preditiva e contribui para a redução de paradas não programadas. Foi possível concluir que as técnicas de aprendizado de máquina apresentam um potencial significativo para otimizar a manutenção na indústria cimenteira, especialmente no monitoramento de desgaste e falhas, conforme indicado pelos resultados obtidos nas simulações realizadas.

Palavras-chave: Manutenção Preditiva. Tribologia. *Machine Learning*. Redes Neurais Artificiais.

ABSTRACT

Maintenance and asset management in the cement industry present complex challenges due to the intensive wear on equipment such as the vertical roller mill, essential in cement production. This work addresses the application of Machine Learning techniques to predict wear and monitor faults in the mill to increase asset availability and efficiency. Two programs were developed: one for compliance and fault analysis and another for wear control, utilizing Artificial Neural Networks (ANN) and Long Short-Term Memory (LSTM) networks. The input variables for the models were obtained from equipment manuals and maintenance plans, and the data were processed and modeled in Python using specific libraries. The results showed that the LSTM model demonstrated superior predictive performance at various roller positions, with higher coefficients of determination (R^2) and lower mean squared error (MSE) compared to the ANN model. This system enables predictive monitoring, aligning with Predictive Maintenance concepts and contributing to the reduction of unscheduled downtime. It was possible to conclude that Machine Learning techniques hold significant potential for optimizing maintenance in the cement industry, particularly in monitoring of wear and faults, as indicated by the results obtained in the simulations.

Keywords: Predictive Maintenance, Tribology, Machine Learning, Artificial Neural Networks.

LISTA DE ILUSTRAÇÕES

Figura 1 – Indústria de cimento.	5
Figura 2 – Desenho esquemático de um moinho vertical de rolos.....	9
Figura 3 – Representação das áreas de atrito.	10
Figura 4 – Desgaste por abrasão.	11
Figura 5 – Desgaste por fadiga.....	11
Figura 6 – Tribossitema.	12
Figura 7 – Representação esquemática de um tribossitema.....	13
Figura 8 – Modelo esquemático da árvore de decisão.	17
Figura 9 – Fluxograma da árvore de decisão utilizada para a análise de conformidade do equipamento.	23
Figura 10 – Exemplo de Ganho de Informação após a divisão dos dados.....	24
Figura 11 – Fluxograma da função Análise de Conformidade Física.	24
Figura 12 – Fluxograma da função de Indicador de Falhas	25
Figura 13 – Fluxograma do programa de previsão do desgaste	30
Figura 14 – Interface Inicial do Programa 1.	32
Figura 15 – Interface da função Análise de Conformidade Física - Status de Conformidade.	33
Figura 16 – Interface de dados da função Análise de Conformidade Física - Status de Não Conformidade.....	34
Figura 17 – Gráfico de Tendência de Falhas.....	35
Figura 18a – Interface da Função Registro de Falhas.	36
Figura 18b – Interface da Função Registro de Falhas.....	36
Figura 19 – Previsão de Desgaste segundo ANN para o Rolo M1.	37
Figura 20 – Previsão de Desgaste segundo LSTM para o Rolo M1.	38
Figura 21 – Comparação entre Desgaste Real e Predito para ANN e LSTM - Rolo M1.	40
Figura 22 – Desgaste previsto ao Longo do Tempo - ANN.....	41
Figura 23 – Desgaste previsto para ao Longo do Tempo - LSTM.	41
Figura 24 – Análise Comparativa entre Desgaste Real e Predito para ANN e LSTM.	43
Figura 25 – Previsão de Desgaste ao Longo do Tempo (ANN) - Rolo M3	44
Figura 26 – Previsão de Desgaste ao Longo do Tempo (LSTM) - Rolo M3.....	44
Figura 27 – Análise Comparativa entre Desgaste Real e Predito para ANN e LSTM (Rolo M3).	46
Figura 28 – Dataset I.....	51
Figura 29 – Dataset II.	51
Figura 30 – Dataset III.....	51
Figura 31 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.1 (mm).....	52
Figura 32 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.2 (mm).....	53
Figura 33 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.3 (mm).....	53

Figura 34 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.4 (mm).	54
Figura 35 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.5 (mm).	54
Figura 36 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.6 (mm).	55
Figura 37 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.7 (mm).	55
Figura 38 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.8 (mm).	56
Figura 39 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.9 (mm).	56
Figura 40 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.10 (mm).	57
Figura 41 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.1 (mm).	57
Figura 42 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.2 (mm).	58
Figura 43 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.3 (mm).	58
Figura 44 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.4 (mm).	59
Figura 45 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.5 (mm).	59
Figura 46 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.6 (mm).	60
Figura 47 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.7 (mm).	60
Figura 48 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.8 (mm).	61
Figura 49 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.9 (mm).	61
Figura 50 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.10 (mm).	62
Figura 51 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.1 (mm).	62
Figura 52 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.2 (mm).	63
Figura 53 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.3 (mm).	63
Figura 54 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.4 (mm).	64
Figura 55 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.5 (mm).	64
Figura 56 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.6 (mm).	65
Figura 57 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.7 (mm).	65
Figura 58 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.8 (mm).	66
Figura 59 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.9 (mm).	66
Figura 60 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.10 (mm).	67
Figura 61 – Fluxo da base de moagem através do moinho, representação de princípio.	68
Figura 62 – Interfaces do moinho de cilindros da LOESCHE.	69
Figura 63 – Rolo completo.	70
Figura 64 – Vista geral do Moinho LOESCHE.	71

LISTA DE QUADROS

Quadro 1 – Variáveis utilizadas na análise da disponibilidade física do moinho	33
Quadro 2 – Variáveis utilizadas na análise de falhas do moinho	35
Quadro 3 – Variáveis presentes em cada conjunto de dados.....	36

LISTA DE TABELAS

Tabela 1 – Métricas de desempenho para ANN e LSTM por posição de desgaste - Rolo M1.	39
Tabela 2 – Coeficientes de determinação de treino e de teste dos modelos preditivos (ANN e LSTM) - Rolo M1.	40
Tabela 3 – Métricas de desempenho para ANN e LSTM por posição de desgaste - Rolo M2.	42
Tabela 4 – Coeficientes de determinação de treino e de teste dos modelos preditivos (ANN e LSTM).	43
Tabela 5 – Métricas de desempenho para ANN e LSTM por posição de desgaste - Rolo M3.	45
Tabela 6 – Coeficientes de determinação de treino e de teste dos modelos preditivos (ANN e LSTM) para o Rolo M3.	46

SUMÁRIO

1	INTRODUÇÃO	5
1.1	Justificativa.....	7
1.2	Objetivos.....	7
1.2.1	<i>Geral.....</i>	7
1.2.2	<i>Específicos.....</i>	7
2	REFERENCIAL TEÓRICO	8
2.1	Indústria de Cimento e Tecnologias	8
2.2	Moinho Vertical de Rolos	8
2.3	Força de atrito	9
2.4	Desgaste	10
2.5	Fadiga	11
2.6	Sistema Tribológico	12
2.7	Lubrificação	13
2.7.1	<i>Planos de Lubrificação em Plantas Industriais.....</i>	13
2.8	Manutenção	14
2.8.1	<i>Planejamento e Controle da Manutenção.....</i>	14
2.8.2	<i>Disponibilidade de ativos críticos</i>	14
2.9	Machine Learning.....	14
2.9.1	<i>Etapas do aprendizado supervisionado</i>	15
2.9.2	<i>Identificação do problema</i>	15
2.9.3	<i>Coleta e identificação dos dados.....</i>	15
2.9.4	<i>Pré-processamento.....</i>	16
2.9.5	<i>Árvore de Decisão</i>	17
2.9.6	<i>ANN (Artificial Neural Networks).....</i>	18
2.9.7	<i>LSTM (Long Short-Term Memory).....</i>	18
2.10	Linguagem de Programação Python.....	18
2.11	Bibliotecas Python	18
2.11.1	<i>Pandas</i>	18
2.11.2	<i>Numpy</i>	19

2.11.3	<i>Scikit-Learn</i>	19
2.11.4	<i>Matplotlib</i>	19
3	METODOLOGIA	20
3.1	Tipos de Pesquisa	20
3.2	Classificação da Pesquisa Quanto aos Objetivos	20
3.3	Materiais e Métodos	21
3.3.1	<i>Materiais</i>	21
3.3.2	<i>Métodos</i>	21
3.4	Metodologia Prática	21
3.4.1	<i>Metodologia de Classificação: Árvore de Decisão</i>	21
3.4.2	<i>Impureza de Gini</i>	22
3.4.3	<i>Processo de Decisão</i>	22
3.4.4	<i>Ganho de Informação</i>	23
3.5	Análise de Conformidade e Falhas - Programa 1	24
3.5.1	<i>Função de Análise de Disponibilidade Física</i>	24
3.5.2	<i>Função de Indicação de Falhas do Equipamento</i>	25
3.5.3	<i>Validação do Modelo 1</i>	25
3.6	Metodologia de Previsão: ANN e LSTM	26
3.6.1	<i>Redes Neurais Artificiais (ANN)</i>	26
3.6.2	<i>Redes LSTM</i>	27
3.7	Previsão e Controle do Desgaste - Programa 2	29
3.7.1	<i>Validação do modelo 2</i>	30
4	RESULTADOS E DISCUSSÃO	32
4.1	Programa 1 - Análise de Conformidade e Falhas.	32
4.1.1	<i>Interface Inicial do Programa</i>	32
4.1.2	<i>Análise de Equipamento</i>	32
4.1.3	<i>Indicador de Falhas: Gráfico de Ocorrências</i>	34
4.1.4	<i>Registro de Falhas: Identificação de Causas e Soluções</i>	35
4.2	Programa 2 - Controle do Desgaste	36
4.2.1	<i>Rolo M1</i>	37

4.2.2	<i>Rolo M2</i>	40
4.2.3	<i>Rolo M3</i>	43
5	CONCLUSÃO	47
	REFERÊNCIAS	48
	APÊNDICE A – DATAFRAMES UTILIZADOS PARA OS MODELOS DE MACHINE LEARNNIG	51
A.1	Análise de Conformidade	51
A.2	Análise de Falhas	51
A.3	Previsão e Controle do Desgaste	51
A.4	Comparação do desgaste previsto vs Desgaste Real para os três rolo M .	52
	ANEXO A – MOINHO VERTICAL DE ROLOS	68
A.1	Imagens do Moinho e dos Rolos de Moagem	68

1 INTRODUÇÃO

A indústria brasileira de cimento começou a se desenvolver em São Paulo e no Rio de Janeiro a partir de 1926. Inicialmente, sua atuação no território nacional foi discreta. No entanto, a partir de 1933, a produção nacional superou as importações, marcando o início de um processo de crescimento e consolidação significativo da indústria brasileira de cimento (AYRES *et al.*, 1999). A Figura 1 permite visualizar a estrutura envolvida em uma grande indústria cimenteira.

Figura 1 – Indústria de cimento.



Fonte: Adaptado de Unsplash (2017).

De acordo com Kihara (2014), na década de 70, ocorreu o chamado “milagre econômico”, que impulsionou a indústria de cimento, por meio de inúmeros projetos habitacionais e de infraestrutura da época. Em 10 anos, a produção de cimento triplicou, de 9 para 27 milhões de toneladas/ano, e para suprir esse aumento na demanda foram instaladas 24 novas fábricas. No século XXI, o Brasil está atravessando um novo ciclo de crescimento, que foi iniciado em 2004, contando com 87 plantas industriais cimenteiras, que são controladas por 17 grupos industriais. Nessas plantas foram produzidas 70 milhões de toneladas no ano de 2013, fazendo assim, o Brasil o sexto maior produtor de cimento do mundo.

O Brasil, diferentemente de outros países, costuma determinar a produção de acordo com a quantidade consumida, já que o cimento é direcionado ao consumo interno (Massari, 2023). Nesse tipo de indústria, os gastos com energia elétrica são elevados, e assim gera a busca por equipamentos mais eficientes. Com isso, surgiu o moinho vertical de rolos com a ideia de substituir os tradicionais moinhos tubulares de bolas, esses novos moinhos apresentam uma redução de aproximadamente 40% no consumo energético (Pontes, 2018).

Os equipamentos da indústria cimenteira estão sujeitos a grandes esforços operacionais e, frequentemente, trabalham próximos de sua capacidade máxima de carga. Esse cenário torna os componentes desses sistemas mais suscetíveis ao desgaste acelerado, o que pode resultar em paradas não planejadas e aumentar os custos de manutenção. Para mitigar esses riscos, é imprescindível o desenvolvimento de planos de manutenção detalhados e personalizados para cada equipamento, o que contribui para a continuidade das operações e para a preservação da integridade dos componentes (Suzuki, 2013).

A implementação de tecnologias de monitoramento em tempo real, como sensores de desgaste, vibração e temperatura, tem se mostrado essencial para antecipar falhas e identificar problemas antes que se tornem críticos. Esses sistemas de monitoramento fornecem dados precisos e contínuos, permitindo intervenções mais assertivas e reduzindo as paradas não programadas. Além disso, o monitoramento constante permite uma abordagem de manutenção preditiva, que maximiza a vida útil dos equipamentos e minimiza o desperdício de recursos.

Na indústria de mineração, onde o desgaste dos equipamentos é um dos principais fatores de perda de produtividade, o estudo do sistema tribológico de cada componente ganha ainda mais relevância. A compreensão detalhada das características de atrito, lubrificação e desgaste para cada peça permite uma avaliação precisa das condições de operação e facilita a escolha de materiais e lubrificantes mais adequados para prolongar a vida útil dos sistemas. Essas práticas são essenciais para reduzir o tempo de parada dos equipamentos, otimizar a produtividade e garantir uma operação segura e eficiente (Suzuki, 2013).

O estudo tribológico é uma ciência que se aprofunda no estudo da fricção e na sua relação com o desgaste de materiais por causa do contato entre superfícies com movimento (Radi *et al.*, 2007). A cada ano que passa, os avanços tecnológicos da área de tribologia vêm evoluindo com o foco principal de reduzir o número de falhas mecânicas que acontecem em máquinas e equipamentos, devido ao desgaste e o atrito.

Machine Learning (ML) e Inteligência Artificial têm sido empregados na administração de energias renováveis, predição de propriedades físico-químicas de catalisadores e fluidos e em comandos de processo. Essas tecnologias têm se destacado na simulação e modelagem de processos químicos na engenharia, como evidenciado por estudos recentes sobre a aplicação de redes neurais profundas para predição em sistemas industriais complexos (Riberiro; Nogueira, 2022). Isso reforça a relevância da integração de técnicas de ML em contextos industriais para otimização de processos e decisões estratégicas.

1.1 Justificativa

Devido ao grande número de falhas por desgaste excessivo em peças (Oliveira; Silva, 2015), ao analisar os fenômenos de atrito entre superfícies com movimento relativo, nota-se que estes estudos têm grande relevância para o aumento da vida útil e desempenho de componentes mecânicos. Nesse contexto, integrar *Machine Learning* com o estudo da tribologia pode contribuir para uma gestão mais eficiente de ativos críticos no setor industrial, facilitando a tomada de decisões inteligentes para otimização da manutenção e produção.

Assim, este estudo visa não apenas aprofundar o entendimento sobre tribologia, mas também aprimoramento da autonomia e eficiência de processos por meio de análises preditivas e decisões embasadas em dados.

1.2 Objetivos

1.2.1 Geral

O objetivo deste trabalho é realizar um estudo exploratório para exemplificar o uso de modelos de *Machine Learning*, como algoritmos de regressão e classificação, para prever falhas e controlar o desgaste em equipamentos de uma indústria de cimento, a partir da análise de parâmetros tribológicos utilizando a linguagem de programação *Python*.

1.2.2 Específicos

- Apresentar os conceitos fundamentais sobre Tribologia, Sistema Tribológico, TPM – Manutenção Produtiva Total, *Machine Learning* e Linguagem de programação *Python*.
- Montar os *Datasets* utilizando parâmetros tribológicos e operacionais do Moinho Vertical de cimento.
- Integrar os algoritmos *Learning* aos programas em linguagem *Python*.
- Realizar testes para análise de precisão do modelo.

2 REFERENCIAL TEÓRICO

2.1 Indústria de Cimento e Tecnologias

A indústria de cimento tem passado por significativas inovações tecnológicas que buscam tanto aumentar a eficiência quanto reduzir as emissões de gases de efeito estufa. Tecnologias como o uso de combustíveis alternativos, captura de carbono, e cimentos com baixas emissões de CO₂ vêm sendo discutidas. Scrivener e Kirkpatrick (2008) destacam o avanço de concretos de alto desempenho e ultra-alto desempenho, com melhorias que vão além da simples resistência estrutural, envolvendo também a importância da pesquisa interdisciplinar.

A produção de cimento é um dos principais contribuintes para as emissões de CO₂ antropogênicas, representando cerca de 5 a 6% das emissões globais. Inovações como a substituição de materiais, uso de combustíveis alternativos e tecnologias de captura de carbono têm sido propostas como soluções sustentáveis (IGHALO, 2020). Esses estudos enfatizam a necessidade de uma abordagem sistemática para superar os desafios ambientais e a lentidão na implementação de tecnologias disruptivas na produção de cimento.

2.2 Moinho Vertical de Rolos

Os processos de britagem e moagem são os que mais contribuem para o elevado consumo de energia elétrica. Por esse motivo, a utilização de moinhos verticais de rolos em detrimento dos moinhos de bolas tem aumentado cada vez mais. Os moinhos verticais ganharam espaço pois, além de apresentar um consumo energético específico menor, diminuindo custos do processo, são mais compactos, o que proporciona economia de espaço. A busca do setor por um moinho eficiente, que ofereça ótimas condições de cominuição, tenha alta produtividade e baixo custo por tonelada foi atendida, (MICHEL, 2017).

No moinho vertical de rolos acontecem simultaneamente a moagem, homogeneização, , secagem e classificação do material, diferente do moinho de bolas, que demanda um classificador externo. O processo de moagem tem por objetivo reduzir as partículas do material à granulometria desejada. O moinho vertical de rolos realiza isso por meio de uma combinação de impacto, compressão, abrasão e atrito.

Segundo Oliveira (2012) os principais componentes de um moinho vertical de rolos são: carcaça, mesa de moagem, rolos moedores, sistema de acionamento, sistema de carregamento hidráulico, anel defletor (*Nozzle ring*), anel de barragem (*dam ring*) e separador de frações de sólidos.


Conforme PITZER (2006), o moinho vertical funciona da seguinte maneira: o material entra no equipamento por uma abertura na sua parte superior e cai por gravidade no centro da mesa. Como essa mesa está girando, o efeito centrífugo causado

pela rotação move esse material para as extremidades. Os rolos posicionados na extremidade da mesa pressionam o material que está localizado entre eles e a mesa, resultando na diminuição das partículas.

O material vai sendo cada vez mais empurrado para as extremidades, até que sai da mesa e é arrastado por gases que vêm do forno. Os gases do forno são reaproveitados para secar o material e arrastá-lo para a parte superior do moinho, onde fica um classificador. Este classificador separa as partículas de acordo com sua granulometria, como ilustrado na Figura 2.

A parte do material que atingir a granulometria especificada é levada para a próxima etapa do processo, enquanto a parcela com partículas maiores volta para o moinho e passa pelo mesmo processo até atingir a granulometria especificada.

Figura 2 – Desenho esquemático de um moinho vertical de rolos.




Fonte: Gebr. Pfeiffer (2024).

2.3 Força de atrito

Segundo Hutchings (1992) e Stoeterau (2004), atrito ou fricção pode ser definido como a resistência proveniente do contato entre corpos em movimento relativo. Devido à existência de rugosidade nas superfícies de materiais, quando dois corpos estão em contato são produzidas junções com características ásperas, que determinam a intensidade na qual o atrito é produzido.

O contato entre as superfícies ocorre em nível atômico de acordo com a interação e proporcionalmente à distância entre as mesmas, logo quanto maior for a força de interação entre os átomos, maior será a força de atrito. Na Figura 3, são representadas duas superfícies aparentemente em contato total, porém, em nível microscópico nota-se que a área de contato real (A_r), é inferior à área de contato aparente (A_a).

Figura 3 – Representação das áreas de atrito.



Fonte: Stoeterau (2004).


2.4 Desgaste

O desgaste pode ser definido como um processo deterioração da superfície de um sólido, na qual o movimento relativo entre as partes do sistema gera perda do material na maioria dos casos segundo Czichos (2020). O desgaste é um fenômeno determinado por meio de testes em um sistema, em qual são analisados parâmetros como parâmetros como características da superfície, carga aplicadas, distância de deslizamento, composição química do material e a velocidade (HUTCHINGS, 1992).

De acordo com KATO; ADACHI (2001), os três principais movimentos relativos que podem causar desgaste são o movimento de rolamento, o movimento de deslizamento e o movimento de impacto. Tradicionalmente, existem quatro tipos de desgaste amplamente aceitos.

No desgaste abrasivo ocorre a remoção do material de uma das superfícies (Figura 4), normalmente por causa da dureza e do formato dos materiais Radi *et al.* (2007).. Esse tipo de desgaste o acontece quando há movimento de deslizamento entre dois corpos e para três corpos quando há movimento de rolamento entre eles (HUTCHINGS, 1992).


Figura 4 – Desgaste por abrasão.



Fonte: Adaptado de Rijeza (2022).

O desgaste por fadiga é um fenômeno resultante de um elevado número de repetições de movimentos de contato entre superfícies, o que gera tensões cíclicas capazes de provocar microfissuras no material ao longo do tempo (RADI et al., 2007). Esse tipo de desgaste é caracterizado pela formação e propagação progressiva dessas fissuras, culminando em falhas estruturais quando a resistência do material é completamente comprometida. A Figura 5 ilustra de forma esquemática o processo de desgaste por fadiga

Figura 5– Desgaste por fadiga.



Fonte: Adaptado de Technology (2020).

2.5 Fadiga


Fadiga vem do latim *FATIGARE* que significa cansar. Ela é um tipo de falha que ocorre em peças por causa do excesso de repetições durante um longo período, diz-se que o material se torna "cansado" de realizar cargas repetidas (SOBOYEJO, 2002).

A ASTM (*American Society for Testing and Materials*), que é um órgão estadunidense de normalização, define a fadiga como um processo permanente, gradual e que, dependendo de como o material é forçado a operar, pode gerar trincas e posteriormente no rompimento total do material (DALMOLIN et al. 2017).

2.6 Sistema Tribológico

Segundo Czichos (2020), um sistema tribológico, também conhecido como ‘tribossistema’, refere-se a um conjunto de componentes em interação que estão sujeitos aos fenômenos tribológicos. Geralmente, um sistema tribológico é composto por pelo menos duas superfícies em contato que estão sujeitas a forças, movimento relativo e desgaste. Como exemplo de um tribossistema, pode-se citar um par de engrenagens, em que a coroa e o pinhão são corpos antagonistas, o ambiente em que operam, juntamente com o elemento interfacial, que pode ser um lubrificante, óxido ou outro material, influencia significativamente o desempenho, conforme ilustrado na Figura 6 a seguir.

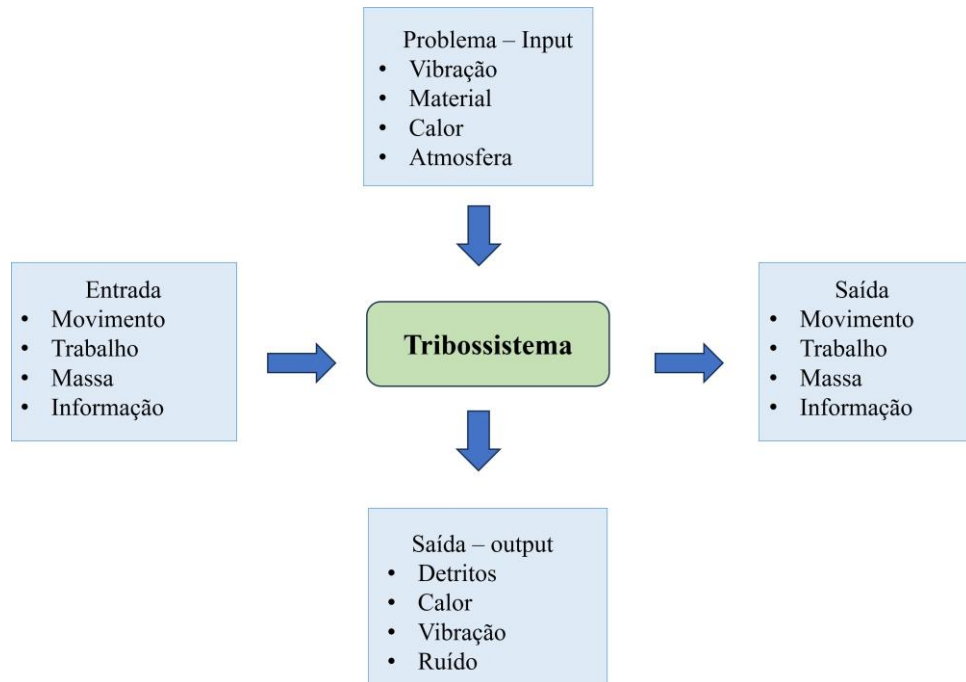
Figura 6 – Tribossistema.



Fonte: Adaptado de Gahr (1987).

Um tribossistema é um sistema tecnológico composto por componentes mecânicos, como superfícies, materiais de atrito e um meio lubrificante. A função técnica do tribossistema refere-se à relação entre as entradas e as saídas úteis (GAHR, 1987). Em outras palavras, é a maneira pela qual o sistema converte as entradas em saídas desejadas. Por exemplo, um tribossistema em um motor de combustão interna tem como função técnica minimizar o desgaste das peças, reduzir o atrito e garantir uma lubrificação eficiente, para que o motor opere de forma suave. A Figura 7 apresenta o esquema de um tribossistema.

Figura 7 – Representação esquemática de um tribossistema.



Fonte: Adpatado de Gahr (1987).

2.7 Lubrificação

Em meados do século dezenove, pesquisadores buscavam estabelecer teorias a respeito dos estudos referentes a lubrificação. Em 1886 o físico Osborne Reynolds estabeleceu as bases da lubrificação a filme fluido, utilizando princípios básicos da mecânica dos fluidos como argumentação diante dos fenômenos observados, contribuindo com o surgimento da teoria clássica da lubrificação hidrodinâmica (HD), a qual é utilizada com frequência em projetos de dispositivos mecânicos (PERSSON; SPENCER, 1999).

2.7.1 Planos de Lubrificação em Plantas Industriais

Para Maia e Barros (2016), os equipamentos industriais contam com uma vasta gama de componentes e peças em movimento constante ou intermitente, sujeitos a diferentes níveis de velocidade. Nesse contexto dinâmico, o atrito surge como um fator inevitável, resultando em aquecimento e desgaste.

Para diminuição desses efeitos adversos, a elaboração de um plano de lubrificação inteligente desempenha um papel crucial. Garantir lubrificação adequada implica em planejamento e programação cuidadosos, levando em consideração o tipo e a quantidade de lubrificante a ser utilizado, bem como o momento e o local de aplicação. A gestão integrada desses aspectos constitui o que denominamos como plano de lubrificação.

2.8 Manutenção

2.8.1 Planejamento e Controle da Manutenção

Segundo Xenos (1998), a minimização das falhas prematuras dos equipamentos é influenciada por dois fatores fundamentais. O primeiro consiste no estabelecimento de uma comunicação eficaz entre as diferentes áreas envolvidas, enquanto o segundo refere-se ao Método de Prevenção da Manutenção. Esse método, conforme definido pelo autor, envolve a realização de atividades em colaboração com os fabricantes dos equipamentos, reduzindo a necessidade de intervenções de manutenção durante sua operação.

Segundo Andrade e Silva (2009) enfatiza., o avanço tecnológico impulsionou a adoção da técnica de manutenção preditiva, empregando computadores e sensores acoplados a programas para monitorar o estado dos equipamentos. A análise dos dados encontrados permite a detecção de anomalias e a elaboração do diagnóstico de falhas por meio da comparação com dados previamente registrados.

Conforme evidenciado por Ribeiro e Fogliatto (2009), outro fator importante é o da confiabilidade, cada vez mais relevante na área de manutenção. A adoção de uma abordagem centrada na confiabilidade permite estabelecer estratégias de reparo mais eficazes para os equipamentos, promovendo maior segurança operacional com benefícios aprimorados e custos reduzidos.

2.8.2 Disponibilidade de ativos críticos

Segundo Kardec e Nascif (2009), a disponibilidade é uma medida da capacidade do projeto de estar plenamente operacional em termos de sua confiabilidade, manutenibilidade e suporte técnico em um determinado momento ou período de tempo. Os autores também observam que o grau de disponibilidade pode ser categorizado em intrínseca, técnica e operacional.

Para Xenos (1998), a principal distinção entre essas classificações reside no tempo médio de disponibilidade do ativo. Nem a disponibilidade intrínseca nem a disponibilidade técnica levam em conta o tempo adicional necessário para logística, espera, atrasos e outros períodos durante a manutenção. Em outras palavras, essas formas de disponibilidade refletem a proporção de tempo em que o ativo está operacional.

2.9 Machine Learning

Machine Learning (ML), ou Aprendizagem de Máquina, refere-se a um conjunto de técnicas utilizadas para capacitar computadores a resolver problemas complexos, por meio de um conjunto de dados que envolvem características e respostas esperadas. Esse conjunto de informações pode incluir textos, imagens, valores de sensores, entre outros.

Segundo IBM (2018), a principal diferença entre ML e as técnicas tradicionais de *software* é que, enquanto as técnicas tradicionais utilizam um conjunto de regras definidas para gerar respostas esperadas, ML cria suas próprias regras através do aprendizado baseado em dados históricos fornecidos durante o treinamento do algoritmo. Dessa forma, o sistema de ML é capaz de aprimorar continuamente sua taxa de sucesso, por meio da análise constante de seus próprios resultados.

Norvig (2010) destaca que há três principais técnicas de *feedback* utilizadas no aprendizado de ML:

- **Aprendizado supervisionado:** onde um conjunto de entradas e saídas é fornecido para que uma regra geral seja criada, com o auxílio de um professor.
- **Aprendizado não-supervisionado:** onde apenas um conjunto de entradas é disponibilizado, sem a correspondência de uma saída correta.
- **Aprendizado por reforço:** onde o sistema interage com o ambiente e recebe recompensas para ajustar suas respostas, criando uma metodologia de melhoria contínua.

2.9.1 Etapas do aprendizado supervisionado

A abordagem para resolver um problema de aprendizado supervisionado envolve diversas etapas essenciais. Primeiramente, é crucial definir claramente o problema a ser resolvido. Em seguida, procede-se à identificação e à coleta dos dados necessários para a análise. Os dados coletados são então pré-processados para garantir sua qualidade e relevância. Após o pré-processamento, os dados são divididos em conjuntos de treino e de teste. O próximo passo é a seleção do algoritmo apropriado para a tarefa em questão, seguida pelo seu treinamento e ajuste fino dos parâmetros. Finalmente, o modelo é validado utilizando o conjunto de dados de teste para avaliar seu desempenho (KOTSIANTIS *et al.*, 2007).

2.9.2 Identificação do problema

Os problemas de aprendizado supervisionado podem ser classificados em duas categorias principais: problemas de classificação e problemas de regressão Maimon e Rokach (2005). Nos problemas de classificação, a meta é prever uma etiqueta de classe, determinando a qual categoria, dentre uma lista predefinida, os dados pertencem. Em contraste, nos problemas de regressão, o objetivo é estimar um valor contínuo, geralmente representado por um número de ponto flutuante ou real (WILD *et al.*, 2017).

2.9.3 Coleta e identificação dos dados

Após a definição do problema, próxima etapa envolve a coleta e identificação dos dados. Esse processo, conhecido como *Feature Engineering*, é composto por quatro fases principais

sendo, *brainstorming*, criação, seleção e avaliação.

Na fase de *brainstorming*, o objetivo é compreender o domínio do problema e reunir informações que ajudem a identificar os atributos (*features*) mais representativos dos dados. Se um especialista não estiver disponível, é recomendável coletar o máximo possível de informações sobre diversas *features*, na esperança de isolar as variáveis mais relevantes (PULGA et al., 2020).

Durante a fase de criação, as *features* são desenvolvidas. Na etapa de seleção, algumas *features* podem ser removidas ou expandidas conforme necessário. A fase de avaliação envolve a estimativa da qualidade do modelo utilizando aquelas que forem selecionadas Pulga *et al.* (2020).

A coleta de dados frequentemente resulta em conjuntos de dados com valores faltantes e ruídos, necessitando de uma subsequente etapa de pré-processamento para limpar e preparar os dados Kotsiantis *et al.* (2007).

2.9.4 Pré-processamento

Segundo Ling *et al.* (2003), a etapa de pré-processamento dos dados pode ser mais demorada e complexa do que a própria coleta e identificação dos dados. Os autores destacam alguns motivos pelos quais essa fase é crucial:

- Dados reais podem ser incompletos, ruidosos e inconsistentes, o que pode mascarar padrões valiosos.
- A preparação dos dados resulta em um conjunto menor e mais refinado, melhorando significativamente a eficiência da mineração de dados.
- A preparação dos dados gera dados de alta qualidade, facilitando a identificação de padrões relevantes e confiáveis.

Mainmon e Rokach (2005) mencionam alguns métodos genéricos para a preparação dos dados:

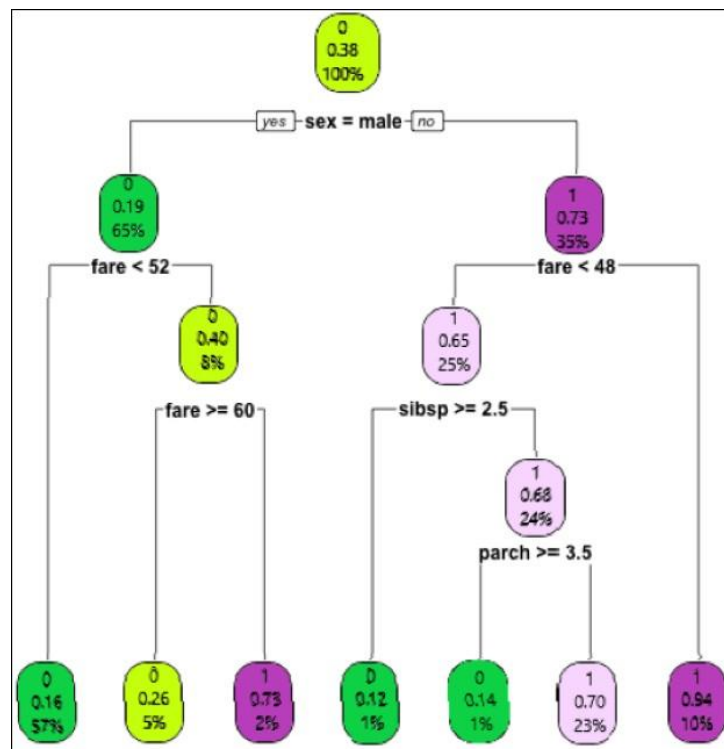
- Estatístico: identificação de *outliers* utilizando valores como média, desvio padrão e intervalo baseados no teorema de Chebyshev, considerando o intervalo de confiança para cada campo.
- Agrupamento: identificação de *outliers* através de técnicas de agrupamento baseadas na distância euclidiana (ou outras métricas).

- Padrão de Comportamento: identificação de *outliers* que não estão em conformidade com os padrões dos dados existentes.

2.9.5 Árvore de Decisão

De acordo com Learn (2021), a árvore de decisão é uma técnica de aprendizado supervisionado não paramétrico, empregada tanto para classificação quanto para regressão. Seu propósito é desenvolver um modelo que preveja o valor de uma variável-alvo, aprendendo regras de decisão simples extraídas dos recursos dos dados. Pode-se conceituar uma árvore de decisão como uma aproximação fragmentada. A Figura 8 a seguir demonstra um modelo esquemático da árvore de decisão.

Figura 8 – Modelo esquemático da árvore de decisão.



Fonte: Adaptado de Pedregosa *et al.* (2011).

De acordo Monard e Baranaukas (2003), os algoritmos que implementam o método de árvores de decisão pertencem à família de algoritmos denominada *Top Down Induction of Decision Trees* (TDIDT). As árvores de decisão são estruturas de dados compostas por nós-folha, representando uma classe e marcando o "fim de uma decisão", e nós de decisão, que correspondem a testes de atributos. Cada resposta ao teste direciona a decisão para uma aresta diferente da árvore.

2.9.6 ANN (*Artificial Neural Networks*)

As Redes Neurais Artificiais (ANN) têm sido amplamente utilizadas para resolver problemas de regressão complexos em diversas áreas, principalmente devido à sua capacidade de modelar relações não lineares e generalizar padrões de dados. Segundo Lecun *et al.* (2015), as ANN possuem uma estrutura hierárquica de camadas que permite a captura de características de alta ordem, tornando-as eficazes em domínios como visão computacional, reconhecimento de padrões e previsão de séries temporais. Além disso, Hastie *et al.* (2009) destacam que as ANN são mais adequadas para grandes conjuntos de dados devido à sua escalabilidade, o que as torna uma escolha popular em problemas complexos que envolvem grandes quantidades de variáveis e interações não triviais.

2.9.7 LSTM (*Long Short-Term Memory*)

As redes *Long Short-Term Memory*, são um tipo específico de redes recorrentes, destacando-se na modelagem de dados temporais, especialmente quando existem dependências de longo prazo entre as observações. De acordo com Hochreiter e Schmidhuber (1997), as LSTMs foram projetadas para resolver o problema de gradiente em redes recorrentes tradicionais, tornando-as mais eficientes em capturar padrões temporais complexos, o que é essencial em áreas como previsão de séries temporais e processamento de linguagem natural.

2.10 Linguagem de Programação Python

Python é um *software* de código aberto com uma licença compatível com a *General Public License* (GPL), o que permite sua incorporação em produtos proprietários devido à sua natureza menos restritiva. A especificação da linguagem é mantida pela *Python Software Foundation* (PSF).

A eficiência e simplicidade do Python são resultado de sua sintaxe clara e objetiva, o que favorece a legibilidade do código-fonte. Python é uma linguagem interpretada, o que possibilita a automação de tarefas e a integração de funcionalidades em aplicativos como *LibreOffice*, *PostgreSQL* e *Blender*. A interpretação da linguagem é realizada por meio de *bytecode* pela máquina virtual Python, tornando o código facilmente portátil entre diferentes sistemas, simplificando assim a compilação de aplicativos em várias plataformas (BORGES, 2014).

2.11 Bibliotecas Python

2.11.1 Pandas

Segundo Coelho (2007), utilizando o *Pandas*, torna-se simples carregar uma variedade de arquivos para análise de dados, incluindo formatos como *.xls*, *.xlsx* e *.csv*. Segundo o autor ao serem importados

para o programa, esses arquivos são tratados como *dataframes*, que são acessados por meio da função de mesmo nome.

De acordo com Borges (2014), é comum importar *dataframes* do Pandas de fontes externas de dados para ampliar a flexibilidade na análise de dados. Essas estruturas, conhecidas por serem bidimensionais, são tipicamente organizadas em linhas e colunas.

2.11.2 Numpy

Conforme destacado por Coelho (2007), o *Numpy* figura como um dos principais conjuntos de ferramentas para a aplicação da linguagem *Python* no campo da computação científica. Esse pacote se destina à resolução eficiente de problemas numéricos. No contexto de programas voltados para *Machine Learning*, a função *array* emerge como uma das mais empregadas do conjunto. Essa função é responsável por criar uma estrutura de dados que organiza as informações categoricamente, conforme as colunas da base de dados fornecida.

2.11.3 Scikit-Learn

A *Scikit-Learn*, também conhecida como *sklearn*, é uma biblioteca de código aberto para *Machine Learning* desenvolvida para a linguagem de programação *Python*. Ela oferece uma ampla gama de algoritmos para classificação, regressão e agrupamento de dados (LEARN, 2021).

2.11.4 Matplotlib

Para Coelho (2007) o conjunto de funções disponíveis no *matplotlib.pyplot* oferece uma variedade de opções para a criação de diferentes formas gráficas. O recurso de plotagem é particularmente versátil, permitindo a apresentação visual de dados de maneira eficaz. o *Matplotlib* é uma biblioteca de software amplamente empregada na criação de gráficos 2D e na visualização de dados de forma abrangente. O pacote foi concebido por John Hunter (1968-2012), em colaboração com outros cientistas, resultando em uma ferramenta agora utilizada em inúmeras pesquisas.

3 METODOLOGIA

3.1 Tipos de Pesquisa

Nesta seção, será apresentada a classificação da pesquisa em dois tipos principais: pesquisa quantitativa e pesquisa qualitativa. A pesquisa quantitativa, conforme Polit e Hungler (2007), enfatiza o raciocínio dedutivo, as regras de lógica e os aspectos mensuráveis da experiência humana. Segundo Gil (2008), por meio de testes estatísticos, é possível expressar em resultados numéricos a probabilidade de uma conclusão específica estar correta, assim como determinar a margem de erro associada ao valor obtido.

Por outro lado, a pesquisa qualitativa, de acordo com Oliveira (2012), adota uma abordagem que busca compreender o fenômeno em seu contexto próprio. O uso da descrição visa capturar as essências do fenômeno, elucidar sua origem e inferir resultados sem a necessidade de cálculos numéricos.

Geralmente, essa classificação é mutuamente excludente: ou a pesquisa é quantitativa ou qualitativa. Neste trabalho, embora se lide com resultados numéricos, a ausência de testes estatísticos para validação de hipóteses posiciona a abordagem adotada como primordialmente qualitativa, enfatizando a compreensão dos fenômenos estudados e suas relações no contexto indústria

3.2 Classificação da Pesquisa Quanto aos Objetivos

As pesquisas com base em seus objetivos se dividem em três tipos: exploratória, descritiva e explicativa. A pesquisa exploratória tem como objetivo principal desenvolver, esclarecer e modificar conceitos e ideias, visando formular problemas mais precisos ou hipóteses para investigações posteriores. Métodos como levantamento bibliográfico e documental, entrevistas não estruturadas e estudos de caso são comuns nesse tipo de pesquisa, Gil (2008).

A pesquisa descritiva, também abordada por Galvão e Ricarte (2019), concentra-se na caracterização de uma determinada população ou fenômeno, bem como no estabelecimento de relações entre variáveis. Uma característica distintiva desse tipo de pesquisa é o uso de técnicas padronizadas de coleta de dados, como questionários e observações sistemáticas.

Conforme Marconi e Lakatos (2003) as pesquisas explicativas buscam estabelecer modelos teóricos, gerando hipóteses por meio de uma abordagem lógica, com experimentos que envolvem a identificação, registro, análise e interpretação das causas dos efeitos de um processo.

Com base nas abordagens adotadas, este trabalho é caracterizado como exploratório, pois visa desenvolver e experimentar o uso de *Machine Learning* para prever desgaste em uma indústria cimenteira. Apesar de lidar com resultados numéricos e utilizar métricas como o erro

quadrático médio (MSE) e o coeficiente de determinação (R^2) para analisar a precisão das previsões, o trabalho não emprega os testes estatísticos característicos da pesquisa quantitativa. Assim, sua abordagem é exploratória com predominância qualitativa, alinhando-se à busca de compreensão e análise aprofundada do fenômeno estudado.

3.3 Materiais e Métodos

Nesta seção, serão apresentados os materiais utilizados e os métodos empregados no desenvolvimento de dois programas: o Indicador de Falhas para a análise de disponibilidade física do equipamento e o Controle de Desgaste do Moinho Vertical de Rolos. Ambos os programas foram desenvolvidos com o objetivo de auxiliar na gestão e manutenção preditiva do equipamento, proporcionando uma visão detalhada tanto das falhas que podem ocorrer durante a operação quanto da previsão do desgaste das capas dos rolos.

3.3.1 Materiais

Diversos materiais foram empregados no decorrer deste estudo, incluindo manuais, livros, artigos, monografias, softwares, entre outros recursos. A metodologia adotada baseou-se em uma abordagem experimental, com o *Anaconda 3* selecionado como a principal ferramenta de software. As bibliotecas *pandas*, *numpy*, *matplotlib* e *Scikit-learn* foram utilizadas como componentes essenciais para o desenvolvimento dos programas. A coleta de dados, identificação das variáveis, criação dos *dataset*, desenvolvimento do algoritmo, realização de testes e análises das vantagens e limitações associadas foram os principais processos executados ao longo do estudo.

3.3.2 Métodos

Para a etapa de desenvolvimento, para criação do banco de dados conhecido como *dataset* foram utilizado o arquivo no formato csv e xlsx, onde os dados foram coletados a partir de pesquisa direta, através da programação de manutenção e das planilhas de controle do Moinho Vertical de Rolos, de inspeções preventivas e medições na rotina de uma indústria cimenteira. Os *dataset* contém informações detalhadas sobre operação, manutenção e condições do equipamento. No Apêndice B, estão presentes dos conjuntos como exemplo de *dataset*.

3.4 Metodologia Prática

3.4.1 Metodologia de Classificação: Árvore de Decisão

A árvore de decisão utilizada neste trabalho toma suas decisões com base na minimização de uma *função de custo* que visa separar os dados da forma mais pura possível em cada nó. Essa função de custo pode ser a *Impureza de Gini* ou a *Entropia*, e ambas medem o grau de desordem ou impureza nos dados. O objetivo é selecionar a divisão que reduz ao máximo essa impureza em cada passo da construção da árvore.

A *Impureza de Gini* é uma métrica que calcula a probabilidade de que um exemplo, escolhido aleatoriamente de um conjunto, seja classificado incorretamente se for atribuído de acordo com a distribuição das classes do conjunto. A fórmula matemática para a impureza de Gini é dada por:

$$Gini(D) = 1 - \sum_{i=1}^c p_i^2$$

Onde:

- D representa o conjunto de dados;
- C é o número total de classes;
- p_i é a proporção de exemplos pertencentes à classe i dentro do conjunto de dados D

Outra métrica utilizada é a *Entropia*, que tem como base a Teoria da Informação e mede o grau de incerteza presente nos dados. Ela é definida pela fórmula:

$$Entropia(D) = - \sum_{i=1}^c p_i \log_2(p_i)$$

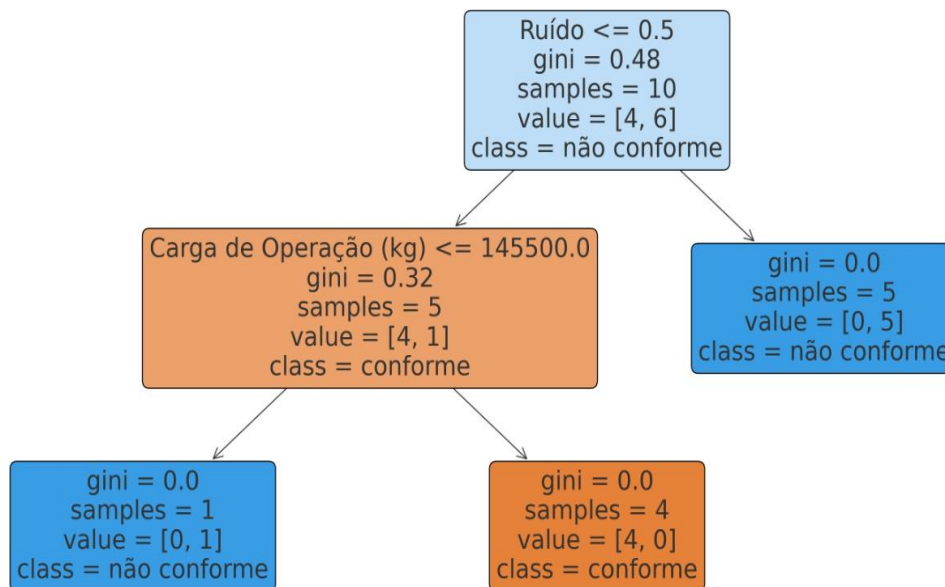
A entropia atinge seu valor mínimo quando todos os exemplos pertencem à mesma classe, e seu valor máximo quando as classes estão igualmente distribuídas (ou seja, o maior nível de incerteza). Assim, a árvore de decisão busca realizar divisões que maximizem o *ganho de informação*, ou seja, a redução da entropia após uma divisão dos dados.

3.4.2 Processo de Decisão

A árvore de decisão, em cada nó, avalia todos os possíveis pontos de divisão dos atributos e calcula qual deles minimiza a função de custo (seja a impureza de Gini ou a entropia). A divisão selecionada é aquela que gera os subconjuntos de dados mais "puros" possíveis como pode se observar na Figura 9. O processo continua de forma recursiva em cada novo subconjunto até que um critério de parada seja atingido (por exemplo, quando todos os exemplos de um nó pertencem à mesma classe ou a árvore atingirem uma profundidade máxima).

Em termos simples, a árvore de decisão está criando regras de decisão do tipo "se-então" que são aplicadas em sequência. Por exemplo, a árvore pode aprender uma regra do tipo "Se a carga de operação do moinho é menor ou igual a 148.000 kg e a vibração excessiva está presente, então o equipamento está não conforme."

Figura 9 – Fluxograma da árvore de decisão.



Fonte: Autores (2024).

3.4.3 Ganho de Informação


O *Ganho de Informação* é a diferença entre a entropia do conjunto de dados antes da divisão e a entropia ponderada dos subconjuntos após a divisão. A fórmula para o ganho de informação é:

$$\text{Ganho de Informação} = \text{Entropia}(D_{\text{antes}}) - (w_1 \times \text{Entropia}(D_1) + w_2 \times \text{Entropia}(D_2))$$

Onde w_1 e w_2 são os pesos (proporções) dos subconjuntos após a divisão.

O gráfico a seguir na Figura 10 ilustra um exemplo de ganho de informação, onde uma divisão nos dados reduz a incerteza, resultando em uma entropia menor após a divisão. O ganho de informação é a métrica que a árvore de decisão maximiza para escolher o melhor ponto de divisão nos dados, reduzindo a incerteza e aumentando a pureza dos subconjuntos.

Figura 10 – Exemplo de Ganho de Informação após a divisão dos dados.



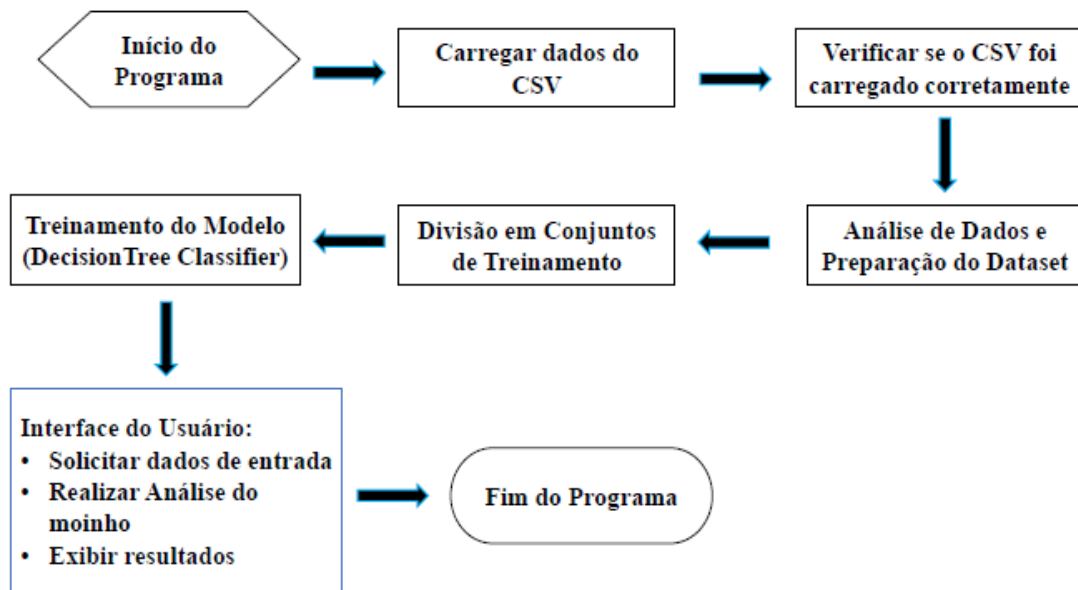
Fonte: Autores (2024).

3.5 Análise de Conformidade e Falhas - Programa 1

3.5.1 Função de Análise de Disponibilidade Física

O primeiro programa foi desenvolvido com o objetivo de realizar uma análise da disponibilidade física do Moinho Vertical de Rolos, utilizando técnicas de aprendizado de máquina para prever o condição de operação do equipamento. As etapas do programa estão presente do Fluxograma da Figura 11.

Figura 11 – Fluxograma da função Análise de Conformidade Física.



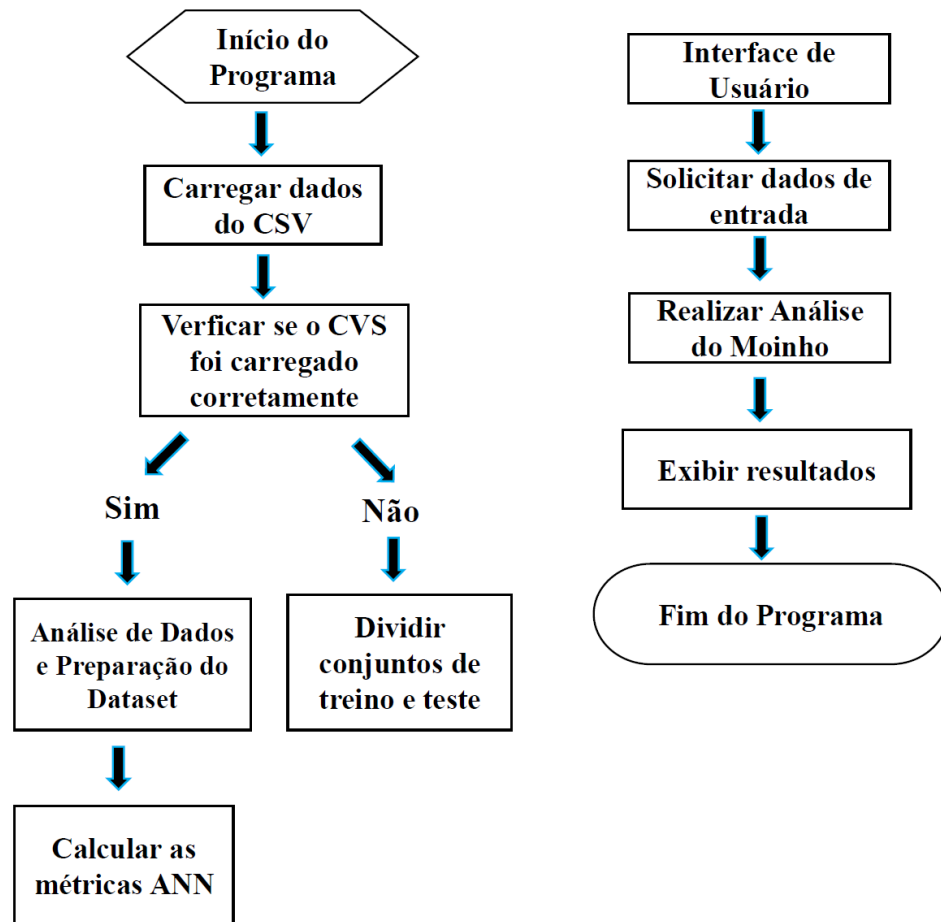
Fonte: Autores (2024).

3.5.2 Função de Indicação de Falhas do Equipamento

O programa também conta com uma funcionalidade específica para o monitoramento das falhas do equipamento, denominada "Indicador de Falhas". Esta função é essencial para registrar ocorrências e gerar relatórios detalhados sobre as falhas observadas no moinho vertical de rolos. A função permite ao usuário registrar e visualizar tendências de falhas.

O fluxograma apresentado na Figura 12 ilustra de maneira clara e sequencial o funcionamento da função "Indicador de Falhas". Ele descreve o processo desde o momento em que uma falha é registrada pelo usuário até a geração de um relatório final. O fluxo começa com a entrada de dados relacionados à falha, como o código e descrição, passando pelo diagnóstico da causa provável e identificação da solução recomendada. Em seguida, o programa atualiza as tendências de falhas, permitindo uma visualização gráfica dessas ocorrências. Por fim, o sistema gera um relatório consolidado, contendo todas as falhas registradas, suas causas e as soluções propostas.

Figura 12 – Fluxograma da função de Indicador de Falhas .



Fonte: Autores (2024).

3.5.3 Validação do Modelo 1

A validação do modelo foi realizada utilizando a métrica de acurácia, que mede a proporção de previsões corretas feitas pelo modelo com relação ao status real do equipamento. O modelo apresentou um desempenho satisfatório, com um alto nível de acurácia tanto nos dados de treino quanto nos dados de teste.

Além disso, foi implementada uma validação cruzada com K-fold, dividindo os dados em 5 subconjuntos (K=5), onde cada subconjunto foi utilizado como conjunto de teste uma vez, enquanto os outros foram utilizados para treino. Essa abordagem permitiu uma avaliação mais robusta do modelo, garantindo sua capacidade de generalização.

3.6 Metodologia de Previsão: ANN e LSTM

A previsão de desgaste foi realizada utilizando dois modelos de aprendizado profundo: *Redes Neurais Artificiais* (ANN) e *Long Short-Term Memory* (LSTM), ambos adequados para modelar problemas temporais e não-lineares.

3.6.1 Redes Neurais Artificiais (ANN)

As Redes Neurais Artificiais (ANN) são compostas por camadas de neurônios artificiais que transformam um conjunto de entradas em saídas por meio de uma série de operações lineares seguidas de uma função de ativação não linear. A equação geral para um neurônio em uma ANN é:

$$y = f\left(\sum_{i=1}^n w_i X_i + b\right)$$

Onde:

- x_i são as entradas,
- w_i são os pesos associados às entradas,
- b é o *bias*,
- f é a função de ativação (neste caso, *ReLU*, definida como $f(x) = \max(0, x)$).

O modelo ANN usado foi composto de três camadas principais:

- Camada de entrada: Composta pelos índices de medição.
- Camadas ocultas: Duas camadas com 32 e 16 neurônios, respectivamente, com a função de ativação *ReLU* e regularização *Dropout* de 20% para evitar *overfitting*.
- Camada de saída: Retorna as previsões de desgaste nas várias posições do equipamento.

3.6.2 Redes LSTM

As Redes Neurais Artificiais (ANN) foram utilizadas para prever o desgaste dos rolos devido à sua capacidade de modelar relações complexas entre as variáveis de entrada (parâmetros de operação e manutenção) e a saída (desgaste em mm). No modelo utilizado, a ANN consiste em múltiplas camadas de neurônios interconectados, que processam os dados de forma hierárquica.

Cada neurônio recebe um conjunto de entradas ponderadas, realiza uma soma ponderada e aplica uma função de ativação para introduzir a não linearidade necessária. A saída de cada neurônio é obtida pela seguinte equação:

$$z = w_1x_1 + w_2x_2 + \dots + w_nx_n + b$$

Onde w são os pesos, x são as entradas e b é o viés. Os pesos w são ajustados durante o treinamento da rede para minimizar a diferença entre a previsão da rede e os valores reais.

A função de ativação utilizada é a ReLU (Rectified Linear Unit), que define a saída do neurônio como:

$$\sigma(z) = \max(0, z)$$

A função ReLU é escolhida por sua capacidade de evitar o problema do gradiente dissipado, proporcionando uma aprendizagem mais rápida e eficiente em redes profundas. Durante o treinamento, o objetivo da rede é minimizar o erro de previsão, que é medido pela função de perda:

$$Loss = \frac{1}{N} \sum_{i=1}^N (y_i - Y_i)^2$$

Onde y_i são os valores reais e \hat{y}_i são os valores preditos pela rede. O processo de otimização é feito pelo algoritmo de gradiente descendente, ajustando os pesos para minimizar essa função de perda.

As Redes LSTM (Long Short-Term Memory) foram utilizadas para capturar as dependências temporais no desgaste dos rolos, já que esses modelos são adequados para lidar com séries temporais e dados sequenciais. O desgaste dos rolos, sendo acumulativo ao longo do tempo, apresenta uma relação temporal que os modelos LSTM são capazes de capturar com eficiência.

As LSTM são uma classe especial de Redes Neurais Recorrentes (RNN) que têm a capacidade de memorizar informações de longo prazo utilizando suas células de memória controladas por portas (*gates*). O funcionamento de uma célula LSTM é descrito pelas seguintes equações:

1. Porta de Esquecimento f_t :

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

Esta porta decide quanto da informação passada da célula de memória anterior C_{t-1} deve ser "esquecida" para que o modelo não mantenha informações irrelevantes.

2. Porta de Entrada i_t :

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

A porta de entrada decide quanto da nova informação \tilde{C}_t , gerada pela célula LSTM, deve ser adicionada ao estado da célula.

3. Atualização da Célula de Memória \tilde{C}_t :

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$$

A célula de memória C_t armazena as informações relevantes ao longo das etapas de tempo, permitindo que a LSTM mantenha informações sobre a série temporal do desgaste.

4. Porta de Saída o_t :

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

Logo, a porta de saída decide qual parte da célula de memória será usada para gerar a próxima previsão. A saída da célula LSTM é calculada como:

$$h_t = o_t \cdot \tanh(C_t)$$

A escolha da ANN justifica-se pela sua capacidade de capturar padrões complexos e modelar a não linearidade no comportamento do desgaste, permitindo previsões mais precisas.

3.7 Previsão e Controle do Desgaste - Programa 2

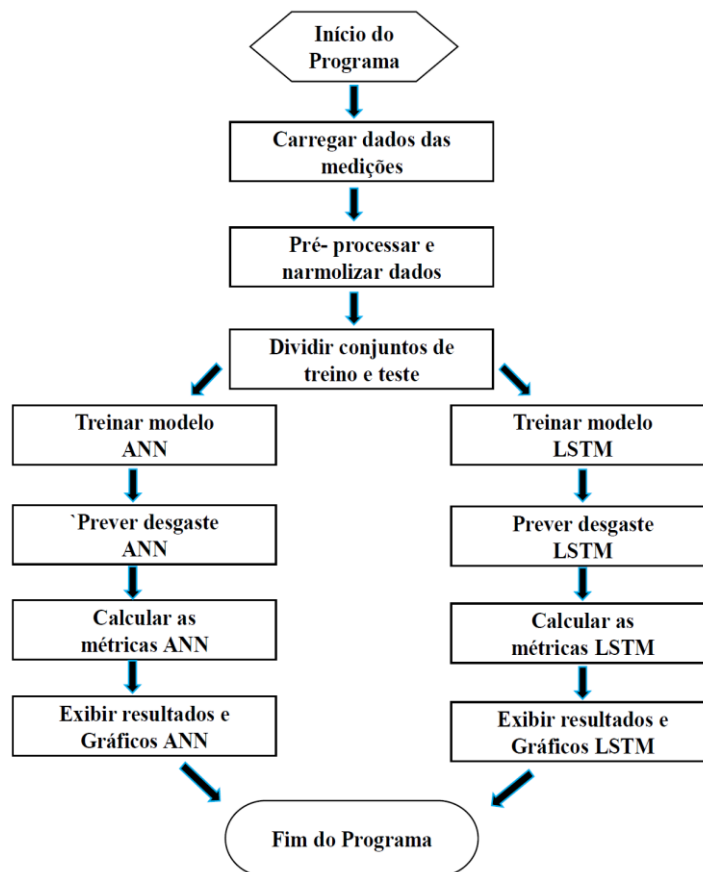
Para o desenvolvimento do modelo de previsão de desgaste, foram utilizados três conjuntos de dados distintos, denominados RoloM1, RoloM2 e RoloM3, correspondentes a três dispositivos de moagem que são monitorados em um processo industrial. Cada um desses conjuntos de dados contém dois subconjuntos: Real e Parcial. O subconjunto Real contém todas as medições realizadas ao longo do tempo, enquanto o subconjunto Parcial possui medições até um determinado ponto, sendo utilizado como base para realizar as previsões das medições futuras.

O principal objetivo do programa é prever o desgaste futuro e a data para programação de troca dos rolos Rolo M1, M2 e M3 a partir dos dados parciais. A previsão é realizada para as dezesseis medições futuras, ou seja, o objetivo do programa é completar as medições parciais

(com até 8 medições) até a medição de número 24, que é o pontofinal de interesse para o controle de desgaste dos rolos. As previsões dos três algoritmos são combinadas, e a média dessas previsões é utilizada como a previsão final para cada posição.

Além das previsões, o programa também realiza a avaliação do modelo usando as métricas R^2 (coeficiente de determinação) e MSE (erro quadrático médio). As previsões são comparadas com os valores reais para medir a precisão do modelo e garantir que as previsões estejam próximo a um limite aceitável. A Figura 13 a seguir possui um fluxograma que resume as principais etapas do programa de previsão do desgaste.

Figura 13 – Fluxograma do programa de previsão do desgaste.



Fonte: Autores (2024).

3.7.1 Validação do modelo 2

A fase de validação citada do modelo citada anteriormente é crucial para avaliar tanto a precisão quanto a capacidade de generalização do modelo em relação aos dados de treino e

teste. Para isso, foram analisados os valores do coeficiente de determinação (R^2) para ambos os conjuntos de dados. O coeficiente de determinação varia de 0 a 1, onde valores próximos de 1 indicam um melhor ajuste do modelo aos dados observados. No entanto, é importante verificar se o modelo não apresenta viés.

O *Coefficiente de Determinação* (R^2) e o *Erro Quadrático Médio* (MSE) se dá pela seguinte equação:

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

Onde:

- y_i são os valores reais
- \hat{y}_i são os valores previstos
- \bar{y} é a média dos valores reais

Usando este método, são obtidos N valores do coeficiente de correlação, em seguida, calcula-se a média. Em vez de obter um único valor de coeficiente de correlação, a análise dos resíduos (ou erros) também é utilizada. Os resíduos representam a variação entre o valor previsto e o valor real da variável dependente usando modelos ajustados.

Neste trabalho, foi aplicado o erro quadrático médio e o MSE da sigla em inglês *Mean Squared Error*:

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

Onde:

- Y_i : valores reais dos dados
- \hat{Y}_i : valores previstos ajustados pelo modelo
- n : número de observações

Dado o tamanho relativamente pequeno do conjunto de dados, foi aplicada a técnica de validação cruzada. Esta técnica é útil para dividir os dados em grupos de treino e teste de maneira mais eficiente. Em vez de apenas separar os dados em dois grupos (aproximadamente

75% para treino e 25% para teste), a validação cruzada divide os dados em K grupos.

Um desses grupos é utilizado como grupo de teste, enquanto os outros $K-1$ grupos são usados para treinar o modelo. Esse processo é repetido até que cada grupo tenha sido utilizado como grupo de teste, proporcionando K diferentes estimativas do coeficiente de determinação (MÜLLER, 2017).

4 RESULTADOS E DISCUSSÃO

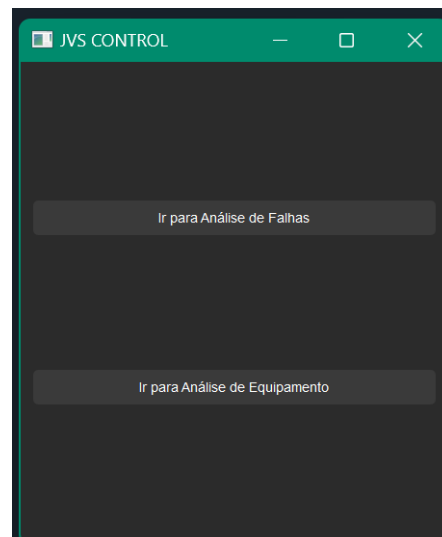
4.1 Programa 1 - Análise de Conformidade e Falhas.

Esta seção apresenta e discute os resultados obtidos pelo programa desenvolvido para análise de falhas com técnicas de *Machine Learning*, utilizando interface gráfica para visualização e interpretação dos dados. O programa integrou o algoritmo classificador baseado em árvore de decisão para prever as causas de falhas em sistemas industriais, além de oferecer funções adicionais.

4.1.1 Interface Inicial do Programa

A interface inicial do programa desenvolvido apresenta um *layout* simplificado ao usuário, para facilitar a navegação entre as funções principais de análise de falhas e análise de equipamentos. Na Figura 14, observa-se a tela inicial, com dois botões principais: “Análise de Falhas” e “Análise de Equipamento”. Esse *design* permite que o operador escolha rapidamente a funcionalidade desejada.

Figura 14 – Interface Inicial do Programa 1.



Fonte: Autores (2024).

4.1.2 Análise de Equipamento

As variáveis utilizadas como parâmetros para a análise da disponibilidade física do moinho foram selecionadas com base em sua relevância para o desempenho e operação do equipamento, conforme pode ser observado no Quadro 1.

Quadro 1 – Variáveis utilizadas na análise da disponibilidade física do moinho

Variável	Descrição
Carga de Operação	Quantidade de material processado pelo Moinho (ton.)
Temperatura	Temperatura de operação do equipamento (°C)
Vibração	Nível de vibração do moinho durante a operação (Hz)
Velocidade angular da Mesa de Moagem	Velocidade de rotação da mesa de moagem em (rpm)
Velocidade angular Classificador	Velocidade de rotação do classificador em (rpm)

Fonte: Autores (2024).

As variáveis descritas no Quadro 1 são analisadas para determinar o status de operação do moinho, classificando-o como "conforme" ou "não conforme". A conformidade refere-se ao fato de o equipamento estar operando dentro dos parâmetros estabelecidos de forma segura e eficiente.

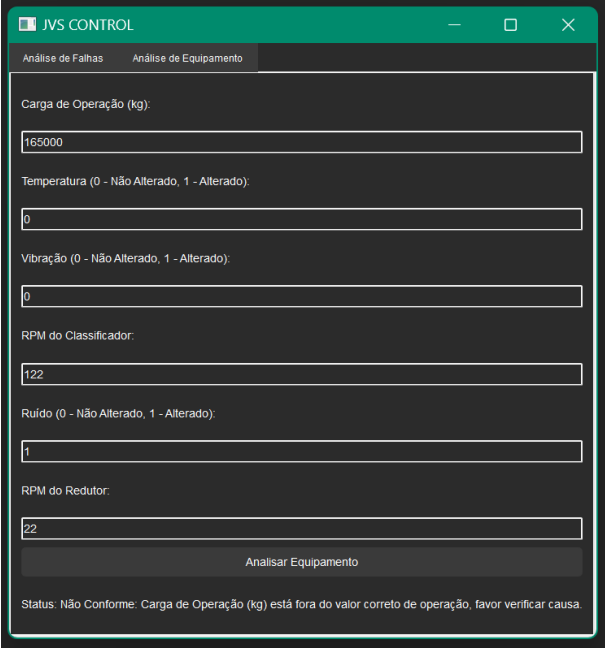
Na função de análise de equipamento, o programa permite que o usuário insira dados específicos de operação, como Carga de Operação (kg), RPM do Classificador, Vibração, Temperatura, entre outros. A resposta é dada como "Conforme" ou "Não Conforme". A Figura 15 ilustra uma análise onde os parâmetros de entrada correspondem aos valores corretos, resultando em uma análise e resposta "Conforme".

Figura 15 – Interface da função Análise de Conformidade Física - Status de Conformidade.

Fonte: Autores (2024).

Em contrapartida, a Figura 16 exibe a função preenchida com valores discrepantes, levando a uma resposta “Não Conforme”. Nessa situação, o programa fornece uma descrição sobre os parâmetros que estão fora de conformidade, permitindo ao operador identificar rapidamente as variáveis que precisam de ajuste. Esse recurso pode ser útil em aplicações de monitoramento, onde a identificação e a correção de falhas em tempo hábil evitam perdas de eficiência e prolongam a vida útil dos componentes.

Figura 16 – Interface de dados da função Análise de Conformidade Física - *Status* de Não Conformidade.



JVS CONTROL

Análise de Falhas Análise de Equipamento

Carga de Operação (kg):
165000

Temperatura (0 - Não Alterado, 1 - Alterado):
0

Vibração (0 - Não Alterado, 1 - Alterado):
0

RPM do Classificador:
122

Ruído (0 - Não Alterado, 1 - Alterado):
1

RPM do Redutor:
22

Analisar Equipamento

Status: Não Conforme. Carga de Operação (kg) está fora do valor correto de operação, favor verificar causa.

Fonte: Autores (2024).

4.1.3 Indicador de Falhas: Gráfico de Ocorrências

O Quadro 2 apresenta as principais variáveis utilizadas para a análise de falhas, como o código da falha, sua descrição, causa provável e a solução recomendada, oferecendo uma visão clara e organizada das informações tratadas pelo sistema (LOESCHE, 2012).


Quadro 2 – Variáveis utilizadas na análise de falhas do moinho

Variável	Descrição
CÓDIGO	Identificador numérico único para cada tipo de falha registrada.
FALHA	Descrição da falha ocorrida no equipamento, como "Desligamento inesperado" ou "Vibração elevada".
CAUSA	Causa provável da falha, baseada em diagnósticos históricos, como "Pressão do ar de bloqueio muito baixa" ou "Baixo nível de óleo".
SOLUÇÃO	Ação recomendada para resolver ou mitigar a falha, como "Restabelecer o sistema do ar de bloqueio" ou "Reabastecer lubrificante".

Fonte: Autores (2024).

A função de “Indicador de Falhas” agrega e exibe graficamente o histórico de falhas registradas, conforme ilustrado na Figura 17. Este gráfico facilita a visualização das falhas mais recorrentes e a análise de tendências, o que é crucial para o planejamento de manutenção preventiva. A apresentação gráfica das falhas permite que engenheiros e técnicos identifiquem rapidamente problemas crônicos, possibilitando intervenções direcionadas e eficientes. Em contextos industriais, o uso de gráficos para representar informações de falhas se mostra uma prática de grande valor para a visualização de dados complexos, oferecendo suporte visual direto para a tomada de decisões.

Figura 17 – Gráfico de Tendência de Falhas.

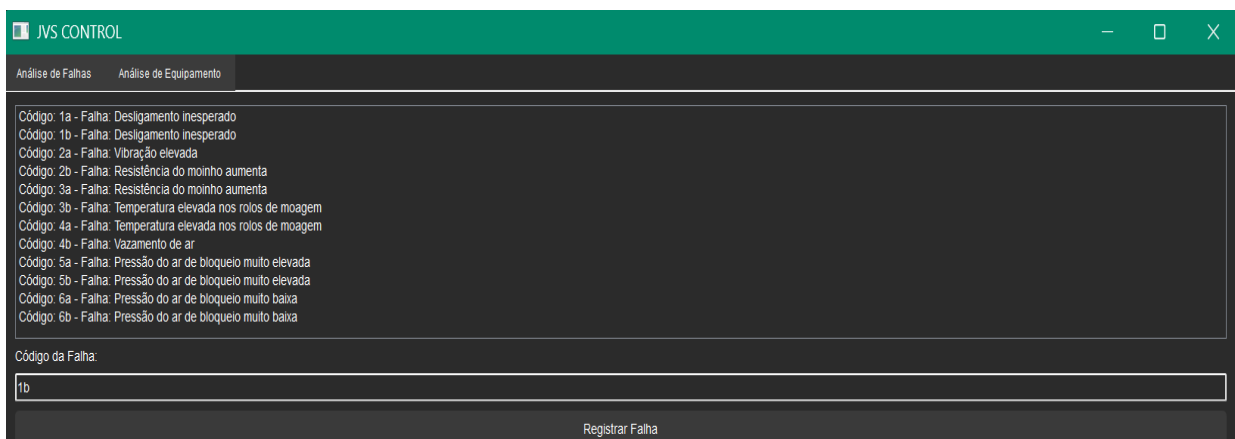


Fonte: Autores (2024).

4.1.4 Registro de Falhas: Identificação de Causas e Soluções

Outro aspecto fundamental do programa é o sistema de registro de falhas, que, ao ser inserido um código de falha, retorna automaticamente a causa e a solução recomendada. Como exemplificado nas Figura 18 a e 18b, ao inserir um código de falha específico, o programa exibe uma descrição da falha associada, as causas possíveis e as soluções sugeridas. Essa função elimina a necessidade de consultas externas, consolidando informações essenciais no próprio sistema e centralizando dados de falhas, o que contribui significativamente para a eficiência na resolução de problemas, uma vez que possibilita aos operadores uma ação rápida e embasada.

Figura 18 a – Interface da Função Registro de Falhas.



Fonte: Autores (2024).

Figura 18 b – Interface da Função Registro de Falhas.

Código	Falha	Causa	Solução
1	1b - Desligamento inesperado	Mensagem de falha do sistema de lubrificação, pouco lubrificante ou nenhum lubrificante	Reabastecer lubrificante
2	1a - Desligamento inesperado	Pressão do ar de bloqueio muito baixa ou não existe nenhum ar de bloqueio.	Restabelecer o funcionamento do sistema do ar de bloqueio
3	1a - Desligamento inesperado	Pressão do ar de bloqueio muito baixa ou não existe nenhum ar de bloqueio.	Restabelecer o funcionamento do sistema do ar de bloqueio
4	2b - Resistência do moinho aumenta	Anel de blindagem gasto	Substituir os anéis de blindagem
5	2b - Resistência do moinho aumenta	Anel de blindagem gasto	Substituir os anéis de blindagem
6	1 - Desligamento inesperado	Pressão do ar de bloqueio muito baixa ou não existe nenhum ar de bloqueio.	Restabelecer o funcionamento do sistema do ar de bloqueio
7	9 - Pressão do ar de bloqueio muito elevada	Sistema do ar de bloqueio sujo	Limpar o sistema do ar de bloqueio
8	9 - Pressão do ar de bloqueio muito elevada	Sistema do ar de bloqueio sujo	Limpar o sistema do ar de bloqueio

Fonte: Autores (2024).

4.2 Programa 2 - Controle do Desgaste

Os dados foram estruturados em colunas que representam medições em diferentes posições (Pos.1 até Pos.10) ao longo do tempo. Cada linha no conjunto de dados corresponde a uma medição específica, identificada por uma data e um número de medição (Medição 0, Medição 1, etc..). O Quadro 3 desdobre as variáveis presentes em cada conjunto de dados.

Quadro 3 – Variáveis presentes em cada conjunto de dados.

Variável	Descrição
Medições	O número da medição.
Data	A data em que a medição foi realizada.
Pos.1 a Pos.10	Valores numéricos representando o desgaste, em milímetros, em dez posições diferentes ao longo da capa do rolo.

Fonte: Autores (2024).

Nesta seção, são apresentados os resultados preditos de desgaste para os três rolos (M1, M2 e M3) em diferentes posições de medição. Os gráficos comparativos entre o desgaste real e o desgaste previsto para cada uma das dez posições, gerados pelos modelos de aprendizado de máquina, estão disponíveis no Apêndice B. Esses gráficos fornecem uma análise detalhada do desempenho preditivo dos modelos em cada posição individual. A seguir, as seções individuais para os rolos M1, M2 e M3 apresentam o desempenho geral do programa para os dispositivos de desgaste.


4.2.1 Rolo M1

As previsões dos modelos de ANN e LSTM para o desgaste do Rolo M1 revelaram um comportamento semelhante em relação à data estimada para a troca da capa.

- ANN: A previsão indicou que a troca da capa deveria ocorrer em 01 de setembro de 2023, durante a Medição 20, quando o desgaste excedeu o limite estabelecido de 115 mm.
- LSTM: O modelo LSTM também previu a necessidade de troca em 01 de setembro de 2023, na mesma medição (Medição 20), quando o desgaste atingiu o valor crítico de 115 mm.


As Figuras 19 e 20 apresentam a evolução do desgaste ao longo do tempo para o Rolo M1. Na Figura 19, são mostradas as previsões obtidas pelo modelo ANN, enquanto na Figura 20, observa-se a previsão fornecida pelo modelo LSTM. Ambos os gráficos destacam o progresso do desgaste nas dez posições medidas ao longo de 26 medições, com a linha tracejada vermelha representando o limite de 115 mm, ponto em que a troca é necessária para evitar falhas operacionais.

Figura 19 – Previsão de Desgaste segundo ANN para o Rolo M1.



Fonte: Autores (2024).

Figura 20 – Previsão de Desgaste segundo LSTM para o Rolo M1.



Fonte: Autores (2024).

Os resultados comparativos dos dois modelos de predição para o desgaste do Rolo M1 são apresentados na Tabela 1. As métricas de desempenho, como o coeficiente de determinação (R^2) e o erro quadrático médio (MSE), foram utilizadas para avaliar a precisão das previsões. Os valores para cada uma das dez posições são discutidos detalhadamente a seguir.

O desempenho do modelo LSTM mostrou-se superior nas posições 3, 5 e 8, onde obteve valores de mais elevados e menores erros médios quadráticos. No entanto, o modelo ANN apresentou um desempenho notável em outras posições, como 2 e 4, com valores de R^2 extremamente altos, próximos de 1, refletindo previsões muito precisas.

Ambos os modelos, porém, enfrentaram dificuldades para prever com precisão o desgaste nas posições 8 e 10, onde os valores de R^2 foram negativos para pelo menos um dos modelos, indicando um ajuste insuficiente para essas posições.

Tabela 1 – Métricas de desempenho para ANN e LSTM por posição de desgaste - Rolo M1.

Posição (mm)	Modelo	R^2 Médio	MSE Médio
Pos.1	ANN	0,8941	5,3219
	LSTM	0,8941	5,3219
Pos.2	ANN	0,9922	0,2471
	LSTM	0,9723	0,8763
Pos.3	ANN	0,9452	1,1595
	LSTM	0,9854	0,3090
Pos.4	ANN	0,9809	0,2444
	LSTM	0,8513	1,8995
Pos.5	ANN	0,9765	0,2214
	LSTM	0,9769	0,2176
Pos.6	ANN	0,9924	0,4697
	LSTM	0,9578	2,6109
Pos.7	ANN	0,8880	1,7676
	LSTM	0,8874	1,7761
Pos.8	ANN	-0,2353	3,4309
	LSTM	0,9300	0,1945
Pos.9	ANN	0,0423	0,1796
	LSTM	0,0423	0,1796
Pos.10	ANN	0,4457	1,4701
	LSTM	-0,1235	2,9800

A Tabela 2 apresenta os coeficientes de determinação R^2 dos modelos preditivos ANN e LSTM durante as fases de treino e teste para o Rolo M1.


Tabela 2 – Coeficientes de determinação de treino e de teste dos modelos preditivos (ANN e LSTM) - Rolo M1.

Coeficiente de Determinação	ANN	LSTM
Treino	0,692	0,737
Teste	0,692	0,737

Fonte: Autores (2024).

A Figura 21 compara as previsões de desgaste real e predito para os modelos ANN e LSTM, evidenciando que o modelo LSTM apresenta uma *performance* ligeiramente superior, com maior concentração de pontos próximos à linha de referência $y = x$.

Figura 21 – Comparação entre Desgaste Real e Predito para ANN e LSTM - Rolo M1.



Fonte: Autores (2024).

4.2.2 Rolo M2


Houve uma leve diferença nas previsões fornecidas pelos modelos de ANN e LSTM, ambos utilizados para prever o desgaste da capa do rolo M2.

- ANN: A data prevista para a troca da capa foi 06 de junho de 2023, durante a Medição 18, momento em que o desgaste ultrapassou o limite estabelecido de 115 mm.

- Long Short-Term Memory (LSTM): A data prevista para a troca da capa foi 08 de agosto de 2023, durante a Medição 19, onde o desgaste também ultrapassou o limite de 115 mm.

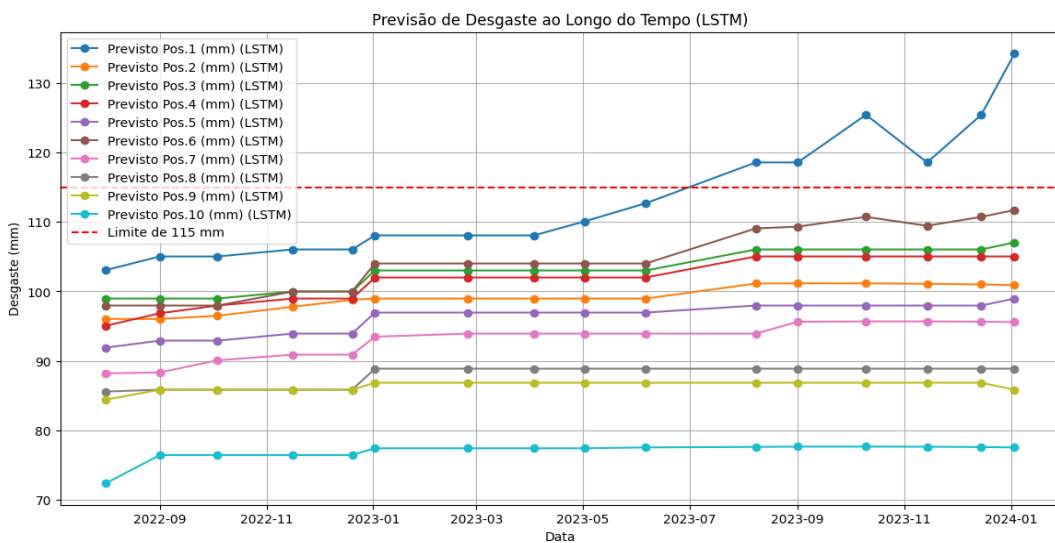
As Figuras 22 e 23 apresentam a previsão de desgaste ao longo do tempo para o Rolo M2, considerando as 16 medições realizadas em cada uma das 10 posições. Na Figura 22, são exibidas as previsões geradas pelo modelo ANN, enquanto a Figura 23 apresenta os resultados fornecidos pelo modelo LSTM.

Figura 22 – Desgaste previsto ao Longo do Tempo - ANN.



Fonte: Autores (2024).

Figura 23 – Desgaste previsto para ao Longo do Tempo - LSTM.



Fonte: Autores (2024).

A seguir, são apresentados os resultados comparativos dos modelos ANN e LSTM para a previsão de desgaste nas diferentes posições do rolo M2. Os coeficientes de determinação R^2 e os erros quadráticos médios (MSE) foram utilizados como métricas de avaliação para ambos os modelos.

A Tabela 3 resume esses resultados, permitindo uma análise detalhada do desempenho de cada modelo ao longo das dezesseis medições preenchidas em cada posição de medição do desgaste.

Tabela 3 – Métricas de desempenho para ANN e LSTM por posição de desgaste - Rolo M2.

Posição (mm)	Modelo	R^2 Médio	MSE Médio
Pos.1	ANN	0,7155	25,3426
	LSTM	0,8664	11,9024
Pos.2	ANN	-1,0181	3,4055
	LSTM	-0,3116	2,2133
Pos.3	ANN	0,5063	3,3151
	LSTM	0,5599	2,9550
Pos.4	ANN	0,4762	3,2659
	LSTM	0,5116	3,0447
Pos.5	ANN	0,2497	3,2709
	LSTM	0,7075	1,2752
Pos.6	ANN	0,6042	10,1845
	LSTM	0,7530	6,3561
Pos.7	ANN	0,3708	3,1240
	LSTM	0,6142	1,9153
Pos.8	ANN	0,1991	1,5486
	LSTM	0,6202	0,7344
Pos.9	ANN	-2,2090	0,6894
	LSTM	-2,0989	0,6658
Pos.10	ANN	0,1358	2,4543
	LSTM	0,2640	2,0902

Fonte: Autores (2024).

O modelo LSTM mostrou-se superior ao ANN em quase todas as posições, com exceção da posição 7, onde o ANN teve um desempenho ligeiramente melhor. O LSTM destacou-se principalmente nas posições 1, 2, 4, 6, 8 e 10, onde obteve melhores valores de R^2 e menores erros.

Entretanto, o modelo ANN apresentou melhores resultados em algumas posições. Na posição 9, por exemplo, ambos os modelos tiveram valores negativos de R^2 , indicando dificuldades na previsão, mas o ANN apresentou um valor de MSE ligeiramente menor. Além disso nas posições 2 e 10, apesar do desempenho superior do LSTM em termos de MSE, o ANN ainda demonstrou resultados competitivos.

Dessa forma, a vantagem do LSTM é mais evidente nas posições em que o erro quadrático médio (MSE) foi significativamente menor, refletindo previsões mais precisas, mas o ANN ainda destaca em algumas posições específicas, como Pos.2 e Pos.9.

A Tabela 4 apresenta os coeficientes de determinação (R^2) dos modelos preditivos ANN e LSTM durante as fases de treino e teste. O LSTM obteve um $R^2 = 0,2486$, indicando um desempenho superior, enquanto o ANN apresentou um $R^2 = 0,0030$, sugerindo baixa capacidade de explicação da variabilidade dos dados.


Tabela 4 – Coeficientes de determinação de treino e de teste dos modelos preditivos (ANN e LSTM).

Coeficiente de Determinação	ANN	LSTM
Treino	0,0030	0,2486
Teste	0,0030	0,2486

Fonte: Autores (2024).

O gráfico de dispersão da Figura 24 complementa esses resultados, mostrando que as previsões do LSTM estão mais próximas da linha de referência $y = x$, reforçando seu desempenho superior. Em contraste, os pontos do ANN estão mais dispersos, refletindo um R^2 negativo (-0,093), evidenciando sua baixa precisão preditiva.

Figura 24 – Análise Comparativa entre Desgaste Real e Predito para ANN e LSTM.



Fonte: Autores (2024).


4.2.3 Rolo M3

As previsões do desgaste do Rolo M3, realizadas com os modelos ANN e LSTM, revelaram algumas divergências quanto ao momento ideal para a troca da capa.

- ANN: O modelo ANN indicou que a troca da capa seria necessária em 08 de agosto de 2023, durante a Medição 19, quando o desgaste ultrapassou o limite crítico de 115 mm.
- LSTM: O modelo LSTM sugeriu a necessidade de troca na Medição 20, realizada em 01 de setembro de 2023, também devido ao desgaste ter ultrapassado os 115 mm.


Nas Figuras 25 e 26, O comportamento das previsões dos modelos também pode ser comparado com as medições reais de desgaste, cujos gráficos comparativos por posição estão dispostos no Apêndice B, permitindo uma análise mais aprofundada da precisão preditiva.

Figura 25 – Previsão de Desgaste ao Longo do Tempo (ANN) - Rolo M3



Fonte: Autores (2024).

Figura 26 – Previsão de Desgaste ao Longo do Tempo (LSTM) - Rolo M3.



Fonte: Autores (2024).

A Tabela 5 resume as métricas de desempenho dos modelos ANN e LSTM para as diversas posições do Rolo M3. Essas métricas, representadas pelos coeficientes de determinação (R^2) e pelo erro quadrático médio (MSE), refletem a precisão de cada modelo para cada posição de medição do desgaste.

Tabela 5 – Métricas de desempenho para ANN e LSTM por posição de desgaste - Rolo M3.

Posição (mm)	Modelo	R^2 Médio	MSE Médio
Pos.1	ANN	0,7537	11,4801
	LSTM	0,7359	12,3113
Pos.2	ANN	0,4158	22,2361
	LSTM	0,8115	7,1764
Pos.3	ANN	0,0206	28,7964
	LSTM	0,7579	7,1184
Pos.4	ANN	-0,3885	26,6791
	LSTM	0,4935	9,7328
Pos.5	ANN	-0,0524	23,5103
	LSTM	0,6296	8,2739
Pos.6	ANN	0,5902	28,6973
	LSTM	0,8553	10,1357
Pos.7	ANN	0,1700	20,8758
	LSTM	0,6679	8,3531
Pos.8	ANN	-1,4297	18,9817
	LSTM	0,3852	4,8035
Pos.9	ANN	-2,3428	17,7455
	LSTM	0,5425	2,4286
Pos.10	ANN	-1,0572	10,0852
	LSTM	-0,1289	5,5344

Fonte: Autores (2024).

A análise das métricas de desempenho mostra que o modelo LSTM obteve resultados significativamente melhores na maioria das posições. O LSTM superou o ANN principalmente nas posições 2, 3, 5, 6 e 9, apresentando melhores valores de R^2 e menores MSE, o que evidencia uma maior capacidade do LSTM em capturar padrões de desgaste nessas posições.

Entretanto, o desempenho do ANN se destacou em algumas posições específicas, como a Pos.1, onde o modelo apresentou um R^2 superior ao do LSTM. Nas posições 4 e 10, ambos os modelos tiveram dificuldades, com resultados de R^2 negativos, embora o LSTM tenha mostrado um desempenho ligeiramente superior ao ANN, exceto na Pos.4, onde o ANN ainda demonstrou uma precisão competitiva.

A Tabela 6 apresenta os coeficientes de determinação R^2 médio dos modelos preditivos ANN e LSTM durante as fases de treino e teste. O LSTM obteve um $R^2 = 0,5750$, mostrando um desempenho significativamente superior em relação ao ANN, que apresentou um R^2 negativo de $-0,5310$, indicando dificuldades em explicar a variabilidade dos dados.

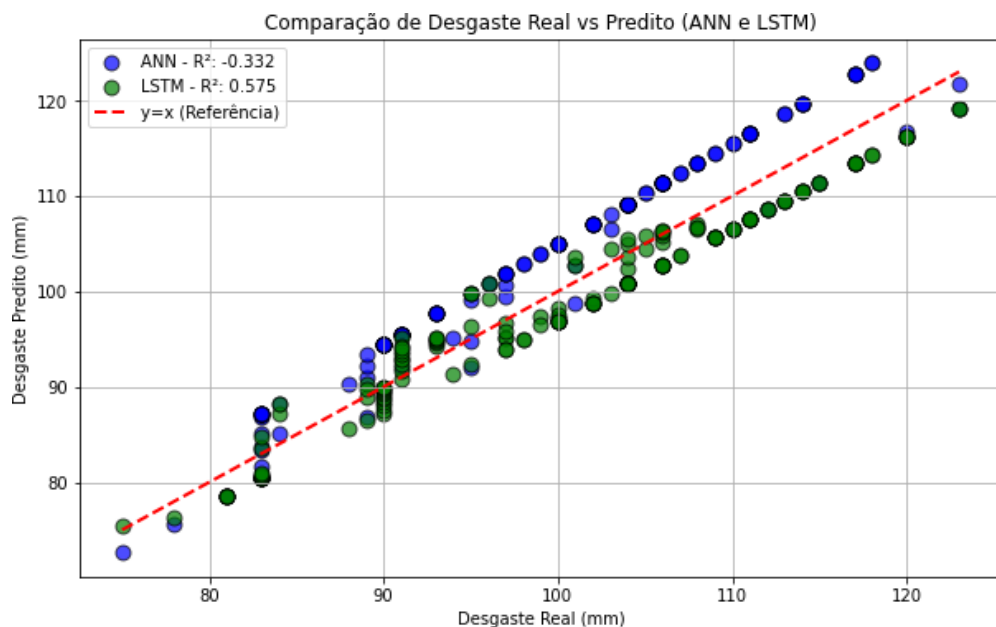
Tabela 6 – Coeficientes de determinação de treino e de teste dos modelos preditivos (ANN e LSTM) para o Rolo M3.

Coeficiente de Determinação	ANN	LSTM
Treino	-0,322	0,5750
Teste	-0,322	0,5750

Fonte: Autores (2024).

O gráfico de dispersão comparativo entre o Desgaste Real e o Desgaste Previsto para ambos os modelos (Figura 27) complementa essa análise. Observa-se que os pontos do LSTM estão mais alinhados à linha de referência $y = x$, enquanto o ANN apresenta maior dispersão, o que reforça a superioridade do LSTM na previsão do desgaste neste rolo.

Figura 27 – Análise Comparativa entre Desgaste Real e Predito para ANN e LSTM (Rolo M3).



Fonte: Autores (2024).

5 CONCLUSÃO

Este trabalho explorou o uso de técnicas de *Machine Learning* como ferramenta auxiliar para a gestão de manutenção industrial, com foco na aplicação de modelos preditivos para monitoramento de desgaste em equipamentos. Por meio do desenvolvimento e teste de dois programas, foi possível implementar algoritmos de Redes Neurais Artificiais (ANN) e Redes de Memória de Longo Prazo (LSTM) para prever o desgaste em moinhos verticais de rolos, oferecendo uma base inicial para futuras aplicações na área de manutenção preditiva.

Os resultados demonstraram que, embora ambos os modelos tenham apresentado previsões consistentes em várias posições de medição, o modelo LSTM mostrou-se mais eficiente em captar padrões temporais de desgaste, o que pode ser vantajoso em cenários de monitoramento contínuo. A análise de conformidade e o registro de falhas implementados na interface dos programas proporcionaram uma visão prática para monitoramento em tempo real, facilitando o acompanhamento de condições do equipamento.

Como se trata de um estudo exploratório, algumas limitações foram observadas, especialmente em posições onde os modelos não alcançaram alta precisão. Isso sugere que futuras pesquisas podem se beneficiar de um conjunto de dados mais extenso e variado, além de ajustes nos modelos para atender a condições operacionais específicas.

Em síntese, este trabalho apresentou uma abordagem inicial e promissora para a aplicação de *Machine Learning* na gestão de manutenção industrial, demonstrando o potencial dessas tecnologias como apoio em tomada de decisões preventivas, alinhadas aos princípios da eficiência e redução de custos.

REFERÊNCIAS

- ANDRADE, T.; SILVA, A. J. d. C. E. Considerações sobre durabilidade, patologia e manutenção das estruturas. **Acervo Tecomat–Tecnologia da Construção e Materiais Ltda**, 2009. Citado na página 14.
- AYRES, M. L. A.; DAEMON, I. G.; FERNANDES, P. C. S. A indústria de cimento. Banco Nacional de Desenvolvimento Econômico e Social, 1999. Citado na página 5.
- BORGES, L. E. **Python para desenvolvedores: aborda Python 3.3**. [S.l.]: Novatec Editora, 2014. Citado 2 vezes nas páginas 18 e 19.
- COELHO, F. C. **Computação Científica com Python**. [S.l.]: Lulu. com, 2007. Citado 2 vezes nas páginas 18 e 19.
- CZICHOS, H. **Tribology: a systems approach to the science and technology of friction, lubrication, and wear**. [S.l.]: Elsevier, 2009. v. 1. Citado na página 12.
- _____. Overview of tribology. In: **Tribologie-Handbuch: Tribometrie, Tribomaterialien, Tribotechnik**. [S.l.]: Springer, 2020. p. 3–30. Citado na página 10.
- DALMOLIN, I. I.; SCHENEIDER, C. J.; GAUTERIO, J. M.; SILVEIRA, V. H. M. da. Desenvolvimento de uma máquina de ensaio de fadiga por flexão rotativa aplicada a aços estruturais de implementos agrícolas. In: **6ª MOEPEX**. [S.l.: s.n.], 2017. Citado na página 12.
- GAHR, K.-H. Z. **Microstructure and wear of materials**. [S.l.]: Elsevier, 1987. v. 10. Citado 2 vezes nas páginas 12 e 13.
- GALVÃO, M. C. B.; RICARTE, I. L. M. Revisão sistemática da literatura: conceituação, produção e publicação. **Logeion: Filosofia da informação**, v. 6, n. 1, p. 57–73, 2019. Citado na página 20.
- Gebr. Pfeiffer. **Moinho Vertical de Rolos MVR - Acionamento Convencional**. 2024. Acesso em: 4 set. 2024. Disponível em: <<https://www.gebr-pfeiffer.com/pt/produtos/moinho-vertical-de-rolos-mvr-acionamento-convencional>>. Citado na página 9.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. [S.l.]: 6. ed. Editora Atlas SA, 2008. Citado na página 20.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The elements of statistical learning: data mining, inference, and prediction**. [S.l.]: Springer Science & Business Media, 2009. Citado na página 18.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, MIT Press, v. 9, n. 8, p. 1735–1780, 1997. Citado na página 18.
- HUTCHINGS, I. **Tribology: friction and wear of engineering materials**. [S.l.]: Elsevier, 1992. Citado 2 vezes nas páginas 10 e 11.
- IBM. **What is Machine Learning?** 2018. Available at: <https://www.ibm.com/cloud/learn/machine-learning> [Acesso em 09 de Novembro, 2024]. Citado na página 15.
- KARDEC, A.; NASCIF, J. **Manutenção-função estratégica**. [S.l.]: Qualitymark Editora Ltda, 2009. Citado na página 14.

KATO, K.; ADACHI, K. **Wear Mechanisms. Chapter 7 of Modern Tribology Handbook**, Ed. **B. Bhushan**. [S.l.]: CRC Press. Boca Raton, 2001. Citado na página 10.

KOTSIANTIS, S. B.; ZAHARAKIS, I.; PINTELAS, P. *et al.* Supervised machine learning: A review of classification techniques. **Emerging artificial intelligence applications in computer engineering**, Amsterdam, v. 160, n. 1, p. 3–24, 2007. Citado 2 vezes nas páginas 15 e 16.

LEARN, S. **Scikit learn user guide**. 2021. Citado 2 vezes nas páginas 17 e 19.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado na página 18.

LING, C. X.; HUANG, J.; ZHANG, H. Auc: a better measure than accuracy in comparing learning algorithms. In: SPRINGER. **Advances in Artificial Intelligence: 16th Conference of the Canadian Society for Computational Studies of Intelligence, AI 2003, Halifax, Canada, June 11–13, 2003, Proceedings 16**. [S.l.], 2003. p. 329–341. Citado na página 16.

LOESCHE. **Manual do operador: LOESCHE Moinho e classificador - Tipo: LM 53.3+3 CS e LSKS 87 CS**. Arcos Plant Line II - Clinker 1, 2012. Ordem: P09822, Número do documento: P09822-M11X00.980 pt Rev. A, Data de edição: 2012-07-10 / gu. Citado 5 vezes nas páginas 34, 68, 69, 70 e 71.

MAIA, E. F.; BARROS, J. R. Plano de lubrificação inteligente executado por planilha com programação em vba aplicado em plantas industriais. In: **II Jornadas Iberoamericanas de Motores Térmicos y Lubricación (La Plata, 2016)**. [S.l.: s.n.], 2016. Citado na página 13.

MAIMON, O.; ROKACH, L. Introduction to knowledge discovery in databases. In: **Data mining and knowledge discovery handbook**. [S.l.]: Springer, 2005. p. 1–17. Citado na página 15.

MARCONI, M. d. A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. [S.l.]: Atlas, 2003. Citado na página 20.

MASSARI, L. 2023. Disponível em: <<<https://www.montarumnegocio.com/6-maiores-produtores-de-cimento-do-mundo/>>>. Citado na página 5.

MICHEL, B. B. A. **The smart welding concept. Global Clement: Wear Protection. Global Clement Magazine**. [S.l.]: Qualitymark Editora Ltda, 2017. Citado na página 8.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, v. 1, n. 1, p. 32, 2003. Citado na página 17.

NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3rd. ed. [S.l.]: Prentice Hall, 2010. Citado na página 15.

OLIVEIRA, C. G. de; SILVA, I. P. P. Os estudos tribológicos no ensino de engenharia mecânica. **Revista de Ensino de Engenharia**, v. 34, n. 2, 2015. Citado na página 7.

OLIVEIRA, G. A. R. N. Critérios de projeto para moinhos de cimento portland. **TCC (Graduação)-Curso de Engenharia Química, Universidade Federal do Rio de Janeiro, Rio de Janeiro**, 2012. Citado 2 vezes nas páginas 8 e 20.

PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011. Citado na página 17.

- PERSSON, B. N.; SPENCER, N. D. Sliding friction: physical principles and applications. **Physics Today**, AIP Publishing, v. 52, n. 1, p. 66–68, 1999. Citado na página 13.
- PITZER. **Recuperação de mesa e rolos dos moinhos de carvão pulverizado da Companhia Siderúrgica Paulista – COSIPA, Anais do XXI Congresso Brasileiro de Manutenção da Associação Brasileira de Manutenção**. [S.l.]: ABRAMAN, 2006. Citado na página 8.
- POLIT, D. F.; HUNGLER, B. P. Fundamentos de pesquisa em enfermagem. In: **Fundamentos de pesquisa em enfermagem**. [S.l.: s.n.], 2007. p. 391–391. Citado na página 20.
- PONTES, R. M. Análise quantitativa de desgaste em um moinho vertical de rolos: um estudo de caso. Universidade Federal da Paraíba, 2018. Citado na página 6.
- PULGA, L.; BIANCHI, G.; FALFARI, S.; FORTE, C. A machine learning methodology for improving the accuracy of laminar flame simulations with reduced chemical kinetics mechanisms. **Combustion and Flame**, Elsevier, v. 216, p. 72–81, 2020. Citado na página 16.
- RADI, P. A.; SANTOS, L. V.; BONETTI, L. F.; TRAVA-AIROLDI, V. J. Tribologia, conceitos e aplicações. **ANAIS DO 13º ENCONTRO DE INICIAÇÃO CIENTÍFICA E PÓS-GRADUAÇÃO DO ITA (XIII ENCITA). XIII., São José dos Campos. Anais [...]. São José dos Campos: Instituto Tecnológico de Aeronáutica**, 2007. Citado 3 vezes nas páginas 6, 10 e 11.
- RIBEIRO, J.; FOGLIATTO, F. Confiabilidade e manutenção industrial. **Belo Horizonte: Elsevier**, 2009. Citado na página 14.
- RIJEZA. 2022. Disponível em: <<https://rijeza.com.br/wp-content/uploads/2022/05/RIJEZA_CPT_mecanismos-desgaste_imagem_abrasao-2-e-3-corpos.png.webp>>. Citado na página 11.
- SCRIVENER, K.; KIRKPATRICK, R. J. Innovation in use and research on cementitious material. **Cement and Concrete Research**, v. 38, p. 128–136, 2008. Disponível em: <https://consensus.app/papers/innovation-research-material-scrivener/bfdcda6e938454dc899cd92b57e74b83/?utm_source=chatgpt>. Citado na página 8.
- SOBOYEJO, W. **Mechanical properties of engineered materials**. [S.l.]: CRC press, 2002. v. 152. Citado na página 11.
- STOETERAU, R. L. Tribologia: Emc 5315. **Florianópolis: Universidade Federal de Santa Catarina. Centro Tecnológico. Departamento de Engenharia Mecânica**, 2004. Citado na página 10.
- SUZUKI, R. Projeto e construção de um equipamento de ensaio de desgaste microabrasivo por esfera rotativa livre. **São Bernardo Do Campo, SP**, 2013. Citado na página 6.
- TECHNOLOGY fluid analysis. 2020. Disponível em: <<https://fluidanalysistech.com.br/_imagens/desgastes.png>>. Citado na página 11.
- WILD, M. *et al.* The global energy balance archive (geba) version 2017: A database for worldwide measured surface energy fluxes. **Earth System Science Data**, Copernicus GmbH, v. 9, n. 2, p. 601–613, 2017. Citado na página 15.
- XENOS, H. G. Gerenciando a manutenção produtiva. **Belo Horizonte: Editora de desenvolvimento gerencial**, v. 171, 1998. Citado na página 14.

APÊNDICE A – DATAFRAMES UTILIZADOS PARA OS MODELOS DE MACHINE LEARNNIG

A.1 Análise de Conformidade

Figura 28 – Dataset I.

Moinho	Código	Equipamento	Carga Nominal (kg)	Carga de Operação (kg)	RPM Nominal da Mesa de Moagem	RPM de Operação	RPM Nominal do Classificador	RPM de Operação do Classificador	Vibração/temperatur	Ruído	Status	
Moinho 1	1	Moinho Vertical de Rolos	151000	151000	22.8	22.8	118	118	0	0	0	conforme
Moinho 2	2	Moinho Vertical de Rolos	151000	160000	22.8	23.0	118	120	1	1	0	não conforme
Moinho 3	3	Moinho Vertical de Rolos	151000	150000	22.8	22.8	118	118	0	0	0	conforme
Moinho 4	4	Moinho Vertical de Rolos	151000	170000	22.8	70.0	118	120	1	1	1	não conforme
Moinho 5	5	Moinho Vertical de Rolos	151000	171000	22.8	60.0	118	118	0	0	1	não conforme
Moinho 6	6	Moinho Vertical de Rolos	151000	150000	22.8	22.8	118	120	0	0	0	conforme
Moinho 7	7	Moinho Vertical de Rolos	151000	150000	22.8	22.8	118	118	0	0	0	conforme
Moinho 8	8	Moinho Vertical de Rolos	151000	160000	22.8	22.8	118	118	0	0	0	não conforme
Moinho 9	9	Moinho Vertical de Rolos	151000	195000	22.8	22.8	118	118	1	0	1	não conforme
Moinho 10	10	Moinho Vertical de Rolos	151000	200000	22.8	21.0	118	120	0	0	1	não conforme

Fonte: Autores (2024).

A.2 Análise de Falhas

Figura 29 – Dataset II.

CODIGO	FALHA	CAUSA	SOLUÇÃO
1a	Desligamento inesperado	Pressão do ar de bloqueio muito baixa ou não existe nenhum ar de bloqueio.	restabelecer o funcionamento do sistema do ar de bloqueio
1b	Desligamento inesperado	Mensagem de falha do sistema de lubrificação; pouco lubrificante ou nenhum lubrificante	Reabastecer lubrificante
2	Vibração elevada	Peças de entrada muito grandes	Reduzir as peças de entrada no valor admissível
3a	Resistência do moinho aumenta	Anel de blindagem gasto	Substituir os anéis de blindagem
3b	Resistência do moinho aumenta	Rolo bloqueado	Verificar o mancal
4a	Temperatura elevada nos rolos de moagem	Baixo nível de óleo	Controlar o nível de óleo
4b	Temperatura elevada nos rolos de moagem	Óleo é muito antigo	eventualmente reabastecer óleo, Controlar quando foi efetuado a última mudança do óleo
5	Vazamento de ar	Defeito no anel coletor	Controlar a vedação do anel coletor, eventualmente trocar (em conjunto)
6a	Pressão do ar de bloqueio muito elevada	Sistema do ar de bloqueio sujo	Limpar o sistema do ar de bloqueio
6b	Pressão do ar de bloqueio muito elevada	Linhas do ar de bloqueio danificadas, por exemplo dobradas	Substituir as linhas defeituosas
7a	Pressão do ar de bloqueio muito baixa	Sistema do ar de bloqueio permeável	Localizar lugares permeáveis, vedar
7b	Pressão do ar de bloqueio muito baixa	Anel de racha do rolo/balanceteiro gasto	Renovar os anéis de racha quando a fenda do ar de bloqueio for muito grande

Fonte: Autores (2024).

A.3 Previsão e Controle do Desgaste

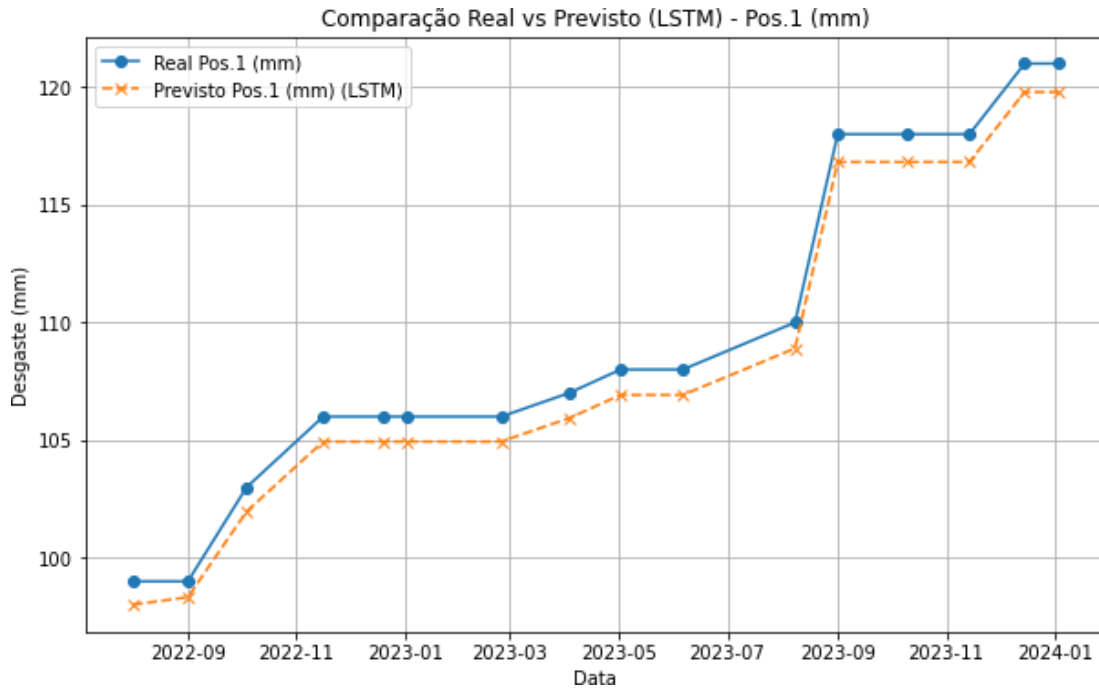
Figura 30 – Dataset III

Medições	Data	Pos.1 (mm)	Pos.2 (mm)	Pos.3 (mm)	Pos.4 (mm)	Pos.5 (mm)	Pos.6 (mm)	Pos.7 (mm)	Pos.8 (mm)	Pos.9 (mm)	Pos.10 (mm)
Medição 0	16-07-2021	51	50	49	49	48	49	49	49	49	52
Medição 1	03-08-2021	69	65	65	61	62	64	56	54	52	56
Medição 2	05-10-2021	72	72	70	75	78	72	65	60	62	60
Medição 3	01-12-2021	80	81	76	78	80	80	72	65	74	63
Medição 4	04-02-2022	80	89	80	80	82	82	72	77	76	63
Medição 5	22-03-2022	82	91	89	85	82	85	79	78	76	72
Medição 6	03-05-2022	89	93	94	85	87	89	83	82	79	73
Medição 7	03-06-2022	92	93	94	89	88	90	86	83	81	73
Medição 8	28-06-2022	97	94	95	94	90	91	88	84	82	75

Fonte: Autores (2024).


A.4 Comparação do desgaste previsto vs Desgaste Real para os três rolo M

Figura 31 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.1 (mm).




Fonte: Autores (2024).

Figura 32 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.2 (mm).




Fonte: Autores (2024).

Figura 33 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.3 (mm).




Fonte: Autores (2024).

Figura 34 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.4 (mm).




Fonte: Autores (2024).

Figura 35 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.5 (mm).




Fonte: Autores (2024).

Figura 36 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.6 (mm).




Fonte: Autores (2024).

Figura 37 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.7 (mm).




Fonte: Autores (2024).

Figura 38 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.8 (mm).




Fonte: Autores (2024).

Figura 39 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.9 (mm).




Fonte: Autores (2024).

Figura 40 – Comparação Real vs Predito (LSTM) para o Rolo M1 - Pos.10 (mm).




Fonte: Autores (2024).

Figura 41 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.1 (mm).




Fonte: Autores (2024).

Figura 42 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.2 (mm).




Fonte: Autores (2024).

Figura 43 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.3 (mm).




Fonte: Autores (2024).

Figura 44 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.4 (mm).




Fonte: Autores (2024).

Figura 45 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.5 (mm).




Fonte: Autores (2024).

Figura 46 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.6 (mm).




Fonte: Autores (2024).

Figura 47 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.7 (mm).




Fonte: Autores (2024).

Figura 48 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.8 (mm).




Fonte: Autores (2024).

Figura 49 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.9 (mm).




Fonte: Autores (2024).

Figura 50 – Comparação Real vs Predito (LSTM) para o Rolo M2 - Pos.10 (mm).




Fonte: Autores (2024).

Figura 51 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.1 (mm).




Fonte: Autores (2024).

Figura 52 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.2 (mm).




Fonte: Autores (2024).

Figura 53 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.3 (mm)..




Fonte: Autores (2024).

Figura 54 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.4 (mm).




Fonte: Autores (2024).

Figura 55 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.5 (mm)..




Fonte: Autores (2024).

Figura 56 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.6 (mm)..




Fonte: Autores (2024).

Figura 57 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.7 (mm)..




Fonte: Autores (2024).

Figura 58 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.8 (mm).




Fonte: Autores (2024).

Figura 59 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.9 (mm).



Fonte: Autores (2024).

Figura 60 – Comparação Real vs Predito (LSTM) para o Rolo M3 - Pos.10 (mm).



Fonte: Autores (2024).

ANEXO A – MOINHO VERTICAL DE ROLOS

A.1 Imagens do Moinho e dos Rolos de Moagem

Nesta seção, são apresentadas as imagens do moinho e dos rolos de moagem, utilizadas para ilustrar o funcionamento do equipamento. As imagens foram retiradas do manual oficial da LOESCHE.

Figura 61 – Fluxo da base de moagem através do moinho, representação de princípio.




Fig. 4: Fluxo da base de moagem através do moinho, representação de princípio

Legenda

- | | |
|--|--|
| 1 Entrada da base de moagem através da câmara de vácuo | 8 Entrada de gás quente |
| 2 Separação do material no separador | 9 Raspadeiras deslocam o material rejeitado no funil |
| 3 O material é transportado pelo gás quente até o separador | 10 O gás quente passa pela coroa de pás |
| 4 Material rejeitado pelo separador | 11 O material é detectado pelo fluxo de gás quente |
| 5 O material de moagem cai pela rampa sobre o centro da mesa | 12 Os rolos moem o material |
| 6 o acionamento LM impulsiona a mesa | 13 Saída do produto moído |
| 7 Material rejeitado | |

Fonte: Loesche (2012).

Figura 62 – Interfaces do moinho de cilindros da LOESCHE.




Fig. 2: Interfaces do moinho de cilindros da LOESCHE , esboço de princípio

Legenda

- | | |
|-----------------------------|-----------------------------|
| 1 Saída de material acabado | 4 Plataforma |
| 2 Abertura de inspeção | 5 Sistema hidráulico |
| 3 Entrada do ar de processo | 6 Entrada da base de moagem |

Fonte: Loesche (2012).

Figura 63 – Rolo completo.





Fig. 12: Rolo cpl.

Legenda

- | | |
|------------------------------|-------------------------------------|
| 1 Eixo do rolo | 9 Proteção |
| 2 Revestimento do rolo | 10 Rolamento de roletes cilíndricos |
| 3 Anel de aperto | 11 Bucha da vedação |
| 4 Núcleo do rolo | 12 Balancete |
| 5 Tampa do núcleo do rolo | 13 Cobertura transparente |
| 6 Cobertura transparente | 14 Admissão do ar de bloqueio |
| 7 Rolamento de rolos cônicos | 15 Vedação do anel coletor |
| 8 Cone espaçador | |

Fonte: Loesche (2012).

Figura 64 – Vista geral do Moinho LOESCHE.



Fonte: Loesche (2012).