



UNIVERSIDADE FEDERAL DO PARÁ
NÚCLEO DE DESENVOLVIMENTO AMAZÔNICO EM ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFRAESTRUTURA E
DESENVOLVIMENTO ENERGÉTICO

RYAN LUIS RODRIGUES LOUZADA

**IDENTIFICAÇÃO DO DESALINHAMENTO DE TRANSPORTADORES DE CORREIA POR
MEIO DE SINAIS DE VIBRAÇÃO EM UM CIRCUITO DE MANUSEIO**

Tucuruí, Pará

2025

RYAN LUIS RODRIGUES LOUZADA

**IDENTIFICAÇÃO DO DESALINHAMENTO DE TRANSPORTADORES DE
CORREIA POR MEIO DE SINAIS DE VIBRAÇÃO EM UM CIRCUITO DE
MANUSEIO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Infraestrutura e Desenvolvimento Energético do Núcleo de Desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Infraestrutura e Desenvolvimento Energético. Área de concentração: Desenvolvimento Energético.

Orientador: Prof. Dr. André Luiz Amarante Mesquita

Tucuruí, Pará
2025

RYAN LUIS RODRIGUES LOUZADA

**IDENTIFICAÇÃO DO DESALINHAMENTO DE TRANSPORTADORES DE
CORREIA POR MEIO DE SINAIS DE VIBRAÇÃO EM UM CIRCUITO DE
MANUSEIO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Infraestrutura e Desenvolvimento Energético do Núcleo de Desenvolvimento Amazônico em Engenharia, da Universidade Federal do Pará, como requisito para a obtenção do título de Mestre em Infraestrutura e Desenvolvimento Energético. Área de concentração: Desenvolvimento Energético.

Orientador: Prof. Dr. André Luiz Amarante Mesquita

Aprovada em 14 de julho de

2025. BANCA EXAMINADORA:

Documento assinado digitalmente
 **ANDRE LUIZ AMARANTE MESQUITA**
Data: 23/01/2026 12:18:48-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. André Luiz Amarante Mesquita / UFPA - Orientador

Documento assinado digitalmente
 **ALEXANDRE LUIZ AMARANTE MESQUITA**
Data: 17/01/2026 15:43:23-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Alexandre Luiz Amarante Mesquita / UFPA

Documento assinado digitalmente
 **Julio Apolinario Cordioli**
Data: 21/01/2026 14:26:51-0300
CPF: ***.276.989-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Dr. Júlio Apolinário Cordioli / UFSC

AGRADECIMENTOS

Primeiramente, agradeço aos meus pais, Edileno Luis e Rosineia Rodrigues, e ao meu irmão, pelo amor, apoio e incentivo incondicional que sempre me deram. Não seria possível chegar até aqui sem o apoio e a força que vocês me deram. Agradeço também às minhas avós, Catarina e Sebastiana, pelo amor e apoio que sempre me deram.

Agradeço ao meu orientador, o professor André Mesquita, por sua orientação valiosa, paciência e conhecimento compartilhado. Sua confiança em mim foi fundamental para o meu desenvolvimento acadêmico e profissional. Agradecer à Dynamox pelo apoio financeiro e a todos meus amigos e colegas do laboratório de fluidodinâmica e particulados (Fluidpar).

RESUMO

INVESTIGAÇÃO SOBRE O USO DE SINAIS DE VIBRAÇÃO PARA DETECTAR DESALINHAMENTO DE CORREIAS EM UM CIRCUITO DE MANUSEIO

O desalinhamento em correias transportadoras é uma das principais causas de desgaste prematuro, falhas operacionais e aumento dos custos de manutenção em sistemas industriais de transporte de materiais. Este trabalho propõe uma metodologia baseada na análise de sinais de vibração para detecção automática do desalinhamento, utilizando uma bancada experimental desenvolvida para simular esse fenômeno de forma controlada. Foram implementadas modificações geométricas em chutes de transferência, projetados por meio de simulações com o Método dos Elementos Discretos (DEM), para gerar diferentes graus de desalinhamento. A coleta de dados foi realizada com sensores triaxiais acoplados à estrutura, e os sinais obtidos passaram por extração de atributos estatísticos no domínio do tempo. Esses dados foram então submetidos a algoritmos de aprendizado de máquina, como Máquinas de Vetores de Suporte (SVM) e Árvores de Decisão, com avaliação por validação cruzada. Os modelos demonstraram alta acurácia na identificação das classes de alinhamento, destacando a relevância de métricas como curtose, pico e fator K. Os resultados confirmam a eficácia da abordagem no diagnóstico de desalinhamentos e sua aplicabilidade em estratégias de manutenção preditiva.

Palavras-chave: desalinhamento de correias transportadoras; análise de vibrações; método dos Elementos Discretos (DEM); aprendizado de máquina; bancada experimental; manutenção preditiva.

ABSTRACT

INVESTIGATION ON THE USE OF VIBRATION SIGNALS TO DETECT BELT MISALIGNMENT IN A HANDLING CIRCUIT

Misalignment in conveyor belts is a significant factor contributing to premature wear, operational failures, and increased maintenance costs in industrial material handling systems. This study presents a methodology based on vibration signal analysis for the automatic detection of belt misalignment, using an experimental test bench developed to simulate this condition under controlled parameters. Geometrical modifications were introduced in transfer chutes, designed through simulations using the Discrete Element Method (DEM), to generate gradual misalignment. Data were collected with triaxial accelerometers, and time-domain statistical features were extracted from the signals. These features were analyzed using machine learning algorithms, including Support Vector Machines (SVM) and Decision Trees, evaluated through cross-validation techniques. The models achieved high accuracy in classifying alignment conditions, with features such as kurtosis, peak value, and K-factor showing strong influence. The proposed approach proved effective for misalignment diagnosis and supports its integration into predictive maintenance strategies.

Keywords: conveyor belt; misalignment; vibration; DEM; machine learning; predictive maintenance.

LISTA DE ILUSTRAÇÕES

Figura 2.1 - Transportador de correia processo de mineração de minério de ferro.	15
Figura 2.2 - Configuração típica de um transportador de correia	16
Figura 2.3 – Ilustração de um chute de transferência.....	17
Figura 2.4 - Hood and spoon design.....	18
Figura 2.5 - Caixa de pedra clássica design.	19
Figura 2.6 - Placa de impacto clássica design.....	20
Figura 2.7 - Danos ao tubo do rolete.	21
Figura 2.8 - (a) traços de fricção da correia no rolete bloqueado (desgaste por fricção do tubo); (b) danos ao tubo devido ao bloqueio do rolamento.....	22
Figura 2.9- Placa de impacto clássica design.....	23
Figura 2.10 - Carregamento fora de material fora de centro.....	24
Figura 2.11 - Acumulo de material na calha de transferência.....	24
Figura 2.12 - a) Mal alinhamento dos cavaletes b) Inclinação incorreta dos cavaletes. ..	25
Figura 2.13 - Desgaste da borda da correia.	26
Figura 2.14 - Desgaste da estrutura do transportador.	26
Figura 2.15 - Contato correia e rolete guia.	27
Figura 2.16 - Derramamento de material causado pelo desalinhamento	27
Figura 2.17 - Incendia por atrito da correia.....	28
Figura 2.18 - Utilização DEM para projeto de chutes de transferência.....	30
Figura 2.19 - Relação entre o valor de pico da vibração e o valor RMS	32
Figura 2.20 - Fator K.....	33
Figura 2.21 – Árvore de decisão.....	35
Figura 2.22 - Estrutura da árvore de decisão.	37
Figura 2.23 - Hiperplano de separação ótima.....	38
Figura 3.1 - Fluxograma do circuito de manuseio de minério.	39
Figura 3.2 - Equipamentos em posse do laboratório. a) MG-01 e TR-01; b) TR-02; c) TR-03; d) EC-01	40
Figura 3.3 - Equipamentos projetados. a) CT-02; b) SP-01; c) SP-01; d) SP-02.....	41
Figura 3.4 - Simulação circuito de manuseio simulações DEM.	42
Figura 3.5 - Circuito de manuseio de minério projeto.	42
Figura 3.6 - Circuito de manuseio de minério.	43
Figura 3.7-Modelagem CT-01	44

Figura 3.8-vista frontal da simulação(A); vista isométrica(B).	44
Figura 3.9 - Fator de desalinhamento	45
Figura 3.10 – Média do desalinhamento no tempo.	45
Figura 3.11 - Defletora reta(A); basculante móvel(B).	46
Figura 3.12 - Simulação com defletora reta.	46
Figura 3.13 – Fator de desalinhamento pelo comprimento da defletora	47
Figura 3.14 - Simulação basculante móvel.	47
Figura 3.15 – Fator de desalinhamento pelo movimento da basculante (com cavalete 45°).	48
Figura 3.16 - Cavalete com 45°(A); Cavalete com 20°(B).	48
Figura 3.17 – Fator de desalinhamento pelo movimento da basculante (com cavalete 20°).	49
Figura 3.18 - Desenho dimensional dos roletes.	51
Figura 3.19- Ensaio experimental; alinhado (A), desalinhado (B).	52
Figura 3.20 - Gráficos de sinal alinhado-LE no domínio da frequência.	53
Figura 3.21 - Gráficos de sinal alinhado-LD no domínio da frequência.	53
Figura 3.22 - Gráficos de sinal desalinhado-LE no domínio da frequência.	54
Figura 3.23 - Gráficos de sinal desalinhado-LD no domínio da frequência.	54
Figura 3.24 - Gráficos de sinal alinhado-LE no domínio do tempo.	54
Figura 3.25 - Gráficos de sinal alinhado-LD no domínio do tempo.	55
Figura 3.26 - Gráficos de sinal Desalinhado-LE no domínio do tempo.	55
Figura 3.27 - Gráficos de sinal Desalinhado-LD no domínio do tempo.	55
Figura 3.28 - Matriz de confusão global do classificador SVM no lado (LE)	58
Figura 3.29 - Curva de acurácia por <i>fold</i> para o modelo SVM no lado LE.	59
Figura 3.30 - Importância relativa das 10 principais features para o SVM no lado LE.	60
Figura 3.31- curva de aprendizado individual por fold SVM no lado LE	60
Figura 3.32 - Matriz de confusão global do classificador SVM no lado LD.	61
Figura 3.33 - Curva de acurácia por <i>fold</i> para o modelo SVM no lado LD.	62
Figura 3.34 - Importância relativa das 10 principais features para o SVM no lado LD.	62
Figura 3.35 - curva de aprendizado individual por fold SVM no lado LD.	63
Figura 3.36 – Matriz de confusão global da Árvore de Decisão no lado LE.	64
Figura 3.37 - Curva de acurácia por <i>fold</i> para a Árvore de Decisão no lado LE.	64
Figura 3.38 - Importância relativa das 10 principais features para a Árvore de Decisão no lado LE.	65

Figura 3.39 - curva de aprendizado individual por fold arvore de decisão no lado LE.....	65
Figura 3.40 - Matriz de confusão global da Árvore de Decisão no lado LD.	66
Figura 3.41 - Curva de acurácia por <i>fold</i> para a Árvore de Decisão no lado LD.....	67
Figura 3.42 - Importância relativa das 10 principais features para a Árvore de Decisão no lado LD.	67
Figura 3.43 - curva de aprendizado individual por fold arvore de decisão no lado LD.....	68

LISTA DE TABELAS

Tabela 1- Especificações técnicas modelo HF+	49
Tabela 2 - Configuração espectral	51
Tabela 3 - Sinais coletados.....	52
Tabela 4 - Exemplo de <i>features</i> extraída dos dados coletados.	55
Tabela 5 - Comparativo dos resultados dos modelos LE e LD.	68

SUMÁRIO

1.	INTRODUÇÃO.....	12
1.1.	<i>Considerações gerais</i>	12
1.2.	<i>Objetivos</i>	14
1.2.1.	Objetivo Geral	14
1.2.2.	Objetivos Específicos	14
1.3.	<i>Estrutura do Trabalho</i>	14
2.	FUNDAMENTOS E REVISÃO BIBLIOGRÁFICA	15
2.1.	<i>Transportador de correia</i>	15
2.2.	<i>Chutes de transferência</i>	16
2.2.1.	Dimensionamento de chute de transferência	17
2.2.2.	Chute Hood Spoon	17
2.2.3.	Caixa de Pedra	18
2.2.4.	Placa de impacto	19
2.3.	<i>Desalinhamento de correia</i>	20
2.3.1.	Causas de desalinhamento de correia	20
2.3.2.	Problemas causados pelo desalinhamento de correia	25
2.4.	<i>Metodologia DEM</i>	28
2.5.	<i>Vibrações mecânicas</i>	30
2.5.1.	Análise no Domínio do Tempo	31
2.6.	<i>Aprendizado de máquina</i>	34
2.6.1.	Árvore de decisão	34
2.6.2.	Máquina de vetor e suporte (SVM)	38
3.	ESTUDO EXPERIMENTAL	39
3.1.	<i>Circuito de manuseio</i>	39
3.1.1.	Chute de transferencia(CT-01) e alinhamento gradual	43
3.2.	<i>Metodologia para coleta de dados e analise de sinais de vibração.</i>	49
3.2.1.	Coleta de dados de vibração	49
3.2.2.	Pré-processamento e extração de <i>feature</i>	56
3.3.	<i>Resultados</i>	56
3.3.1.	Fluxo algorítmico em Python	57
3.3.2.	Desempenho do classificador SVM	58

3.3.3. Desempenho do modelo árvore de decisão.....	63
3.3.4. Comparativo entre os Lados	68
4. CONCLUSÃO	70
4.1. <i>Considerações finais.....</i>	<i>70</i>
4.2. <i>Trabalhos Futuros.....</i>	<i>70</i>

1. INTRODUÇÃO

1.1. Considerações gerais

A manutenção desempenha um papel crucial no setor industrial, já que seus custos podem representar uma parte significativa dos custos de produção de uma empresa. Estratégias eficazes de manutenção evitam paradas inesperadas, reduzem custos e podem até aumentar a vida útil das máquinas industriais. Por essas razões, as abordagens de manutenção têm passado por diversas transformações, impulsionadas pelos esforços de pesquisadores, engenheiros, técnicos e especialistas (Nunes; Santos e Rocha, 2023).

As correias transportadoras são amplamente utilizadas em diversas indústrias para movimentar produtos, desde alimentos até materiais a granel como carvão. O alinhamento da correia em relação as bordas dos transportadores é um parâmetro essencial para o monitoramento desses sistemas, pois está diretamente ligado ao desgaste da correia e à falha prematura de componentes como roletes, polias e engrenagens. Tradicionalmente, o alinhamento é verificado por meio de métodos mecânicos, utilizando sensores de temperatura e interruptores (Chamorro *et al.*, 2022). Apesar de serem métodos confiáveis, muitas vezes a correia já enfrenta condições adversas antes que o desalinhamento seja identificado, o que resulta em maior consumo de energia e estresse nos componentes críticos. Além disso, esses sensores não são sempre aplicáveis, especialmente em ambientes com poeira e condições extremas (Chamorro *et al.*, 2022).

A estratégia mais básica de manutenção da indústria é a manutenção corretiva (MC), que consiste em substituir ou reparar uma peça apenas quando ela está danificada e o equipamento não pode operar sem intervenção. Devido aos altos custos associados a paradas inesperadas, a MC evoluiu para abordagens mais proativas. A primeira a surgir foi a manutenção preventiva (MP), que envolve inspeções periódicas realizadas por técnicos especializados e a substituição de peças antes que ocorra uma falha crítica. Essa substituição é feita em intervalos regulares ou após um determinado número de ciclos de trabalho, conforme indicado pelo fabricante do equipamento. Isso pode resultar em substituições prematuras ou tardias de componentes, onde o primeiro cenário aumenta os custos de manutenção e o

segundo pode levar a consequências mais graves, exigindo uma ação de MC. (Nunes; Santos e Rocha, 2023). Em seguida, surge a manutenção preditiva (PdM), que se beneficia de avanços tecnológicos em sensores, redes e inteligência artificial, conforme fundamentado por Ersöz et al. (2022), fortalecendo a capacidade de antecipar falhas e programar intervenções com maior precisão temporal.

O conceito de Indústria 4.0 enfatiza a importância de identificar anomalias no funcionamento dos dispositivos, permitindo prever possíveis falhas por meio do uso de sensores e automação, com foco em reduzir custos relacionados a interrupções na produção (Diallo *et al.*, 2021). Diversos estudos têm explorado esse tema, incluindo uma proposta para desenvolver um sistema especialista baseado na condição dos transportadores, a aplicação de redes neurais convulsionais para monitorar o estado dos motores dos transportadores, a estimativa da vida útil dos componentes por meio de técnicas analíticas, o uso de visão computacional para avaliar a probabilidade de falhas, o cálculo da vida útil remanescente dos rolamentos utilizando regressão por vetores de suporte (SVR) e a previsão de falhas baseada em dados em sistemas complexos (Rumin *et al.*, 2023).

As operações com correias transportadoras, especialmente em ambientes industriais como mineração e metalurgia, frequentemente enfrentam problemas de desvio/desalinhamento da correia (*mistracking*). Esse desalinhamento aumenta a resistência ao movimento, elevando o consumo de energia, acelera o desgaste de componentes e pode ocasionar paradas de emergência (DABEK et al., 2023). Além disso, os métodos tradicionais por contato atuam quando a correia já tocou o sensor ou a estrutura, ou seja, após o aparecimento de um sintoma tardio; os próprios autores destacam que ainda é limitado o número de soluções capazes de detectar o desvio “bem antes” (Dabek *et al.*, 2023; Netto *et al.*, 2021).

Este trabalho justifica-se pela necessidade de desenvolver métodos mais eficazes e inovadores, utilizando a análise de vibrações para detectar desalinhamentos de forma precoce e precisa. A criação de uma bancada experimental permitirá o aprimoramento dessas metodologias, contribuindo para a redução de custos e o aumento da eficiência nas operações industriais.

1.2. Objetivos

1.2.1. Objetivo Geral

Desenvolver um circuito de manuseio de minério e metodologias para avaliação do desalinhamento de correia transportadora.

1.2.2. Objetivos Específicos

- Desenvolver um chute de transferência entre correias transportadoras no laboratório;
- Desenvolver metodologias e modificações para geração de um desalinhamento gradual com base em simulações DEM;
- Desenvolver metodologia para avaliação do desalinhamento de correia transportadoras a partir de sinais de vibrações mecânicas.

1.3. Estrutura do Trabalho

Este trabalho está dividido em cinco capítulos. O primeiro capítulo introduz o assunto do trabalho e apresenta os objetivos da dissertação.

O Capítulo 2 apresenta a fundamentação teórica, onde inicialmente são abordados os conceitos de desalinhamento de correias, os impactos operacionais associados, e uma revisão. Em seguida, traz uma revisão sobre o uso de metodologias avançadas, como a análise de sinais de vibração e o processamento de imagens, na identificação dos desalinhamentos.

No Capítulo 3 é descrito o processo de desenvolvimento do laboratório e da bancada experimental, que simula condições reais de operação de transportadores. A metodologia utilizada nos ensaios de desalinhamento e a aplicação das técnicas mencionadas para análise de dados.

O Capítulo 4 apresenta os resultados obtidos a partir dos ensaios, com uma discussão aprofundada sobre a influência de diferentes fatores no desalinhamento e a eficácia das técnicas empregadas para detectar esses desalinhamentos em diferentes condições de operação, assim como sugestões de estudos futuros.

2. FUNDAMENTOS E REVISÃO BIBLIOGRÁFICA

2.1. Transportador de correia

Os transportadores de Correia (TC) são equipamentos destinados ao transporte de materiais (Gelais, 2016). São amplamente utilizadas em indústrias como carvão, metalurgia, mineração, usinas termelétricas, terminais de carga a granel e outros locais devido à sua economia, confiabilidade, segurança, longa distância de transmissão e grande capacidade de transmissão (Du *et al*, 2023). São utilizados quando se precisa de manuseio contínuo de grânéis sólidos, sendo capazes de atingir altas capacidades de transporte com elevada disponibilidade e excelente custo de operação e manutenção (Gelais, 2016). A Figura 2.1 apresenta uma foto de um transportador de correia utilizado na indústria de mineração (Hartmann, 2023).



Figura 2.1 - Transportador de correia processo de mineração de minério de ferro.
Fonte: Hartmann, 2023.

Para atender às necessidades de diversas áreas da indústria, os transportadores de correia podem ser configurados de várias maneiras; contudo, os componentes de sua estrutura permanecem os mesmos. A Figura 2.2 ilustra uma configuração típica de uma correia transportadora de minério de ferro (Balieiro, 2019).




Figura 2.2 - Configuração típica de um transportador de correia
 Fonte: Baleiro, 2019.

2.2. Chutes de transferência

Os chutes de transferências (CT) são equipamentos mecânicos que tem a função redirecionam o fluxo de material entre um transportador para outro, preservando o fluxo de material. Assim, possuindo grande importância para o manuseio e transporte eficiente de materiais sólidos a granel, especialmente para sistemas de transporte por correia em operações de processamento de minério (Jacobs-Capdevill *et al* 2024). Os chutes recebem material com uma altura de queda que difere bastante de um chute para outro, a mudança da direção de queda do material impede o impacto direto no transportador inferior, e também impede que o material seja despejado para fora do sistema, o que resulta em perdas e retrabalho (Silva, 2016).

Algumas exigências no transporte de materiais a granel continuam a pressionar a indústria de transportadores, pois ainda não são totalmente compreendidas, como geração de poeira, desgaste e ruído excessivo (Xie *et al.*, 2016). A Figura 2.3 ilustra um projeto de chute de transferência.



Figura 2.3 – Ilustração de um chute de transferência.
Fonte: Ferreira, 2020.

2.2.1. Dimensionamento de chute de transferência

Os projetos dos CT variam de acordo com a necessidade de cada empresa (Swinderman *et al.*, 2009). A configuração do chute depende das propriedades do material a granel ou dos requisitos específicos da configuração do sistema. Os principais componentes utilizados nos projetos de chutes de transferência são hood spoon, caixa de pedra e placa de impacto (Mascarenhas e Mesquita, 2013).

2.2.2. Chute Hood Spoon

Um chute *Hood Spoon* é uma configuração que consiste em uma seção curva que captura o material e o guia, conforme ele sai da correia transportadora superior de forma mais controlada do que fosse em queda livre mostrado na Figura 2.4. O

spoon é uma superfície igualmente curva que captura o material que desliza para baixo do duto e o guia para a correia inferior. Este projeto visa manter o fluxo de material o mais contínuo possível, o que traz diversas vantagens, como a redução do desgaste da correia, a degradação do material, o derramamento e a liberação de poeira. A curvatura presente no capuz e na colher reduz o impacto do material e diminui as variações na velocidade do fluxo. Além disso, o *hood* possui uma forma convergente que minimiza a expansão do material (Vreeburg, 2018).




Figura 2.4 - Hood and spoon design.
Fonte: Vreeburg, 2018.

2.2.3. Caixa de Pedra

A caixa de pedra em um chute de transferência consiste em uma superfície onde existe o acumulo de material ao ponto de forma uma pilha. Como principal função a caixa de pedra evitar o contato partícula-parede a partir do material entrada, assim impondo o contato partícula-partícula (Aarde, 2009).

Segundo Mascarenhas e Mesquita (2013), as caixas de pedra são principalmente usadas para materiais abrasivos, como minério, uma vez que esses materiais podem causar danos significativos aos chutes de transferência. Entretanto,

as caixas de pedra não devem ser usadas em casos em que a diferença de velocidade entre o material sendo carregado e a correia transportadora receptora é grande, pois isso pode causar desgaste significativo na correia, assim como derramamento.

Em ocasiões em que é necessário grandes alturas de queda, configurações com várias caixas de pedras uma sobre a outra podem ser implementadas. Isso pode ser usado para reduzir o impacto e controlar a velocidade do material sobre quedas de maior distância. Essa configuração é chamada de chute em cascata (Vreeburg, 2018). Na Figura 2.5 encontra-se um exemplo clássico de caixa de pedra.




Figura 2.5 - Caixa de pedra clássica design.
Fonte: Adaptado de Rossow (2020).

2.2.4. Placa de impacto

As placas de impacto atuam absorvendo a colisão das partículas, proveniente do fluxo de material da polia motriz. Elas são utilizadas para garantir que não ocorra o contato pesado do fluxo de material na estrutura do sistema quando nenhuma variação direcional do componente de velocidade é necessária. Comumente são utilizados dois projetos. O mostrado na Figura 2.6(A) é para condições de alta velocidade da correia, o objetivo da placa de impacto é eliminar o componente de velocidade horizontal do material e assim absorver a maior parte do dano e desgaste para proteger o restante do chute. Na Figura 2.6(B) é para condições de baixa

velocidade da correia onde a placa de impacto absorve o componente de velocidade vertical, consequentemente, protege a correia transportadora receptora do desgaste por impacto e proporciona um fluxo uniforme na correia. O objetivo do projeto de uma placa de impacto é projetá-la com a seleção correta do tipo de material e geometria, a fim de suportar o impacto e o desgaste abrasivo e, como resultado, alcançar uma vida útil aceitável (Rossow, 2020).




Figura 2.6 - Placa de impacto clássica design.

Fonte: Adaptado de Rossow (2020).

2.3. Desalinhamento de correia

Um problema frequente em transportadores de correia corresponde ao mistracking (desalinhamento), que ocorre quando a correia se desloca para uma das bordas do percurso. Isso pode ser gerado por componentes que fazem a correia desviar da sua trajetória central. Como, falhas na geometria de uma correia transportadora ou defeitos nos componentes do transportador em uma seção vertical ou longitudinal do percurso, pode causar danos à correia. Pode-se considerar o desalinhamento da correia tanto um tipo quanto uma causa de dano (Bortnowski *et al.*, 2022).

2.3.1. Causas de desalinhamento de correia

2.3.1.1. Causas comuns de desalinhamento causado pelos roletes

Segundo Otto e Katterfeld (2015), os roletes implicam em grande influência no alinhamento correto das correias transportadoras. Mudanças pequenas no

posicionamento ideal dos roletes podem resultar em um desalinhamento maciço da correia. O desalinhamento dos roletes pode ser separado em orientações translacionais e rotacionais. Esse desalinhamento pode ser axial, radial ou angular, levando a vibrações excessivas e ao desgaste acelerado dos rolamentos e vedações. Roletes mal ajustados podem causar a correia a desviar para um lado, agravando o problema ao longo do tempo (Bahrun *et al.*, 2022).

O desalinhamento da correia pode ser agravado por roletes danificados ou bloqueados, que criam pontos de resistência variável ao longo da correia, resultando em um movimento não linear e, eventualmente, no desalinhamento da correia. Este desalinhamento contínuo causa um ciclo vicioso de desgaste e danos, onde a correia em atrito constante com a estrutura do transportador e com os roletes guia, como mostrado nas Figuras 2.7 e 2.8. A Figura 2.7 mostra os danos ao tubo do rolete, bordas cortantes visíveis, enquanto a Figura 2.8 apresenta exemplos de bloqueio de roletes: (a) traços de fricção da correia no rolete bloqueado (desgaste por fricção do tubo), (b) danos ao tubo devido ao bloqueio do rolamento (Nascimento *et al.*, 2020; Kulinowski; Kasza e Zarzycki, 2021).



Figura 2.7 - Danos ao tubo do rolete.
Fonte: Nortnowski *et al.*, 2022.



Figura 2.8 - (a) traços de fricção da correia no rolete bloqueado (desgaste por fricção do tubo); (b) danos ao tubo devido ao bloqueio do rolamento
 Fonte: Nortnowski *et al.*, 2022.

2.3.1.2. Desalinhamento causado pelo tambor

O desalinhamento das correias transportadoras pode ser causado por diversos fatores, incluindo o tensionamento inadequado dos tambores. Quando a tensão da correia não é uniforme ao longo do tambor, cria-se uma força desequilibrada que pode deslocar a correia lateralmente. Esse fenômeno ocorre porque a parte da correia com menor tensão tende a escorregar, resultando em um alinhamento defeituoso. O desalinhamento contínuo não só reduz a eficiência do sistema, como também aumenta o desgaste dos componentes da correia, incluindo os próprios tambores e roletes (Mazurkiewicz, 2015; Rucki *et al.*, 2020).

A correta manutenção do tensionamento é crucial para prevenir os problemas citados no parágrafo anterior. Estudos indicam que a aplicação de sistemas de monitoramento em tempo real pode ajudar a detectar e corrigir desalinhamentos de forma proativa. Esses sistemas utilizam sensores para medir a força de pressão da correia sobre os tambores e ajustar automaticamente a tensão conforme necessário. Isso não apenas melhora a vida útil da correia e dos tambores, mas também minimiza interrupções operacionais (Mazurkiewicz, 2015).

Kobayashi e Toya (2007) observaram que o desalinhamento dos tambores de acionamento gera o desalinhamento da correia, pois a correia tende a seguir a nova linha de rastreamento criada pela rotação desalinhada entre os tambores. A correia desliza na direção do desalinhamento dos roletes até atingir um novo ponto de equilíbrio. Em seus experimentos, Kobayashi e Toya confirmaram que os ângulos de desalinhamento em diferentes planos influenciam significativamente a distância de deslizamento da correia. Além disso, a velocidade de transporte da correia também

foi investigada, concluindo que o aumento da velocidade não aumenta significativamente o desalinhamento, devido à força de centragem que atua na correia.

A Figura 2.9 ilustra como o desalinhamento da correia ocorre em tambores cilíndricos. Quando há um ângulo de desalinhamento no plano (β) do rolete acionado, a correia que toca o rolete move-se junto com ele, assumindo uma nova linha de rastreamento que faz um ângulo reto com o eixo do rolete. Este movimento faz com que a correia deslize para o lado, gerando o desalinhamento. A correia continua a se mover na direção do desalinhamento até que eventualmente possa sair do rolete. A figura mostra a progressão do ponto de borda da correia de X1 para X2, ao invés de diretamente para X3.




Figura 2.9- Placa de impacto clássica design.
Fonte: Adaptado de Kobayashi e Toya, 2007.

Debek (2023) em seus estudos utilizou esse método de desalinhamento para o tambor de retorno, resultando em uma distribuição assimétrica das tensões na correia. Este desalinhamento gerou forças de tensão e atrito que, por sua vez, provocaram atrito cinético, carregando os rolamentos do tambor de forma desigual. Como resultado, a correia se movia em direção ao atuador com menor tensão, levando ao desalinhamento. Os resultados experimentais mostraram um aumento na resistência ao movimento da máquina, que afetou diretamente os valores das forças registradas no sistema de acionamento e no mecanismo de tensionamento, além de aumentar o consumo de energia elétrica do motor de acionamento.

2.3.1.3. Desalinhamento causado pela alimentação

Os materiais a granel precisam manter um fluxo uniforme e consistente ao passar pelo chute. Cargas de surto podem causar vários problemas, entre eles o desvio da correia (Vreeburg, 2018).

O carregamento fora de centro corresponde quando o material é descarregado na correia transportadora predominantemente de um lado (Figura 2,10). Esse problema é comum em chutes onde a direção do escoamento é alterada. Entretanto, pode ocorrer em chutes de transferência em linha, quando o material se acumula dentro do chute, não chegando ao entupimento (Figura 2.11) ou quando há mudanças nas características do material como umidade, tamanho das partículas ou velocidade da correia transportadora alterando a trajetória do material. Isso faz com que o material se acumule mais em um lado da correia receptora (Swinderman *et al*, 2009).



Figura 2.10 - Carregamento fora de material fora de centro.
Fonte: Adaptado de Swinderman *et al.*, 2009.




Figura 2.11 - Acumulo de material na calha de transferência.
Fonte: Adaptado de Swinderman *et al.*, 2009.

2.3.1.4. Desalinhamento causado posicionamento dos roletes.

O desalinhamento da correia pode ser causado pelo posicionamento incorreto dos cavaletes de roletes. Quando instalados com desvio angular em planta, esses elementos geram forças laterais que desviam a correia de seu trajeto central, provocando desgaste nas bordas e risco de falhas operacionais (Yurchenko, 2017).

Esse efeito é induzido pela rotação dos cavaletes (Figura 2.12(A) ou por sua inclinação no plano vertical, Figura 2.12(B), podendo até causar desalinhamento em sentido oposto ao desejado. Pequenos desvios acumulados ao longo do transportador podem intensificar o problema, tornando essencial o correto alinhamento estrutural desses componentes (Yurchenko, 2017).




Figura 2.12 - a) Mal alinhamento dos cavaletes b) Inclinação incorreta dos cavaletes.
 Fonte: YURCHENKO, 2017.

2.3.2. Problemas causados pelo desalinhamento de correia

A disponibilidade e confiabilidade do sistema de transporte por correia são requisitos de alto nível para plantas de mineração. O desalinhamento ou desvio da correia transportadora é uma das causas que interrompem a operação, causando perdas de produção e danos à correia (Bahrin *et al.*, 2021).

O desalinhamento causa desgaste desigual e acelerado na correia, especialmente nas bordas (Figura 2.13), expondo o núcleo da correia e levando à sua deterioração prematura e necessidade de substituições frequentes. Além disso, o

contato contínuo da correia com partes fixas do transportador, como roletes e tambores, aumenta o desgaste desses componentes, resultando em custos adicionais de manutenção e reparo (Yurchenko, 2017). Como a correia desalinha na direção de menor tensão, isso leva ao atrito da correia e a estrutura do transportador (Figura 2.14). em muitos casos esse contato acontece entre a correia e os roletes guias, que corresponde a proteções contra esse fenômeno (Figura 2.15) (Bortnowski *et al.*, 2022). O aumento da fricção no sistema, eleva a potência necessária para operar o transportador, aumentando os custos operacionais e impondo desgaste prematuro aos componentes do sistema, como os motores de acionamento e mecanismos de tensionamento (Dabek *et al.*, 2023; Reicks, 2016).




Figura 2.13 - Desgaste da borda da correia.
Fonte: Nortnowski *et al.*, 2022.



Figura 2.14 - Desgaste da estrutura do transportador.
Fonte: Nortnowski *et al.*, 2022.



Figura 2.15 - Contato correia e rolete guia.

Fonte: Nortnowski *et al.*, 2022.

O desalinhamento severo pode resultar em derramamento e dispersão de matéria (Sun; Wang e Meng, 2022). Especialmente nas bordas da correia, causando perdas de material e riscos de segurança para os trabalhadores, exige limpeza e manutenção adicionais, além disso a queda de material úmido ao redor das estruturas de aço do transportador podem acelerar a corrosão, ao mesmo tempo em que dificultam a observação do problema pela equipe de manutenção da planta de operação (Otto; Katterfeld, 2019; Gibbs, 2019; Swinderman *et al.*, 2009). Na Figura 2.16 encontram-se exemplos desse material que cai da correia.



Figura 2.16 - Derramamento de material causado pelo desalinhamento

Fonte: Swinderman *et al.*, 2009.

Além do desgaste e do derramamento de material, o atrito prolongado entre a correia transportadora e componentes como roletes e estruturas. em casos graves

pode levar a incidentes como incêndios ou até mesmo o descolamento da correia do quadro do rolo, conforme ilustrado na Figura 2.17. Esses incidentes têm consequências severas para o equipamento, podendo causar danos irreparáveis, além de representar riscos significativos para o meio ambiente e a segurança dos trabalhadores (Zhang e Wei, 2023).



Figura 2.17 - Incêndio por atrito da correia.
Fonte: Zhang e Wei, 2023.

2.4. Metodologia DEM

Método dos Elementos Discretos (DEM) é utilizado para modelar e simular o comportamento de partículas adesivas, especialmente em sistemas onde as forças adesivas desempenham um papel crucial. Este método, introduzido por Cundall e Strack em 1979, se destaca por sua capacidade de resolver o meio adesivo em escala de partículas individuais. Isso permite uma representação precisa das interações de contato entre partículas (Chen *et al.*, 2023).

Softwares que utilizam o DEM são frequentemente empregados para otimizar o dimensionamento de chutes de transferência, permitindo a calibração dos materiais e a importação de geometria. As simulações ajudam a identificar riscos de bloqueios, áreas de alto desgaste e determinar a capacidade máxima dos chutes. Isso reduz a necessidade de protótipos físicos e acelera o processo de desenvolvimento de projetos (Cole, 2024).

O modelo JKR (Johnson-Kendall-Roberts) é amplamente utilizado no método de elementos discretos (DEM) para simular contatos coesivos entre partículas, nesse

modelo são incorpora forças de adesão causadas pelos efeitos de van der Waals. Esse modelo é essencial para entender a interação entre partículas em ambientes onde a adesão desempenha um papel significativo, como em materiais viscoelásticos e solos úmidos (Zhao *et al.*, 2019). A força normal JKR é calculada conforme exposto na Eq. (01):

$$F_{JKR} = -4\sqrt{\pi\gamma E^* \alpha^3} + \frac{4E^*}{3R^*} \alpha^3, \quad (1)$$

sendo que γ representa a energia superficial, E^* corresponde ao módulo de Young, equivalente, α é o raio de contato, e R^* é o raio equivalente, eles são dados por:

$$\alpha = \sqrt{\delta R^*}, \quad (2)$$

$$\frac{1}{R^*} = \frac{1}{R_i} + \frac{1}{R_j}. \quad (3)$$

Sendo que R_i e R_j denotam os raios das duas partículas, δ é a sobreposição JKR. Quando a energia superficial $\gamma=0$, a força normal JKR é calculada pelas Equações (F_{jkr}) e (α), tornando-se então a força normal Hertz-Mindlin, expressa na Eq. (4)

$$F_{Hertz} = \frac{4}{3} E^* \sqrt{R^* \delta^3}. \quad (4)$$

A lacuna máxima δ_c com coesão não nula entre partículas é definida como:

$$\delta_c = \frac{\alpha_c^2}{R^*} - \sqrt{\frac{4\pi\gamma\alpha_c}{E^*}}, \quad (5)$$

$$\alpha_c = \left(\frac{9\pi\gamma R^{*2}}{2E^* \left(\frac{3}{4} - \frac{1}{\sqrt{2}} \right)} \right)^{\frac{1}{3}}. \quad (6)$$

Na ocasião onde as partículas não estão em contato real e a lacuna é menor que δ_c , a força coesiva máxima é denominada de força de tração e pode ser expressa da seguinte forma:

$$F_{pullout} = \frac{3}{2} \pi \gamma R^*. \quad (7)$$

Nesse modelo, pode-se determinar que a força necessária com o intuito de separar duas partículas úmidas em contato é calculada pela Eq. (8), onde γ é a tensão

superficial do líquido; θ é o ângulo de contato. A energia superficial do modelo JKR é deduzida como:

$$F_{pullout} = -2\pi\gamma_{\delta} \cos(\theta) \sqrt{R_i R_j}. \quad (8)$$

Nos chutes de transferência, o DEM é utilizado para projetar e otimizar o fluxo de materiais, minimizando problemas como bloqueios e desgaste excessivo dos revestimentos do chute. Um estudo específico (Basu *et al.*, 2021). Focou na modificação de um chute de alimentação de secador em uma planta de pelotização de minério de ferro. Utilizando o DEM, tornou-se capaz de identificar áreas problemáticas (Figura 2.18) e propor modificações de projeto que resultaram em melhorias significativas na operação do chute, como mudanças na placa defletora e na inclinação e seção transversal do chute. Essas alterações reduziram o bloqueio e o desgaste, melhorando a confiabilidade e a vida útil do equipamento (Basu *et al.*, 2021).




Figura 2.18 - Utilização DEM para projeto de chutes de transferência.
 Fonte: Basu *et al.*, 2021.

2.5. Vibrações mecânicas

As técnicas de identificação de defeitos por análise de vibração podem ser divididas em três grandes grupos de acordo com o domínio cujo sinal é tratado e analisado. Portanto, são essas técnicas no domínio do tempo e no domínio da frequência e no tempo-frequência (Bezerra, 2004).

2.5.1. Análise no Domínio do Tempo

Uma série temporal é composta por uma sequência de valores numéricos discretos ao longo do tempo, a partir dos quais vários atributos podem ser extraídos para determinar índices que caracterizam o sinal. Nesse contexto, considerando a série temporal x_i ($i = 1, 2, 3, \dots, N$), onde N representa o número de elementos de x_i , as expressões matemáticas a seguir descrevem características ou atributos que podem ser extraídos de uma série temporal, considerando o sinal no domínio do tempo (Costa, 2024):

2.5.1.1. Valor-de-Pico

O valor-de-pico corresponde ao valor absoluto do elemento de maior magnitude dentre os demais indivíduos da série:

$$X_{pico} = \max|X_i|. \quad (9)$$

2.5.1.2. Raíz Média Quadrada (RMS)

Trata-se da raiz quadrada da média dos quadrados de todos os elementos do sinal. Esse cálculo pode oferecer uma percepção da energia total presente no sinal (Caesarendra, 2015). O valor RMS é uma métrica amplamente reconhecida na análise de vibrações para avaliar os níveis estatísticos globais das vibrações. Esse valor oferece uma medida eficaz da amplitude média das vibrações ao longo do tempo, auxiliando na quantificação do nível de vibração global em um sistema. Ele é especialmente útil para indicar aumentos na energia do sinal. Conforme mencionado por Barilli (2013), as vibrações globais tendem a se manifestar nos estágios finais de falha, o que limita a eficácia do valor RMS na detecção de defeitos em fases iniciais. A Eq. 10 ilustra como calcular o RMS:

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N X_i^2} \quad (10)$$

2.5.1.3. Fator de Crista

O fator de crista corresponde a razão entre o valor-de-pico e o valor RMS. Segundo Caesarendra (2015), trata-se de uma medida de impactos, apropriada para sinais com características de picos consecutivos. De acordo com Bezerra (2004), há uma relação que descreve o comportamento e classifica o fator de crista de um

equipamento. Ele notou que, com o aparecimento de um defeito no rolamento, o valor de pico aumenta mais rapidamente do que o valor RMS, resultando em um aumento do fator de crista. Essa relação é ilustrada na Figura 2.19.




Figura 2.19 - Relação entre o valor de pico da vibração e o valor RMS
Fonte: Bezerra, 2004.

2.5.1.4. Fator K

O fator K é uma métrica empregada na análise de vibrações mecânicas, desenvolvida para superar as limitações do fator de crista na detecção de defeitos em estágios iniciais. O fator de crista, que é a razão entre o valor de pico da vibração e o valor RMS do sinal, pode não ser eficaz em identificar problemas quando os sinais de defeitos são fracos. Para contornar essas limitações, o fator K é definido como o produto do valor RMS pelo valor de pico das vibrações. A expressão matemática do fator K é dada na Eq. 11 essa métrica permite uma detecção mais sensível e precisa de anomalias vibratórias, aprimorando a eficiência no monitoramento da saúde de máquinas e estruturas (Bower; Qi e Bazilevs, 2023.). A Figura 2.20 mostra a evolução do fator K ao longo do tempo, conforme Bezerra (2024). Esta representação gráfica destaca como o valor do fator K pode variar à medida que as condições das máquinas mudam, evidenciando a importância de seu monitoramento contínuo.

$$F_K = X_{PICO}X_{RMS} \quad (11)$$




Figura 2.20 - Fator K
Fonte: Bezerra, 2004.

2.5.1.5. Curtose

A Curtose é um conceito estatístico usado na análise de vibrações e detecção de falhas em máquinas, especialmente em rolamentos. A curtose é o quarto momento estatístico central normalizado pelo desvio padrão, elevado à quarta potência. Para defeitos em rolamentos, um rolamento em condições normais exibe uma distribuição Gaussiana de aceleração, representando a aleatoriedade esperada. No entanto, quando um rolamento desenvolve defeitos, essa distribuição se torna não gaussiana devido ao aumento de picos de aceleração (Moura, 2024).

A Equação da densidade de probabilidade, representada como $p(x)$, e o cálculo da Curtose (k) são apresentadas nas Eqs. 12 e 13.

$$p(x) = \frac{1}{\sqrt{2\pi\sigma}} \exp \left[-\frac{1}{2} \left(\frac{x(t) - \mu}{\sigma} \right)^2 \right] \quad (12)$$

$$k = \left[\frac{m}{\sigma} \right]^4 = \frac{1}{\sigma^4} \int_{-\infty}^{+\infty} [x(t) - \mu]^4 p(x) dx \quad (13)$$

2.6. Aprendizado de máquina

O aprendizado de máquina, um ramo essencial da inteligência artificial, tem se destacado na ciência moderna por sua capacidade de capacitar sistemas computacionais a executar tarefas específicas sem a necessidade de comandos explícitos. Esse campo da inteligência artificial utiliza algoritmos e modelos estatísticos para permitir que máquinas aprendam e façam previsões ou decisões com base em dados. Entre as inúmeras aplicações do aprendizado de máquina, destacam-se a mineração de dados, o processamento de imagens e a análise preditiva, áreas nas quais essas tecnologias têm revolucionado processos e resultados (Mahesh, 2020).

Existem várias categorias de aprendizado de máquina, cada uma com suas próprias características e aplicações. O aprendizado supervisionado, por exemplo, utiliza algoritmos que treinam modelos com base em dados rotulados, permitindo que o sistema preveja resultados futuros com precisão. Em contraste, o aprendizado não supervisionado trabalha com dados não rotulados, buscando identificar padrões ocultos ou estruturas subjacentes sem qualquer orientação prévia. Além disso, o aprendizado semi-supervisionado combina elementos de ambos, aproveitando uma pequena quantidade de dados rotulados juntamente com um grande volume de dados não rotulados para melhorar a eficácia do modelo (Géron, 2019; Soares, 2024).

Os tipos de dados que o computador pode prever são definidos por um método de aprendizado de máquina alternativo. De acordo com Izbicki e Santos (2020), a previsão é obtida por uma variável $Y \in \mathbb{R}$, depende de um vetor $x = (x_1, \dots, x_d) \in \mathbb{R}^d$. O aprendizado está solucionando um problema de regressão quando a predição fornece Y como variável quantitativa. Por outro lado, o problema em questão é chamado de classificação se Y for uma variável qualitativa.

Dentre os métodos de Classificação, existem os classificadores *Plug-in*, *Support Vector Machine* (SVM), Árvores de decisão, Método do k vizinhos mais próximos e, por fim, as Redes neurais artificiais (Soares, 2024).

2.6.1. Árvore de decisão

Árvore de decisão é uma das técnicas mais amplamente utilizadas em aprendizado de máquina, especialmente em problemas de classificação, sendo aplicada em áreas que envolvem o estudo de máquinas, reconhecimento de padrões e estatística (Jijo; Abdulazeez, 2021). Essencialmente, a árvore de decisão cria uma

partição do espaço amostral baseada nos dados, representada em forma de árvore (Janikow, 1998). Essas metodologias são não paramétricas e interpretam resultados através de particionamentos chamados nós. Inicialmente, cada particionamento define uma condição sobre a distribuição dos dados por classes e direciona as amostras de dados para outros nós, repetindo o processo conforme os parâmetros estabelecidos no aprendizado. Os últimos nós da árvore, denominados folhas, correspondem às predições (De Ville, 2013; Izbicki; Santos, 2020). A Figura 2.21 mostra um exemplo de formação de uma árvore de decisão (Jijo; Abdulazeez, 2021).




Figura 2.21 – Árvore de decisão.

Fonte: Jijo e Abdulazeez, 2021

Uma grande vantagem das árvores de decisão é a facilidade com que as predições podem ser interpretadas usando ferramentas gráficas. Além disso, para aumentar a precisão das predições e lidar com grandes quantidades de dados, métodos que combinam várias árvores, como o *Gradient Boosting Decision Tree* (GBDT), os tornam mais otimizados (Liu *et al.*, 2020). Como afirmado por Liu *et al.*, (2021), para reduzir o erro entre os valores reais e previstos, um modelo inicial é ajustado aos resíduos de um modelo anterior. A combinação dos resultados de todos os modelos anteriores dá como resultado um modelo preditivo final. Conforme a Eq.

14, o processo GBDT procura os parâmetros ideais α e β , onde $F_m(x_i)$ é a função preditiva na m -ésima interação.

$$(\alpha_m, \beta_m) = \arg \min_{\alpha, \beta} \sum_{i=1}^N (L(y_i, F_m(x_i)) + \beta h(x_i; \alpha)) \quad (14)$$

inicialmente, deve-se definir um classificador fraco F_0 (Eq. 15) partindo da constante β para alcançar o valor mínimo da função de perda $L(y, F_m(x))$:

$$F_0 = \arg \min_{\beta} \sum_{i=1}^N L(y_i, \beta) \quad (15)$$

Para reduzir a função de perda, o m -ésimo classificador ($\beta_m h(x; \alpha_m)$) é construído na direção do gradiente descendente na Eq. 16:

$$-g_m(x_i) = -\left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right], F(x_i) = F_{m-1}(x_i), i = 1, \dots, N \quad (16)$$

Os dados da amostra são ajustados a partir dos classificadores básicos para obter um modelo inicial, e o parâmetro α_m é ajustado na Eq. 17:

$$\alpha_m = \arg \min_{\alpha, \beta} \sum_{i=1}^N [-g_m(x_i) - \beta h(x_i; \alpha)]^2 \quad (17)$$

Com α_m calculado, é possível calcular a Eq. 18 com o peso atual do modelo:

$$\begin{aligned} \beta_m &= \arg \min_{\alpha, \beta} \sum_{i=1}^N L([y_i, F_{m-1}(x_i) + \beta h(x_i; \alpha)]^2 F_0) \\ &= \arg \min_{\beta} \sum_{i=1}^N L(y_i, \beta) \end{aligned} \quad (18)$$

Com os parâmetros estabelecidos, a função preditiva (Eq. 19) é atualizada após cada interação até a condição de convergência:

$$F_m(x) = F_m(x) + \beta h(x_i; \alpha_m) \quad (19)$$

Entre as variações mais conhecidas de árvores de decisão estão a Árvore de Classificação e Regressão (CART), Dicotomias Iterativas 4 (ID4), Detecção Automática de Interação Qui-quadrado (CHAID) e Árvore Estatística Imparcial e

Eficiente (QUEST) (Jijo; Abdulazeez, 2021). No método CART, cada regra usa uma única variável de entrada para determinar a melhor divisão para cada nó, utilizando critérios de medida de impureza, como o índice de Gini, que mede a distribuição de dados de cada classe em um nó. Isso facilita a seleção de características mais relevantes e a eliminação das menos significativas, aumentando a precisão do modelo nas etapas subsequentes (Zaman et al., 2011; Muralidharan; Ravikumar e Kangasabapathy, 2014; Ravikumar; Kanagasabapathy e Muralidharan, 2019, 2020). A impureza do nó é calculada pelo índice de Gini, conforme a Eq. 20:

$$i(t) = 1 - \sum_{h=1}^c P(t_c^h)^2 \quad (20)$$

A Figura 2.22, conforme Izbicki e Santos (2020), exemplifica a estrutura de uma árvore de decisão, destacando como as amostras de dados são ramificadas e condicionadas em sucessivos nós até atingirem as folhas, que correspondem às predições finais.




Figura 2.22 - Estrutura da árvore de decisão.
Fonte: Izbicki e Santos, 2020.

2.6.2. Máquina de vetor e suporte (SVM)

Em tarefas de classificação, enfrentam-se dois tipos de desafios: o conceitual e o computacional. O primeiro refere-se à dificuldade de encontrar um hiperplano que consiga separar adequadamente os dados em espaços com muitas variáveis, assegurando que o modelo generalize bem. Já o segundo diz respeito à complexidade de lidar com esses espaços de alta dimensionalidade de forma eficiente. Para contornar essas limitações, foi proposta a Máquina de Vetores de Suporte (SVM), que determina um hiperplano ótimo com base nos vetores que delimitam as classes (Costa, 2024).

A SVM tornou-se uma das principais técnicas da Inteligência Artificial, destacando-se pela alta precisão na separação de padrões, superando muitas abordagens tradicionais (Costa, 2024). Sua lógica consiste em projetar os dados de entrada, por meio de funções não lineares, em um espaço de características mais complexo, onde seja possível traçar um plano com máxima margem entre os grupos, favorecendo a capacidade preditiva do modelo. A Figura 2.25 ilustra esse conceito, mostrando a separação ótima entre as classes por meio de margens máximas.




Figura 2.23 - Hiperplano de separação ótima.

Fonte: Costa, 2024.

3. ESTUDO EXPERIMENTAL

3.1. Circuito de manuseio

Para a geração de dados experimentais, foi necessário projetar um circuito de transferência de minério. Esse circuito foi baseado no trabalho de Wanzeler (2023), que realizou um estudo de similaridade numérica de um chute real, com o intuito de criar um modelo em escala reduzida, esse chute em questão integra o projeto de um circuito de manuseio de minério do Laboratório de Fluidodinâmica e Particulados (Fluidpar). Esse chute é denominado de CT-01.

O circuito possui como componentes principais a moega (MG-01), localizada no transportador de correia (TR-01), que transporta o fluxo de material até o chute de transferência (CT-01). O mesmo descarrega o material na segunda transportador de correia (TR-02), que o conduz para o segundo chute (CT-02), situada na entrada do elevador de caneca (EC-01). O elevador de caneca eleva o material até o terceiro transportador de correia (TR-03), através do terceiro chute de transferência (CT-03). Encontra-se o fluxograma do circuito na Figura 3.1. O circuito de manuseio de minério já contava em pose os seguintes equipamentos TR-01(JUNTO MG-01), TR-02, TR-03 e EC-01, que são mostrados na Figura 3.2.




Figura 3.1 - Fluxograma do circuito de manuseio de minério.

Fonte: Elaboração própria.



(A)



(B)



(C)



(D)

Figura 3.2 - Equipamentos em posse do laboratório. a) MG-01 e TR-01; b) TR-02; c) TR-03; d) EC-01

Fonte: Elaboração própria.

Com a finalidade de interligar os componentes já presentes no laboratório, houve-se a necessidade de projetar os chutes de transferências CT-02 e CT-03. E assim também como duas estruturas metálicas, a primeira corresponde à estrutura para suportar o CT-01, denominado SP-01. E a segunda, chamada de SP-02 que tem como função adequar a altura do transportador de correia dois (TC-02) aos demais componentes do circuito. os componentes citados anteriormente, encontram-se exposto na figura a seguir (Figura 3.3).




Figura 3.3 - Equipamentos projetados. a) CT-02; b) SP-01; c) SP-01; d) SP-02.
 Fonte: Elaboração própria.

Os chutes de transferências citados anteriormente tiveram simulações individuais utilizando o método de elementos discretos (DEM) com o *software* bulkflow V14, os dados do material usando na simulação corresponde a calibração feita por Wanzeler (2023), com a finalidade de fazer um projeto de qualidade sem problemas comuns, como já citados, em exemplo tem-se o entupimento ou um escoamento desalinhado.

Afim de ter o posicionamento e as distâncias ideais de todos os componentes do circuito, teve-se a necessidade de simular todos os componentes do circuito de manuseio (Figura 3.4). Com os resultados dessa simulação conformaram-se que as posições ideais dos componentes são as mesmas projetadas baseadas nas simulações individuais. O projeto final do circuito de manuseio de minério apresentado na Figura 3.5 e na Figura 3.6 encontra-se o projeto construído no laboratório.




Figura 3.4 - Simulação circuito de manuseio simulações DEM.
 Fonte: Elaboração própria.




Figura 3.5 - Circuito de manuseio de minério projeto.
 Fonte: Elaboração própria.



Figura 3.6 - Circuito de manuseio de minério.
Fonte: Elaboração própria.

3.1.1. Chute de transferencia(CT-01) e alinhamento gradual

O chute CT-01 é composto por duas caixas de pedra, sendo apresentada na Figura 3.7 a modelagem do CT-01, bem como a disposição dos transportadores TR-01 e TR-02 sobre ele. Utilizando o método de elementos discretos (DEM) e o software Bulk Flow Analyst V14 analisou inicialmente o escoamento. A Figura 3.8 (A) apresenta a vista frontal do chute com o fluxo de material e na Figura 3.8 (B) a vista isométrica.




Figura 3.7-Modelagem CT-01
Fonte: Elaboração própria.




Figura 3.8-vista frontal da simulação(A); vista isométrica(B).
Fonte: Elaboração própria.

Para analisar o desalinhamento do transportador de correia 2 (TR-02) utilizou-se a ferramenta *particle motion analyst*, disponível no software *DEM View*. A velocidade dos transportadores de correia (TR-01 e TR-02) corresponde a 1,68 m/s e a taxa de alimentação a 60,33 Ton/hora. Este e os demais dados da simulação estão exposto no trabalho citado anteriormente (Wanzeler, 2023).

Como o desalinhamento pode ser causado pela diferença de passagem de material pelo lado esquerdo e pelo lado direito, nos gráficos a seguir essa quantidade de material será apresentada por LE para o número de partículas passando pelo lado esquerdo e LD para o número de partículas passando pelo lado direito, correspondente ao sentido do escoamento. Essa divergência na passagem de

material dentro de uma simulação DEM corresponde ao fator de desalinhamento (Figura 3.9). Na Figura 3.10 apresenta-se o fator de desalinhamento do CT-01 ao longo do Tempo, representa o fluxo de material fora de centro na saída do chute.




Figura 3.9 - Fator de desalinhamento.
Fonte: Elaboração própria.





Figura 3.10 – Média do desalinhamento no tempo.
Fonte: Elaboração própria.

Como o chute apresenta um Fator desalinhamento alto, com uma diferença de carga entre os lados direito e esquerdo de 40%. Projetou-se modificações com o intuito de alinhar de forma gradual o escoamento, para assim gerar dados experimentais para a pesquisa. As modificações desenvolvidas correspondem a duas formas de alinhar o chute de transferência. A primeira corresponde a uma defletora

reta e a segunda como um basculante móvel, respectivamente representadas na Figura 3.11 (A) e Figura 3.11 (B).



(A) (B)
Figura 3.11 - Defletora reta(A); basculante móvel(B).
 Fonte: Elaboração própria.

A defletora reta encontra-se posicionada entre as duas caixas de pedra, a geometria do mesmo foi a de um triângulo retângulo com as arestas iguais. A fim de variar o desalinhamento essa defletora funciona como uma guilhotina, variando o valor do comprimento das arestas, para modificar o desalinhamento. Baseando-se nesse método, foram feitas diversas simulações. na Figura 3.12 encontra-se um exemplo dessas simulações. E com base no resultado delas gerou-se a tabela do fator de desalinhamento pelo comprimento da defletora da Figura 3.13.




Figura 3.12 - Simulação com defletora reta.
 Fonte: Elaboração própria.




Figura 3.13 – Fator de desalinhamento pelo comprimento da defletora

Fonte: Elaboração própria.

A basculante móvel atua guiando a queda do material, conforme aumentamos o ângulo entre a parede do chute e a chapa basculante móvel, o fluxo de material é alinhado gradativamente. Na Figura 3.14 encontra-se uma simulação de como o material se comporta com essa modificação. Baseando-se nas simulações variando a distância da parede do chute e a basculante móvel a Figura 3.15 encontra-se um gráfico de como o desalinhamento diminui com o aumento do ângulo. Nota-se que é apresenta um valor negativo. Isso ocorre quando o desalinhamento sai do lado direito da correia para o lado esquerdo.




Figura 3.14 - Simulação basculante móvel.

Fonte: Elaboração própria.




Figura 3.15 – Fator de desalinhamento pelo movimento da basculante (com cavalete 45°).

Fonte: Elaboração própria.

Em processo experimental do comissionamento do circuito observou-se que o desalinhamento era pouco visível por conta de os cavaletes serem de 45 graus. Com o intuito de melhorar a visualização do material depositado de forma desalinhado sobre a correia, confeccionou-se, e houve a troca dos cavaletes com inclinação de 45 graus (Figura 3.16 (A)), por cavaletes de 20 graus (Figura 3.16 (B)). Com essa mudança, houve a necessidade de refazer as simulações do escoamento, a figura a seguir trás esses dados e a divisão das classes que corresponde ao fator de desalinhamento grave, leve e alinhado (Figura 3.17):




Figura 3.16 - Cavalete com 45°(A); Cavalete com 20°(B).

Fonte: Elaboração própria.




Figura 3.17 – Fator de desalinhamento pelo movimento da basculante (com cavalete 20°).

Fonte: Elaboração própria.

3.2. Metodologia para coleta de dados e análise de sinais de vibração.

3.2.1. Coleta de dados de vibração

Com o objetivo de avaliar o desalinhamento com base em sinais de vibrações, foi utilizado o TC-02, os cavaletes dispostos foram os de 20°. Cada cavalete é composto por três roletes. São dois posicionados nas laterais sob a correia em um ângulo de 20° e um posicionado horizontalmente sob a região central da correia. Para a coleta de dados dois acelerômetros da empresa ®Dynamox S.A, o modelos DynaLogger HF+, Na Tabela 1 encontra-se as especificações técnicas do modelo.

Tabela 1- Especificações técnicas modelo HF+

Informações gerais	
Modelo	HF+
Dimensão	39 mm x 39 mm x 35 mm
Peso	67 g
Material	LEXAN™
Cor	Azul
Fixação	Parafusado ou colado
Memória	51 200 amostras (configurável)
Bluetooth	BLE 53 / 2400 –2483.5 MHz
Tensão	3 V
Autonomia	3 a 5 anos
Alcance	100 m
Comunicação com App	Android e iOS

Temperatura de operação	
Temperatura de operação	$-20^{\circ}\text{C} \leq T \leq 84^{\circ}\text{C}$
Resolução de temperatura	0,01°C
Vibração	
Acelerômetro	MEMS triaxial
Bandas de frequência	2 Hz a 13 kHz (configurável)
Resposta em frequência (± 3 dB)	7,6 kHz
Faixa de amplitude	Até ± 16 g
Taxa de amostragem	Até 26 kHz
Resolução mín. em frequência	0,006 Hz (8 bits) e 0,012 Hz (16 bits)
Resolução mín. em amplitude	16 mg (8 bits) e 61 μg (16 bits)
Linhas de resolução (LOR)	98 304 (uniaxial) e 32 768 (triaxial)
Frequência máxima	571 Hz a 13 kHz (configurável)
Tempo máx. de aquisição	172,2 s (uniaxial) e 57,3 s (triaxial)

Fonte: Elaboração própria.

Os acelerômetros estão posicionados lateralmente a um dos cavaletes próximos ao centro da correia transportadora, o transportador é composto por 4 cavaletes sobre o chute de transferência um (CT-01), os outros quatro dispostos sobre transportador, na Figura 3.18 (A) temos uma ilustração disso, junto a nomenclatura dos sensores, que se refere ao lado que ele está posicionado, sensor do lado direito (LD) e sensor do lado esquerdo (LE), dentro dela também tem o a representação do posicionamento de cada eixo.

A instalação dos sensores ao cavalete está exposta na Figura 3.18 (B), a forma de fixação deles é por aparafusamento com um parafuso M6 (Figura 3.18, (C)), que precise de 7,2 mm de profundidade mínima em relação a superfície perfurada, e mostrado na Figura 3.18 (C) junto as dimensões do acelerômetro.




Figura 3.18 - Desenho dimensional dos roletes.

Fonte: Elaboração própria.

A plataforma *DynaPredict Web* foi usada para configurar a coleta de dados dos sensores. *DynaPredict Web* é um espaço na nuvem, onde os dados coletados pelos *dynaloggers* são centralizados por meio de um aplicativo móvel, sendo utilizados para análise, interpretação e previsão de falhas. Através da plataforma, configuram-se os espectrais padrões do sinal, conforme mostrado na Tabela 2.

Tabela 2 - Configuração espectral

Faixa dinâmica	4g
Eixos	X, Y e Z
Frequência máxima	6572 Hz
Duração da coleta	2,49 s
Taxa de amostragem	12800 Hz

Fonte: Elaboração própria.

Após a configuração do sensor, realizou-se a coleta dos sinais de vibração, que foram classificados em duas categorias: a primeira correspondendo ao alinhamento e a segunda ao desalinhado. O ideal seria utilizar três classes, onde seria dividido em alinhado, desalinhamento leve e desalinhamento severo. Onde o desalinhamento foi com base nas simulações DEM, onde a diferença de material entre o LD e O LE corresponde a um desalinhamento abaixo de 10% corresponde aos dados alinhados, entre 10% e 20% como desalinhamento leve e acima de 20 % Como desalinhamento severo. No entanto, quando foram realizados os experimentos, notou-se uma dificuldade em ajustar o desalinhamento moderado e alinhado. Logo, optou-se para

usar apenas duas classes alinhado e desalinhado, essa classe desalinhada consiste em ser o desalinhamento grave. A Figura 3.19 (A) apresenta o ensaios com a correia alinhada e na Figura 9.19 (B) apresenta o desalinhamento severo




Figura 3.19- Ensaio experimental; alinhado (A), desalinhado (B).

As coletas dos sinais foram feitas a partir do aplicativo *mobile dynaprect* da @Dynamox S.A, organizados em arquivos de formato *json*. Eles foram baixados manualmente após verificação do ID de cada sinal no site da *Dynaprect*, e distribuídos em pastas conforme a data e local de coleta.

Os arquivos foram organizados em pastas dentro do *google drive*, onde o mesmo foi nomeado de alinhado e desalinhado, que corresponde as classes, e dentro dessas classes possuem subpastas que são LD (lado direito) e LE (lado esquerdo), que são o posicionamento do sensor no cavalete, na tabela a seguir tem-se as disposições desses dados (Tabela 3), no total foram extraídos 1.756 sinais espectrais. Essa configuração permitiu agrupar os dados por classe e localização dos sensores, posicionamento do mesmo.

Tabela 3 - Sinais coletados

Condição	Posição do acelerômetro	
	LD	LE

	(sinal espectral)	(sinal espectral)
Alinhado	458	474
Desalinhado	410	414

Fonte: Elaboração própria.

As Figuras 3.20 e 3.21 apresentam os espectros de frequência triaxiais (eixos x,y e z) para a condição alinhada, lado esquerdo (LE) e direito (LD), respectivamente. Eles são exemplos dos dados coletados. Nas Figuras 3.22 e 3.23, correspondentes a espectros de sinal da classe desalinhada para LE e LD, respectivamente.




Figura 3.20 - Gráficos de sinal alinhado-LE no domínio da frequência.
Fonte: Elaboração própria.




Figura 3.21 - Gráficos de sinal alinhado-LD no domínio da frequência.
Fonte: Elaboração própria.




Figura 3.22 - Gráficos de sinal desalinhado-LE no domínio da frequência.

Fonte: Elaboração própria.




Figura 3.23 - Gráficos de sinal desalinhado-LD no domínio da frequência.

Fonte: Elaboração própria.

Nas Figuras 3.24 e 3.25 apresentam os sinais no domínio do tempo triaxiais (eixos x,y e z) para a condição alinhada, lado esquerdo (LE) e direito (LD), respectivamente. Eles são exemplos dos dados coletados. Nas Figuras 3.26 e 5.27, correspondentes a espectros de sinal da classe desalinhada para LE e LD, respectivamente.




Figura 3.24 - Gráficos de sinal alinhado-LE no domínio do tempo.

Fonte: Elaboração própria.




Figura 3.25 - Gráficos de sinal alinhado-LD no domínio do tempo.

Fonte: Elaboração própria.




Figura 3.26 - Gráficos de sinal Desalinhado-LE no domínio do tempo.

Fonte: Elaboração própria.




Figura 3.27 - Gráficos de sinal Desalinhado-LD no domínio do tempo.

Fonte: Elaboração própria.

Com o intuito de classificar e avaliar esse desalinhamento foram extraídas características estatísticas essenciais no domínio do tempo, como RMS, valor de pico, fator de crista, fator K. Na Tabela 4 há esses dados para os exemplos trazidos anteriormente.

Tabela 4 - Exemplo de *features* extraída dos dados coletados.

	Eixo	Valor de pico	RMS	Fator de crista	Fator k	Curtose	Assimetria
Alinhado-LE	x	0,75688	0,14907	5,07720	5,07720	3,35860	0,10500

Alinhado-LD	Y	1,56686	1,02959	1,52183	2,89703	2,98276	-0,04864
	Z	1,04759	0,21141	4,95517	15,69224	3,31755	-0,04979
	X	0,73856	0,14908	4,95422	22,57849	3,36592	0,03308
	Y	1,71592	1,03466	1,65844	3,03242	3,13752	0,00487
	Z	0,90375	0,21433	4,21661	13,85807	2,97023	0,04694
	X	1,01013	0,16642	6,06983	21,15359	3,52033	0,19568
Desalinhado-LE	Y	1,68586	1,02596	1,64320	3,02867	3,10729	0,08014
	Z	1,02924	0,20501	5,02048	15,55617	3,18913	-0,02344
	X	0,69656	0,14951	4,65905	21,51064	3,21598	0,13324
Desalinhado-LD	Y	1,55709	1,01498	1,53412	2,99304	3,03786	0,00750
	Z	1,04075	0,229281	4,53919	13,99796	3,20947	-0,04667

Fonte: Elaboração própria.

3.2.2. Pré-processamento e extração de *feature*

Primeiramente, os dados foram pré-processados. foram extraídas características estatísticas essenciais no domínio do tempo, como RMS, valor de pico, fator de crista, fator K, curtose e assimetria. A seleção dessas características é baseada em sua eficácia demonstrada em pesquisas anteriores para identificar falhas em sistemas mecânicos e equipamentos industriais.

Para cada um dos 1.756 sinais (matriz 3×N) são calculados as seis métricas no domínio do tempo para cada eixo. totalizando 18 atributos por sinal. Essa seleção baseia-se em trabalhos que relacionam tais estatísticas a sinais de falha mecânica. O processamento foi desenvolvido em *Python 3.10* e executado no *Google Colaboratory®*.

3.3. Resultados

Com o intuito de avaliar e validar a eficácia dos modelos de classificação na identificação do desalinhamento em correias transportadoras, foram implementadas duas abordagens de aprendizado supervisionado: Máquinas de Vetores de Suporte (SVM) e Árvores de Decisão (Decision Tree), aplicadas separadamente aos dados de cada acelerômetro (LD e LE). A avaliação ocorreu por meio de validação cruzada estratificada do tipo *GroupKFold* com cinco partições, de modo a garantir a integridade dos grupos por arquivo e evitar vazamento de dados entre treino e teste.

As métricas utilizadas para avaliação da performance de ambos os modelos incluíram a acurácia média (com desvio-padrão), o escore F1 ponderado e a matriz de confusão global.

3.3.1. Fluxo algorítmico em Python

O primeiro estágio do algoritmo, a função *extract_triaxial_features* converte cada janela 3×N nos 18 (dezoito) atributos estatísticos, anexando os metadados, rotulando as classe, o posição do sensor e nome do arquivo. A vetorização com o *NumPy* elimina laços explícitos e reduz o tempo de execução para poucos segundos, mesmo quando se processam milhares de janelas.

O segundo estágio, encapsulado em *load_and_segment*, percorre o diretório-raiz, válida a integridade de cada JSON e consolida todas as amostras num único *DataFrame Pandas*. A padronização tabular viabiliza a integração imediata com a API do *Scikit-Learn*.

O terceiro estágio entra em ação *evaluate_side*, que aplica separadamente a LDA e LOA, um *GroupKFold* com $k = 5$. O conceito fundamental de validação cruzada: referece a uma técnica estatística em que o conjunto de dados é fracionado em k partes (ou *folds*, como referenciamos nesse trabalho) e, de forma rotativa, cada parte assume o papel de conjunto de teste, enquanto as partes restantes compõem o conjunto de treino. Assim o modelo é treinado e avaliado k vezes, possibilitando a avaliação do seu desempenho médio em dados realmente novos.

No caso particular do *GroupKFold*, a divisão não é feita amostra a amostra, mas sim por grupos predefinidos. Isso garante que todos os segmentos derivados de um mesmo arquivo permaneçam sempre na mesma partição, prevenindo *data leakage*. Para cada interação, quatro dos cinco grupos (80%) correspondem ao treino, e o grupo remanescente (20%) é reservado exclusivamente para teste. nenhum dado de teste participa do ajuste do modelo nem do cálculo dos parâmetros do *RobustScaler*. Após concluída a avaliação, o grupo de teste retorna ao conjunto de treino e outro grupo assume seu lugar. Ao fim dos cinco ciclos, cada arquivo terá configurado exatamente uma vez como teste, produzindo uma média de acurácias menos suscetível a flutuações amostrais

No quarto estágio são treinados dois modelos distintos. O primeiro corresponde ao SVM com kernel RBF ($C=10; \gamma=\text{"scale"}$), ele é capaz de delinear fronteiras não-lineares em espaço de alta dimensão, enquanto o segundo que corresponde a Árvore de Decisão de profundidade três privilegia transparência interpretativa. Ambos recebem *class_weight='balanced'*, que substituindo técnicas destrutivas de *undersampling* e mantendo a variabilidade das classes menos frequentes. Ao término

de cada *fold*, as predições são armazenadas; o agregado final serve de base para as matrizes de confusão, curvas de acurácia por *fold* e estimativas de importância de atributos.

3.3.2. Desempenho do classificador SVM

Para o modelo SVM, com *kernel* radial base e parâmetro de regularização $C=10$, obteve desempenho satisfatório em ambos os lados do sistema, com destaque para os resultados no lado direito (LE). Nele, o modelo apresentou acurácia média de $97,07\% \pm 0,82$ variação percentual absoluta, e com um escore F1 médio também de $97,07\%$, indicando equilíbrio entre sensibilidade e precisão. A matriz de confusão na Figura 3.28, revela 467 classificações corretas para a classe “Alinhado” e 395 para “Desalinhado”, com apenas 26 classificações equivocadas, sendo 7 falsos positivos e 19 falsos negativos. O desempenho ao longo das partições de validação cruzada evidenciada na Figura 3.29, que ilustra a curva de acurácia por *fold*. Observa-se baixa dispersão entre os valores, com todas as repetições mantendo desempenho acima de 96%, o que atesta a robustez do modelo mesmo frente à variabilidade dos dados.




Figura 3.28 - Matriz de confusão global do classificador SVM no lado (LE)
 Fonte: Elaboração própria.




Figura 3.29 - Curva de acurácia por *fold* para o modelo SVM no lado LE.
 Fonte: Elaboração própria.

A importância das variáveis para a tomada de decisão do classificador, os resultados são apresentados na Figura 3.30. destacaram-se: Kurtosis_y (18%), KFactor_y (10,2%), RMS_x (9,32%), Skewness_z (8%) e Peak_y (7,7%). Esses resultados indicam a predominância do eixo z na caracterização do desalinhamento, a Figura 3.31 possui o treinamento individual de cada fold para o modelo SVM no lado LE.




Figura 3.30 - Importância relativa das 10 principais features para o SVM no lado LE
 Fonte: Elaboração própria.




Figura 3.31- curva de aprendizado individual por fold SVM no lado LE
 Fonte: Elaboração própria.

Para o lado direito (LD), o desempenho do modelo SVM manteve-se alto, com acurácia média de 95,73% com desvio padrão de 1,90. e escore F1 também de 95,73%, conforme demonstrado na Figura 3,32. Ainda que inferior aos valores obtidos

no lado LE, os resultados mostram que o modelo é capaz de generalizar bem mesmo em condições distintas de sensoriamento. A curva de acurácia por *fold* (Figura 3.33) mostra maior variação entre os *folds*, indicando que o modelo pode ser mais sensível a variações no lado LOA, possivelmente devido a ruídos ou menor propagação das vibrações nesse ponto.

No que diz respeito à importância das features (Figura 3.34), foram Kurtosis_y (22,14%), KFactor_y (12,14%), RMS_x (10,36%), Skewness_z (9,64%) e Peak_y (9,29%), sugerindo maior participação dos eixos y e z. A Figura 3.35 possui o treinamento individual de cada fold para o modelo SVM no lado LE.




Figura 3.32 - Matriz de confusão global do classificador SVM no lado LD.
 Fonte: Elaboração própria.




Figura 3.33 - Curva de acurácia por *fold* para o modelo SVM no lado LD.
 Fonte: Elaboração própria.




Figura 3.34 - Importância relativa das 10 principais features para o SVM no lado LD.
 Fonte: Elaboração própria.




Figura 3.35 - curva de aprendizado individual por fold SVM no lado LD.
Fonte: Elaboração própria.

3.3.3. Desempenho do modelo árvore de decisão

O classificador árvore de decisão foi configurado com profundidade máxima de três níveis, visando equilíbrio entre poder discriminativo e interoperabilidade. Tal escolha visa favorecer a compreensão das decisões do modelo, aspecto desejável em aplicações industriais que demandam transparência algorítmica.

No lado LE, o modelo obteve acurácia média de 96,40% $\pm$ 1,86. e score F1 médio de 96,39%. A matriz de confusão mostra 459 classificações corretas da classe “Alinhado” e 397 da classe “Desalinhado”, com apenas 32 erros totais (Figura 3,36), revelando bom desempenho mesmo com estrutura decisória reduzida.

A curva de acurácia por *fold* (Figura 3.37) confirma a estabilidade do modelo, com métricas próximas à média em todas as partições.

As variáveis mais influentes (Figura 3.38) foram RMS_z (70,68%) e RMS_x (27,60%). As demais variáveis apresentaram influência nula na decisão do modelo. Na Figura 3.39 é apresentado as curvas de treinamento individual por fold para o modelo de árvore de decisão no lado LE.




Figura 3.36 – Matriz de confusão global da Árvore de Decisão no lado LE.
Fonte: Elaboração própria.




Figura 3.37 - Curva de acurácia por *fold* para a Árvore de Decisão no lado LE.
Fonte: Elaboração própria.




Figura 3.38 - Importância relativa das 10 principais features para a Árvore de Decisão no lado LE.

Fonte: Elaboração própria.




Figura 3.39 - curva de aprendizado individual por fold arvore de decisão no lado LE.

Fonte: Elaboração própria.

No lado LD, a árvore de decisão apresentou desempenho equivalente ao modelo SVM, com acurácia de $95,73\% \pm 1,08$ desvio padrão. e escore F1 de $95,73\%$, conforme expresso na Figura 3.40. Esta simetria nos resultados pode indicar um ajuste adequado da estrutura do modelo às características específicas do lado esquerdo.

A curva de acurácia, representada na Figura 3.41, evidencia consistência entre os *folds*, com estabilidade superior àquela observada no SVM para o mesmo lado.

As variáveis com maior impacto na classificação (Figura 3.42) foram KFactor_y (76,54%), Kurtosis_z (15,26%), RMS_y (5,02%) e Kurtosis_y (2,61%). As demais variáveis não apresentaram contribuição significativa. A Figura 3.43 apresenta as curvas de aprendizado para cada fold para o lado LD para o modelo de árvore de decisão.




Figura 3.40 - Matriz de confusão global da Árvore de Decisão no lado LD.
 Fonte: Elaboração própria.




Figura 3.41 - Curva de acurácia por *fold* para a Árvore de Decisão no lado LD.
 Fonte: Elaboração própria.




Figura 3.42 - Importância relativa das 10 principais features para a Árvore de Decisão no lado LD.
 Fonte: Elaboração própria.




Figura 3.43 - curva de aprendizagem individual por fold para o modelo de decisão no lado LD.
Fonte: Elaboração própria.

3.3.4. Comparativo entre os Lados

A Tabela 4.1 apresenta um resumo comparativo das métricas médias de desempenho obtidas por cada modelo para os lados LDA e LOA. Ela evidencia as diferenças de acurácia entre os posicionamentos dos sensores e serve como base para a análise que segue.

Tabela 5 - Comparativo dos resultados dos modelos LE e LD.

Modelo	Lado	Acurácia Média	Desvio padrão
SVM	LE	97,07	± 0,82
SVM	LD	95,74	± 1,90
Árvore de decisão	LE	96,4	± 1,86
Árvore de decisão	LD	95,73	± 1,08

Nessa análise comparativa é demonstrado que o lado LE apresentou desempenho um pouco superior em todos os cenários. Este resultado está diretamente relacionado à dinâmica do experimento, onde o desalinhamento da correia causou seu deslocamento predominante para o lado LD, aumentando o contato físico e a intensidade vibracional nessa região. Consequentemente, os sensores posicionados no lado LD captaram sinais mais ruidosos, com maior variabilidade e complexidade, o que impactou o desempenho dos modelos preditivos.

por outro ponto, a correia apresentou menor contato com os roletes laterais para o lado LE, gerando um padrão vibracional mais limpo e estável. Isso favoreceu a consistência das classificações, especialmente no modelo SVM, cujo desvio-padrão

de acurácia foi o menor entre todos os casos ($\pm 0,82$). Além disso, o modelo SVM aplicado ao lado LE concentrou suas decisões em variáveis relacionadas ao eixo z, mais estáveis estruturalmente, enquanto o LE exigiu dependência de atributos do eixo y, como o KFactor_y, para alcançar desempenho semelhante.

Outro ponto que foi observado corresponde ao tensionamento da correia. Como os ensaios experimentais para a coleta de dados foram conduzidos em longos períodos, onde a ordem de realização foi primeiro os ensaios para a classe alinhado e depois para a classe desalinhado, ao final dos ensaios a correia apresentou folgas de tensionamento ao final dos ensaios, e não foi observado onde houve o começo dessa folga por conta do alto ruído advindo do funcionamento do circuito de manuseio.

4. Conclusão

4.1. Considerações finais

Com base nos resultados obtidos, pode-se concluir que o uso de técnicas de aprendizado de máquina combinadas com atributos estatísticos extraídos de sinais triaxiais é eficaz na detecção de desalinhamento em correias transportadoras. Os modelos SVM e de árvore de decisão apresentaram bom desempenho geral, com destaque para o SVM do lado LE, que obteve a maior acurácia média e a menor variabilidade entre as partições de validação.

O posicionamento do sensor demonstrou ser um fator decisivo no desempenho dos modelos. O lado LE, por ter menor contato direto com a correia deslocada, gerou sinais mais consistentes e de fácil interpretação pelos algoritmos. Por outro lado, o lado LD, mais afetado pelo desalinhamento físico, exigiu maior esforço computacional e apresentou maior variabilidade nas métricas avaliadas.

Considerando que, em cenários industriais reais, o lado para o qual a correia se moverá nem sempre é conhecido com antecedência, recomenda-se a instalação de sensores em ambos os lados da estrutura, se possível. Isso permitiria uma captura mais robusta dos efeitos de vibração causados por desalinhamento da correia para ambas as direções, aumentando a confiabilidade do diagnóstico automático.

Além da análise binária entre condições de alinhamento e desalinhamento, este estudo fornece uma base sólida para investigações futuras mais complexas, como a caracterização de níveis distintos de desalinhamento, o uso de sinais em domínio tempo-frequência (como wavelet), ou ainda a aplicação de arquiteturas profundas baseadas em redes neurais convolucionais ou recorrentes. A incorporação de técnicas mais avançadas de seleção de atributos, otimização de hiper parâmetros e coleta de dados com carga também se apresentam como caminhos promissores para ampliar ainda mais a aplicabilidade da abordagem aqui apresentada.

4.2. Trabalhos Futuros

A continuidade desta pesquisa pode se beneficiar da ampliação da base de dados, contemplando diferentes condições operacionais, como variações de carga, velocidades distintas e tipos de materiais transportados. Além disso, a coleta em

ambientes industriais reais é essencial para validar a robustez do modelo frente a ruídos externos e às complexidades típicas das plantas de grande porte. Essa etapa permitirá verificar se a metodologia proposta mantém sua eficácia em condições menos controladas do que as reproduzidas em bancada.

A aplicação de modelos mais avançados de aprendizado de máquina, em especial as técnicas de aprendizado profundo, como redes neurais convolucionais (CNN) e recorrentes (LSTM). Esses modelos possuem maior capacidade de extrair padrões complexos e temporais dos sinais, o que pode resultar em diagnósticos mais precisos. A comparação direta do desempenho desses métodos com os algoritmos clássicos, como SVM e Árvores de Decisão, permitirá avaliar em que medida o aumento da complexidade algorítmica se traduz em ganhos reais de desempenho.

Também se destaca a importância do desenvolvimento de sistemas de monitoramento em tempo real, utilizando dispositivos embarcados ou soluções baseadas em Internet das Coisas (IoT). Essa abordagem permitiria não apenas a detecção imediata de desalinhamentos, mas também a integração com estratégias de manutenção preditiva, favorecendo a tomada de decisão rápida e a redução de paradas inesperadas.

Outro aspecto identificado durante os ensaios foi a influência da folga na correia sobre os sinais de vibração. Esse fenômeno pode ser facilmente confundido com o desalinhamento em análises preliminares, o que reforça a necessidade de investigações dedicadas. A inclusão desse fator em bases de dados futuras permitirá diferenciar seus efeitos e, conseqüentemente, evitar diagnósticos equivocados, contribuindo para a maior confiabilidade do sistema.

Por fim, recomenda-se a generalização da metodologia para outras falhas que afetam os transportadores de correia. Além do desalinhamento causado pela alimentação, pode-se realizar o desalinhamento causado pela torção do tambor de acionamento, é pertinente incluir no escopo de diagnóstico defeitos como desgaste de roletes, fadiga da correia e falhas estruturais na máquina. Essa ampliação permitirá a construção de um sistema mais abrangente de monitoramento, capaz de atender às demandas reais da indústria e de consolidar a aplicação da inteligência artificial como ferramenta de apoio à manutenção preditiva.

REFERÊNCIAS

BAHRUN, Sabri *et al.* Optimization production capacity by improving transfer chute to control material flow and prevent belt conveyor off centerline in mining plant. **International Conference on Science and Technology (ICST)**, p. 167-177, Mai. 2021. Disponível em:

https://www.researchgate.net/publication/351330352_Optimization_production_capacity_by_improving_transfer_chute_to_control_material_flow_and_prevent_belt_conveyor_off_centerline_in_mining_plant. Acesso em: 7 set. 2025.

BALIEIRO, Ricardo Luís. **Desenvolvimento de abordagem baseada em técnicas de visão computacional e de aprendizado de máquinas para monitoramento e controle de falhas em correias transportadoras**. 2019. Tese (Doutorado em Sistemas Dinâmicos) - Escola de Engenharia de São Carlos, University of São Paulo, São Carlos, 2019. Disponível em: 10.11606/T.18.2019.tde-02102019-142926. Acesso em: 7 jul. 2025.

BASU, Saprati *et al.* Design modification of iron ore bearing transfer chute using discrete element method. **Engineering Computations**, v. 38, n. 9, p. 3590-3607, 5 abr. 2025. DOI: <https://doi.org/10.1108/EC-08-2020-0435>. Acesso em: 7 set. 2025.

BENGIO, Yoshua. Learning deep architectures for AI. **Now Foundations and Trends**, v. 2, n. 1, p. 1-127, 2009. ISBN 9781601982957. DOI: <https://doi.org/10.1561/22000000006>. Acesso em: 7 set. 2025.

BEZERRA, Roberto de Araujo. **Detecção de falhas em rolamentos por análise de vibração**. 2004. 150p. Tese (Doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, SP. Disponível em: 20.500.12733/1599538. Acesso em: 2 set. 2025.

BORTNOWSKI, P., KRÓL, R. & OZDOBA, M. Modelling of transverse vibration of conveyor belt in aspect of the trough angle. **Sci Rep** 13, nov. 2023. DOI: <https://doi.org/10.1038/s41598-023-46534-w>. Acesso em: 7 set. 2025.

BORTNOWSKI, Piotr *et al.* Types and causes of damage to the conveyor belt – Review, classification and mutual relations. **Engineering Failure Analysis**, v. 140, p. 106520, 2022. ISSN 1350-6307. DOI: <https://doi.org/10.1016/j.engfailanal.2022.106520>. Acesso em: 7 set. 2025.

BOWER, A. F.; QI, Y.; BAZILEVS, Y. Vibrations. In: BROWN UNIVERSITY. EN4: Dynamics and Vibrations. Notas de curso, Brown University. Disponível em: <https://www.brown.edu/Departments/Engineering/Courses/En4/Notes/Vibrations/Vibrations>. Acesso em: 7 set. 2025.

BRUTON, S. L.; KUTZ, J. Nathan. Data-driven science and engineering: machine learning. **Dynamical Systems, and Control**, p. 18, 2019.

CARVALHO, Regivaldo *et al.* A UAV-based framework for semi-automated thermographic inspection of belt conveyors in the mining industry. **Sensors**, v. 20, n. 8, p. 2243, 2020. DOI: <https://doi.org/10.3390/s20082243>. Acesso em: 7 set. 2025.

CHAMORRO, Jose *et al.* Health monitoring of a conveyor belt system using machine vision and real-time sensor data. **CIRP Journal of Manufacturing Science and Technology**, v. 38, p. 38-50, 2022. ISSN 1755-5817. DOI: <https://doi.org/10.1016/j.cirpj.2022.03.013>. Acesso em: 7 set. 2025.

CHEN, Jian *et al.* A force–displacement relation based on the JKR theory for DEM simulations of adhesive particles. **Powder Technology**, v. 427, p. 118742, 2023. ISSN 0032-5910. DOI: <https://doi.org/10.1016/j.powtec.2023.118742>. Acesso em: 7 set. 2025.

COLE, Stephen. How to optimise transfer chutes design with the Discrete Element Method (DEM). **Altair Community**, 11 set. 2024. Disponível em: <https://community.altair.com/discussion/39538/how-to-optimise-transfer-chutes-design-with-the-discrete-element-method-dem/p1>. Acesso em: 19 ago. 2024.

COSTA, Thiago Barroso et al. **Proposta de metodologia para diagnóstico de falha em rolamentos de baixa velocidade**. 2024. Tese (Mestrado em Infraestrutura e Desenvolvimento Energético), Núcleo de Desenvolvimento Amazônico em Engenharia, Programa de Pós-graduação em Engenharia de Infraestrutura e Desenvolvimento Energético, Tucuruí, 2024.

DĄBEK, Przemysław *et al.* Application of the methods of monitoring and detecting the belt mistracking in laboratory conditions. **Applied Sciences**, v. 13, n. 4, p. 2111, 2023. DOI: <http://dx.doi.org/10.3390/app13042111>. Acesso em: 7 set. 2025.

DĄBEK, Przemysław; WRÓBLEWSKI, Adam; WODECKI, Jacek; BORTNOWSKI, Piotr; OZDOBA, Maksymilian; KRÓL, Robert; ZIMROZ, Radosław. Application of the Methods of Monitoring and Detecting the Belt Mistracking in Laboratory Conditions. **Applied Sciences**, v. 13, n. 4, art. 2111, 2023. DOI: 10.3390/app13042111. [MDPI](https://doi.org/10.3390/app13042111)

DE VILLE, Barry. Decision trees. **Wiley Interdisciplinary Reviews: Computational Statistics**, v. 5, n. 6, p. 448-455, mai. 2013. DOI: <https://doi.org/10.1002/wics.1278>. Acesso em: 7 set. 2025.

DIALLO, M. S. *et al.* Identifying Benchmarks for Failure Prediction in Industry 4.0. **Informatics**, v. 8, n. 4, art. 68, 2021. DOI: 10.3390/informatics8040068. Disponível em: <https://www.mdpi.com/2227-9709/8/4/68>. Acesso em: 8 set. 2025.

DOROSZUK, Błażej; KRÓL, Robert. Analysis of conveyor belt wear caused by material acceleration in transfer stations. **Mining Science**, v. 26, p. 189–201, 2019. DOI: 10.5277/msc192615. Disponível em: https://www.researchgate.net/publication/341004713_ANALYSIS_OF_CONVEYOR_BELT_WEAR_CAUSED_BY_MATERIAL_ACCELERATION_IN_TRANSFER_STATIONS. Acesso em: 8 set. 2025.

DU, Hao *et al.* An optical non-contact flow-meter of conveyor belt based on FPGA. **Measurement Science and Technology**, v. 34, n. 10, p. 105007, jul. 2023. DOI: <http://dx.doi.org/10.1088/1361-6501/ace277>. Acesso em: 7 set. 2025.

ERSÖZ, O. Ö. *et al.* A Systematic Literature Review of the Predictive Maintenance from Transportation Systems Aspect. **Sustainability**, v. 14, n. 21, art. 14536, 2022. DOI: 10.3390/su142114536. Disponível em: <https://www.mdpi.com/2071-1050/14/21/14536>. Acesso em: 8 set. 2025.

FERREIRA, Thelri Aguiar. **Estratégia de manutenção para chutes de transferência de uma usina de classificação de bauxita**. Orientador: Maciel da Costa Furtado. 2020. Trabalho de Curso (Bacharelado em Engenharia Mecânica) – Faculdade de Engenharia Mecânica, Campus Universitário de Tucuruí, Universidade Federal do Pará, Tucuruí, 2020. Disponível em: <https://bdm.ufpa.br:8443/jspui/handle/prefix/3898>. Acesso em: 7 set. 2025.

GELAIS, Marcelo Alves. **Cálculo dinâmico de transportadores de correia: uma análise comparativa ao cálculo estático corroborada por medições de campo**. 2016. 150 f. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal de Minas Gerais, Escola de Engenharia, Belo Horizonte, 2016.

GÉRON, Aurélien. **Hands-On Machine Learning With Scikit-Learn, Keras, And Tensorflow: Concepts, Tools, And Techniques To Build Intelligent Systems**. 2. Ed. London, United Kingdom: O'Reilly Media, 2019. Disponível em: http://14.139.161.31/OddSem-0822-1122/Hands-On_Machine_Learning_with_Scikit-Learn-Keras-and-TensorFlow-2nd-Edition-Aurelien-Geron.pdf. Acesso em: 7 set. 2025.

GIBBS, A. **Eliminating Conveyor Belt Misalignment / Side-Travel Problems**. ASGCO Manufacturing, Inc., USA, 2019. Disponível em: <https://www.bulk-online.com/de/node/69817>. Acesso em: 7 set. 2025.

HARTMANN, Ricardo Augusto Terui. **Otimização híbrida por estruturas celulares de rolos de correias transportadoras**. 2023. Dissertação (Mestrado), Universidade Tecnológica Federal do Paraná, 2023.

HAYKIN, Simon. Neural networks and learning machines. 2. Ed. **Pearson Education**, Inc., Upper Saddle River, New Jersey, 2009. Disponível em: <https://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>. Acesso em: 7 set. 2025.

IZBICKI, Rafael; DOS SANTOS, Tiago Mendonça. **Aprendizado de máquina: uma abordagem estatística**. 1. Ed. São Carlos, São Paulo: **Rafael Izbicki**, 2020. ISBN 978-65-00-02410-4.

JACOBS-CAPDEVILLE, Patricio; KUANG, Shibo; YU, Aibing. Unrevealing energy dissipation during iron ore transfer through chutes with different designs. **Powder Technology**, v. 435, p. 119446, 2024. ISSN 0032-5910. DOI: <https://doi.org/10.1016/j.powtec.2024.119446>. Acesso em: 7 set. 2025.

JANIKOW, Cezary Z. Fuzzy decision trees: issues and methods. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 28, n. 1, p. 1-14, 1998. DOI: <https://doi.org/10.1109/3477.658573>. Acesso em: 7 set. 2025.

JIAO, Jinyang *et al.* A comprehensive review on convolutional neural network in machine fault diagnosis. **Neurocomputing**, v. 417, p. 36-63, 2020. ISSN 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2020.07.088>. Acesso em: 7 set. 2025.

JIGO, Bahzad; ABDULAZEEZ, Adnan. Classification based on decision tree algorithm for machine learning. **Journal of Applied Science and Technology Trends**, v. 2, n. 01, p. 20-28, 2021. DOI: <https://doi.org/10.38094/jastt20165>. Acesso em: 7 set. 2025.

KOBAYASHI, Yuko; TOYA, Kiminori. Effect of belt transport speed and other factors on belt mistracking. **Microsystem technologies**, v. 13, p. 1325-1330, 2007. DOI: <https://doi.org/10.1007/s00542-006-0357-y>. Acesso em: 7 set. 2025.

KULINOWSKI, Piotr; KASZA, Piotr; ZARZYCKI, Jacek. Identification of the operating parameters of the friction drum drive in industrial conditions. **Eksploracja i Niezawodność**, v. 23, n. 1, p. 94-102, 2021. DOI: <http://dx.doi.org/10.17531/ein.2021.1.10>. Disponível em: https://www.researchgate.net/publication/348197742_Identification_of_the_operating_parameters_of_the_friction_drum_drive_in_industrial_conditions. Acesso em: 7 set. 2025.

LIU, Xiangwei *et al.* Acoustic signal based fault detection on belt conveyor idlers using machine learning. **Advanced Powder Technology**, v. 31, n. 7, p. 2689-2698, 2020. ISSN 0921-8831. DOI: <https://doi.org/10.1016/j.appt.2020.04.034>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0921883120301898>. Acesso em: 7 set. 2025.

LIU, Yi *et al.* Research On The Fault Analysis Method Of Belt Conveyor Idlers Based On Sound And Thermal Infrared Image Features. **Measurement**, v. 186, p. 110177, 2021. ISSN 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2021.110177>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263224121010915>. Acesso em: 7 set. 2025.

MAHESH, Batta *et al.* Machine Learning Algorithms - A Review. **International Journal of Science and Research (IJSR)**, v. 9, n. 1, p. 381-386, 2020. DOI: <http://dx.doi.org/10.21275/ART20203995>. Disponível em: https://www.researchgate.net/publication/344717762_Machine_Learning_Algorithms_-_A_Review. Acesso em: 7 set. 2025.

MASCARENHAS, Fernando Pereira; MESQUITA, Alexandre Luiz Amarante; MESQUITA, André Luiz Amarante. Simulation of transfer chute operation using the discrete element method. **Federal University of Pará, Faculty of Mechanical Engineering, Augusto Corrêa St**, v. 1, p. 66075-110, 2013.

MAZURKIEWICZ, Dariusz. Maintenance of belt conveyors using an expert system based on fuzzy logic. **Archives of Civil and Mechanical Engineering**, v. 15, n. 2, p. 412-418, 2015. ISSN 1644-9665. DOI: <https://doi.org/10.1016/j.acme.2014.12.009>.

Disponível

em: <https://www.sciencedirect.com/science/article/pii/S1644966514001654>. Acesso em: 7 set. 2025.

MOURA, Lis Silva de. **Avaliação comparativa de bases magnéticas para fixação de acelerômetros na análise de vibração industrial**. Orientador: Walter dos Santos Sousa; Coorientador: Alexandre Luiz Amarante Mesquita. 2024. 77 f. Trabalho de Curso (Bacharelado em Engenharia Mecânica) – Faculdade de Engenharia Mecânica, Campus Universitário de Tucuruí, Universidade Federal do Pará, Tucuruí, 2024. Disponível em: <https://bdm.ufpa.br/handle/prefix/6909>. Acesso em: 7 set. 2025.

MURALIDHARAN, V., RAVIKUMAR, S., KANGASABAPATHY, H. Condition monitoring of Self aligning carrying idler (SAI) in belt-conveyor system using statistical features and decision tree algorithm. **Measurement**, v. 58, p. 274-279, 2014. ISSN 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2014.08.047>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263224114003765>.

NASRI, N. PERTIWI, Y. WAHYUDI, D. Analisa Kerusakan Roller Idler Pada Bottom Ash Conveyor. **Jurnal Energy**, V.7, N.1, mai. 2017. ISSN 2088-4591. Disponível em: <http://repository.upm.ac.id/id/eprint/1271>. Acesso em 7 set. 2025.

NETTO, Guilherme G.; COELHO, Bruno N.; DELABRIDA, Saul E.; SINATORA, Amilton; AZPÚRUA, Hector; PESSIN, Gustavo; OLIVEIRA, Ricardo A. R.; BIANCHI, Andrea G. C. Early Defect Detection in Conveyor Belts using Machine Vision. In: *Proceedings of the 16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2021) – Volume 4: VISAPP*. [S.I.]: SCITEPRESS, 2021. p. 303–310. DOI: 10.5220/0010240803030310. Disponível em: <https://www.scitepress.org/Papers/2021/102408/102408.pdf>. Acesso em: 13 set. 2025

NUNES, P.; SANTOS, J.; ROCHA, E. Challenges in predictive maintenance—A review. **CIRP Journal of Manufacturing Science and Technology**, v. 40, p. 53-67, 2023. ISSN 1755-5817. DOI: <https://doi.org/10.1016/j.cirpj.2022.11.004>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1755581722001742>. Acesso em: 7 set. 2025.

OTTO, H.; KATTERFELD, A. Prediction and simulation of mistracking of conveyors belts. **International Conference on Conveying and Handling of Particulate Solids**. Mai. 2015. Disponível em: https://www.researchgate.net/publication/316853069_Prediction_and_Simulation_of_Mistracking_of_Conveyors_Belts. Acesso em: 7 set. 2025.

OTTO, Hendrik; KATTERFELD, Andre. Belt Mistracking—Simulation and Measurements of Belt Sideways Dynamics. **University of Magdeburg, Chair of Material Handling Universitätsplatz**, v. 2, p. 39104, 2019. Disponível em: https://www.researchgate.net/publication/337360025_Belt_Mistracking_-_Simulation_and_Measurements_of_Belt_Sideways_Dynamics. Acesso em: 7 set. 2025.

RAVIKUMAR, S., KANAGASABAPATHY, H., MURALIDHARAN, V. Fault diagnosis of self-aligning troughing rollers in belt conveyor system using k-star algorithm.

Measurement, v. 133, p. 341-349, 2019. ISSN 0263-2241. DOI:

<https://doi.org/10.1016/j.measurement.2018.10.001>. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0263224118309175>. Acesso em: 7 set. 2025.

RAVIKUMAR, S.; KANAGASABAPATHY, H.; MURALIDHARAN, V.. Multi-Component Fault Diagnosis of Self Aligning Troughing Roller (SATR) in Belt Conveyor System using Decision Tree – a Statistical Approach. **FME Transicions**, v. 48, p. 364-371, 2020. DOI: 10.5937/fme2002364R. Disponível

em:https://www.researchgate.net/publication/341135981_Multi-component_fault_diagnosis_of_Self_Aligning_Troughing_Roller_SATR_in_belt_conveyor_system_using_decision_tree_A_statistical_approach. Acesso em: 7 set. 2025.

REICKS, Allen V. Idler Misalignment on Belt Conveyors: If Your Belts are Misaligned, You are Likely Wasting Power and Money. **Rock Products**, 2016. Disponível em:

<https://rockproducts.com/2016/08/19/idler-misalignment-on-belt-conveyors/>. Acesso em: 7 set. 2025.

ROSSOW, Jeandré. **Análise DEM de uma rampa de transferência de transportador**. 2020. Tese (Mestrado em Engenharia Mecânica) – Faculdade de

Engenharia, Universidade de Stellenbosch, Stellenbosch, 2020. Disponível em:

https://www.academia.edu/97041508/DEM_analysis_of_a_conveyor_transfer_chute. Acesso em: 2 set. 2025.

RUMIN, P.; KOTOWICZ, J.; ZASTAWNA-RUMIN, A.; HOGG, D. *Utilization of Measurements, Machine Learning and Analytical Calculation for Preventing Belt Flip Over on Conveyor Belts*. **Measurement**, v. 218, p. 113157, jun. 2023. Disponível em:

<https://ssrn.com/abstract=4410408>. Acesso em: 8 set. 2025.

SILVA, Ronan Jackson. **Caracterização de sistema tribológico e seleção de ligas para revestimento de chutes de transferência de minério**. 2016. 91 f. Dissertação (Mestrado em Engenharia de Materiais) – Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2016.

SOARES, João Lucas Lobato. **Desenvolvimento de sistema de diagnóstico de falhas em roletes de transportadores de correia**. Orientador: Alexandre Luiz

Amarante Mesquita. 2024. 123 f. Dissertação (Mestrado em Engenharia de Infraestrutura e Desenvolvimento Energético) – Núcleo de Desenvolvimento Amazônico em Engenharia, Universidade Federal do Pará, Tucuruí, 2024.

Disponível em: <https://repositorio.ufpa.br/jspui/handle/2011/16511>. Acesso em: 02 jul. 2025.

SUN, Xiaoxia; WANG, Yongqi; MENG, Wenjun. Evaluation system of curved conveyor belt deviation state based on the ARIMA–LSTM combined prediction model. **Machines**, v. 10, n. 11, p. 1042, 2022. DOI:

<https://doi.org/10.3390/machines10111042>. Disponível em:

<https://www.mdpi.com/2075-1702/10/11/1042>. Acesso em: 7 set. 2025.

SWINDERMAN, *et al.* **Foundations™: The Practical Resource for Cleaner, Safer, More Productive Dust & Material Control**. 4. Ed. USA: Martin Engineering Company, 2009. Disponível em: <https://www.martin-eng.com/sites/default/files/Foundations/Book%20Downloads/f4-2012.pdf> . Acesso em: 2 jul. 2025.

VREEBURG, W. P. J. Redesign of a Tata Steel transfer chute with dust liberation problems. 2018. Tese (Mestrado em Engenharia Mecânica) - Delft University of Technology, 2018. Disponível em: <https://resolver.tudelft.nl/uuid:379dedce-2291-4f22-957b-b7619e242e63>. Acesso em: 7 set. 2025.

WANZELER, Hermeson Conceição. **Estudo de similaridade em um chute de pelotas**. Orientador: André Luiz Amarante Mesquita. 2023. 94 f. Trabalho de Curso (Bacharelado em Engenharia Mecânica) – Faculdade de Engenharia Mecânica, Campus Universitário de Tucuruí, Universidade Federal do Pará, Tucuruí, 2023. Disponível em: <https://bdm.ufpa.br/handle/prefix/5382>. Acesso em: 7 set. 2025.

XIE, Liyu; ZHONG, Wenqi; ZHANG, Hao; YU, Aibing; QIAN, Yujun; SITU, Yougong. *Wear process during granular flow transportation in conveyor transfer*. **Powder Technology**, v. 288, p. 65–75, 2016. DOI: 10.1016/j.powtec.2015.10.043. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0032591015301315>. Acesso em: 8 set. 2025.

YURCHENKO, Vadim. Belt Aligning Revisited. **E3S Web Conferences**, V.21, n. 11, jan. 2017. DOIS: <https://doi.org/10.1051/e3sconf/20172102021>. Disponível em: https://www.researchgate.net/publication/320984162_Belt_Aligning_Revisited. Acesso em: 7 set. 2025.

ZAMAN, Qamruz *et al.* Fundamentals of classification and regression trees. **Bio Technology**, v. 40, p. 5407-5414, 2011. Disponível em: https://www.academia.edu/72981523/Fundamentals_of_classification_and_regression_trees. Acesso em: 7 set. 2025.

ZHANG, Xiufen; WEI, Zhanchao. Design of Coal Conveying Belt Correction Device Based on FTA-QFD-TRIZ. **Journal of Failure Analysis and Prevention**, v. 23, n. 6, p. 2519-2532, 2023. DOI: <https://doi.org/10.1007/s11668-023-01789-3>. Disponível em: <https://link.springer.com/article/10.1007/s11668-023-01789-3>. Acesso em: 7 set. 2025.

ZHAO, Chuan *et al.* Analysis of wet soil granular flow down inclined chutes using discrete element method. **Water**, v. 11, n. 11, p. 2399, 2019. DOI: <https://doi.org/10.3390/w11112399>. Disponível em: <https://www.mdpi.com/2073-4441/11/11/2399>. Acesso em: 7 set. 2025.