

# Enhanced Engine Vibration by Computer Vision Methods for Predictive Maintenance

## Vibração Aumentada de Motor por Métodos de Visão Computacional para Manutenção Preditiva

Loureni Monteiro Coutinho<sup>1</sup>, Leonardo de Assis Silva<sup>1</sup>, Fabricio Bortolini de Sá<sup>2</sup>

**Resumo:** Predictive maintenance focuses on the continuous monitoring of the system, with the goal of identifying potential degradations in advance, and commonly uses vibration sensors. However, this method can become costly when dealing with very large networks. As an alternative, studies have emerged that use high-speed cameras to capture video footage of motion and analyze vibration through computer vision processing and motion magnification algorithms. In this context, this work proposes a vibration analysis system based on video, following three main approaches: spectrogram analysis, vibration magnification, and classification of the equipment's operational condition using PCA and Random Forest. For algorithm validation, numerical data was collected using a vibration sensor, and video recordings were made using a GoPRO camera. Experiments were conducted in stages, and the results showed that the algorithm was able to distinguish between the motor's operating condition classes and classified these states with an accuracy of at least 86%.

**Keywords:** computer vision — vibration analysis — motion amplification — predictive maintenance

**Resumo:** A manutenção preditiva foca no monitoramento contínuo do sistema, com o objetivo de identificar potenciais degradações antecipadamente, e comumente utiliza sensores de vibração. No entanto, esse método pode se tornar custoso ao lidar com malhas extensas. Como alternativa, surgiram estudos que utilizam câmeras de alta velocidade para capturar vídeos de movimento e analisar a vibração por visão computacional e algoritmos de ampliação de movimento. Nesse contexto, este trabalho propõe um sistema de análise de vibração baseado em vídeo, seguindo três abordagens principais: análise de espectrograma, ampliação de vibração e classificação da condição operacional do equipamento usando PCA e Random Forest. Para validação do algoritmo, foram obtidos dados com sensor de vibração e uma câmera GoPRO. Os experimentos foram conduzidos em etapas, e os resultados mostraram que o algoritmo foi capaz de distinguir entre as classes de condição operacional do motor, classificando esses estados com uma precisão de pelo menos 86%.

**Palavras-Chave:** visão computacional — análise de vibração — amplificação de movimento — manutenção preditiva

<sup>1</sup>Coordenadoria de Engenharia Elétrica, Instituto Federal do Espírito Santo (IFES), Brasil

<sup>2</sup>Coordenadoria de Engenharia Mecânica, Instituto Federal do Espírito Santo (IFES), Brasil

\*Corresponding author: lourenimonteiroc@gmail.com

DOI: <http://dx.doi.org/10.22456/2175-2745.150897> • Received: 13/10/2025 • Accepted: 27/10/2025

CC BY-NC-ND 4.0 - This work is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License.

## 1. Introdução

A manutenção preditiva é descrita pela NBR5462 [1] como uma manutenção focada no monitoramento contínuo do sistema, sendo baseada na aplicação de técnicas de análise de dados com o objetivo de identificar possíveis degradações antecipadamente para reduzir as manutenções preventiva e corretiva.

Dentre as diversas metodologias utilizadas pela manutenção preditiva, é possível citar: análise de vibrações; monitoramento de temperatura; análise de óleo; monitoramento de

ruídos; medição de corrente; etc. Dentre elas, este trabalho tem foco na análise de vibração.

A partir disso, entende-se que a vibração é encontrada em qualquer sistema que possua uma máquina em movimento, podendo indicar problemas mecânicos, que podem evoluir e causar falhas no processo. Dessa forma, a análise de vibração é usada nas indústrias com o intuito de monitorar a integridade dos equipamentos, identificar possíveis problemas e corrigi-los antes de acontecerem perdas significativas no sistema [2].

Dentre os equipamentos mais utilizados no setor industrial, destacam-se os motores. Nesse caso, há diferentes causas de

falhas que podem surgir no decorrer de seu uso. Essas falhas, sejam de natureza elétrica ou mecânica, causam vibrações em frequências diferentes à operação normal na carcaça dos motores [3]. Uma ferramenta utilizada na análise de vibração são sensores de vibração, que possuem a capacidade de diagnosticar possíveis defeitos a partir das componentes em frequência detectadas.

Entretanto, para monitorar equipamentos por meio de sensores de vibração, é necessário que esses sensores estejam em contato direto com a estrutura do equipamento. Devido à grande quantidade de motores empregados em um único processo industrial, é necessário instalar vários sensores ao longo de todo o sistema. Por esse motivo, alguns estudos têm sugerido alternativas para o monitoramento e diagnóstico de motores e outros equipamentos industriais sem o uso de sensores de vibração.

Neste contexto, alguns trabalhos, como [4], [5], [6] e [7], utilizam câmeras como uma alternativa. Com elas, é possível monitorar o processo como um todo e identificar possíveis falhas em diversos pontos do sistema ao mesmo tempo. Caso sejam problemas relacionados à vibração de equipamentos, podem-se utilizar técnicas de processamento digital de imagens e visão computacional para detectá-las ou até mesmo aumentar visualmente em vídeo as vibrações do sistema, possibilitando ao analista enxergar a movimentação dos equipamentos.

Destarte, este trabalho utiliza técnicas de visão computacional e processamento digital de sinais e imagens para desenvolver um sistema capaz de aumentar a vibração de um motor em vídeo, detectar a frequência de vibração do equipamento automaticamente e identificar a possibilidade de falha proveniente dele.

Dessa forma, para um melhor entendimento, este trabalho está estruturado como a seguir. A Seção 2 apresenta alguns trabalhos relacionados ao tema; a Seção 3 explica como foi feita cada etapa do sistema; na Seção 4 são descritos os experimentos feitos e os resultados obtidos; e a Seção 5 faz uma conclusão geral do trabalho.

## 2. Trabalhos Relacionados

Estudos recentes propõem alternativas aos sensores de vibração como a utilização de câmeras de alta velocidade. Essa metodologia possui vantagens como menor custo, fácil configuração e captura de informações de um cenário extenso [6]. Ou seja, uma única câmera pode monitorar diversos equipamentos.

Dessa forma, a partir das imagens adquiridas pela câmera, são utilizados algoritmos para a análise de vibração que se baseiam na detecção e na amplificação de movimento.

O trabalho de Liu et al. [8] apresenta a criação do método *Motion Magnification*, que foi evoluindo por meio dos trabalhos de Wu et al. [9], Wadhwa et al. [10] e Wadhwa et al. [11]. Esses métodos de análise de movimento foram utilizados como uma forma não invasiva de analisar a integridade de equipamentos e estruturas por diversos pesquisadores.

O artigo de Smieja et al. [4] destaca a evolução de métodos de análise de vibração baseados em sensores convencionais em comparação com abordagens visuais, que permitem medições não invasivas e de múltiplos pontos simultaneamente. O trabalho revisa algoritmos de processamento de imagens, como fluxo óptico e técnicas baseadas em fase, discutindo sua complexidade computacional, qualidade visual e aplicações em ambientes industriais. Os autores concluem que os métodos visuais são eficazes na detecção de falhas em máquinas e estruturas, oferecendo vantagens significativas em cenários onde sensores convencionais apresentam limitações.

Na revisão de Luo et al. [5], o foco é o uso da amplificação de movimento em medições de vibração de estruturas civis. O artigo analisa algoritmos, além de métodos recentes baseados em aprendizado de máquina. São discutidos os principais desafios, como interferências de grandes movimentos, ruídos em vídeos e a necessidade de ajustes manuais de parâmetros.

O trabalho de Jasim e Alsalaet [6] propõe uma metodologia de medição de vibração baseada em câmeras de alta velocidade para detectar problemas em máquinas e estruturas. Os autores validaram a técnica em experimentos utilizando simuladores de falhas e um aparato de eixo em rotação, demonstrando correlação consistente com medições obtidas por acelerômetros e vibrometria a laser. O estudo destaca ainda a eficácia de métodos baseados em fluxo óptico e fase para extração de vibrações, concluindo que o uso de câmeras pode ser uma ferramenta robusta para manutenção preditiva e monitoramento estrutural.

O trabalho de Zhao et al. [7] apresenta uma proposta que consiste em calcular automaticamente o comprimento de onda espacial de corte a partir da componente de brilho da imagem no espaço HSV, eliminando a necessidade de ajustes manuais presentes no método original. A técnica foi validada em vídeos de teste e em um dispositivo rotor-mancal, analisando condições como desbalanceamento, desalinhamento, afrouxamento de parafusos e falhas combinadas. Os resultados mostraram que a abordagem melhora a eficiência, aumenta a clareza na visualização de deslocamentos e oferece uma alternativa promissora para o diagnóstico não invasivo de falhas em máquinas rotativas.

A partir disso, verifica-se que câmeras de alta velocidade em conjunto com métodos de amplificação de movimento podem ser utilizadas como alternativa não invasiva à ferramentas de análise de integridade de equipamentos, tais como o sensor de vibração.

Dessa forma, este trabalho propõe o desenvolvimento de um sistema para identificar em vídeos a vibração de equipamentos industriais (motores) utilizando pirâmide de Riesz [11] para aumentar a amplitude da vibração na imagem, a fim de facilitar a identificação de problemas de vibração por um analista.

## 3. Metodologia

Nesta seção, são descritos os métodos utilizados para o desenvolvimento do sistema de aumento de vibração e de análise

dos vídeos. Isso inclui a captura dos dados em vídeo e do sensor de vibração, um algoritmo de análise de espectrograma dos vídeos, o algoritmo de aumento de vibração com pirâmide de Riesz e o algoritmo de análise com PCA.

### 3.1 Obtenção dos Dados

Os dados foram obtidos em uma área externa no Ifes - Campus Aracruz. Foi montada uma bancada de teste com um motor acoplado a um disco, sustentado por dois mancais. Foram utilizados um inversor de frequência para alimentar o motor com as frequências elétricas de 40Hz e 60Hz, um sensor de vibração posicionado no mancal mais próximo ao disco, e uma câmera de alta velocidade, de acordo com a Figura 1.




**Figura 1.** Bancada do laboratório de manutenção do Ifes - Campus Aracruz montada em área externa.

Foi utilizado o sensor de vibração VibXpert® II para obter os valores de frequência de vibração do motor (mecânica) e suas respectivas amplitudes. Já o conjunto de dados em vídeo foi obtido a partir de uma câmera GoPro Hero 6 Black, com capacidade de captura de vídeos em até 240 fps com 1080p.

O motor foi energizado em três diferentes modos de operação: normal, com desbalanceamento, e com falta de uma fase. Para simular o desbalanceamento, foram utilizados três conjuntos de parafuso e porca, que pesam ao todo 60g, dispostos nos furos da extremidade do disco acoplado ao motor, de acordo com a Figura 2. Os parafusos foram colocados nos furos destacados em vermelho, o furo mais externo tem 60mm de raio e os furos mais internos têm 45mm de raio.




**Figura 2.** Disco fixado ao eixo do motor.

### 3.2 Algoritmos Implementados

Foram utilizados três algoritmos para a análise dos vídeos obtidos: análise de espectrograma, aumento de movimento, e análise com PCA. O primeiro algoritmo tem o objetivo de analisar o espectro de frequência de uma região de interesse (ROI) do *frame* para identificar o valor da frequência principal de vibração do motor.

O segundo algoritmo foi utilizado para aumentar a vibração do motor com o método da Pirâmide de Riesz, a partir da frequência detectada pelo primeiro algoritmo. Ou seja, o primeiro algoritmo estima automaticamente a frequência que deve ser utilizada pelo segundo algoritmo para destacar o movimento do motor (vibração de interesse). Já o terceiro algoritmo classifica o movimento, estimando se o motor está em funcionamento normal ou apresentando alguma falha (desbalanceado ou sem uma fase). Todos foram implementados em *Python*.

#### 3.2.1 Análise de Espectrograma

A análise de espectrograma teve como objetivo identificar as frequências dominantes da vibração do motor. Para delimitar a região de interesse (ROI), foi treinado um modelo YOLOv11-nano [12] com 1400 imagens rotuladas no *Label Studio*. O YOLO detectava o motor apenas no primeiro *frame*, sendo essa ROI replicada nos demais para reduzir o custo computacional.

Os *frames* foram convertidos em escala de cinza e suas intensidades somadas dentro da ROI, formando um sinal unidimensional. Para remover variações lentas de iluminação e captar apenas as vibrações de maior frequência, aplicou-se um filtro passa-alta de *Butterworth* (5 Hz). O espectrograma foi calculado com a função *spectrogram* da biblioteca *SciPy*, utilizando janela de 256 amostras e frequências até 100 Hz. A frequência dominante foi obtida pela soma das intensidades ao longo do tempo em cada faixa e interpretada como frequência principal do sistema.

#### 3.2.2 Aumento de Vibração

O aumento de vibração foi implementado com a Pirâmide de Riesz [11]. A ROI foi convertida em escala de cinza e, no primeiro *frame*, aplicaram-se a Pirâmide Laplaciana e as transformadas de Riesz. Nos demais, calculou-se a diferença de fase quaterniônica entre *frames*. O sinal foi filtrado com passa-banda *Butterworth* centrado na frequência dominante ( $\pm 3$  Hz a partir da frequência detectada).

A magnificação foi obtida ao aplicar um fator de amplificação às fases filtradas, e o vídeo final foi reconstruído combinando os *frames* originais e amplificados, permitindo visualizar a intensificação da vibração.

A Figura 3 ilustra esse processo. Em a), uma linha vermelha na região de interesse de um *frame* do vídeo original apresenta os *pixels* que exemplificarão a diferença no tempo do vídeo sem e com aumento de vibração. Em b), é possível ver que, ao longo do tempo (diferença vertical), os *pixels* dessa linha não apresentaram muita variação de movimento. Já em c), é notável uma diferença em que, no vídeo com

vibração amplificada, esses mesmos *pixels* apresentam uma movimentação maior.




**Figura 3.** Amplificação do movimento do motor. Em a), uma linha vermelha na região de interesse de um *frame* do vídeo original. Em b) ao longo do tempo os *pixels* dessa linha apresentaram pouca variação de movimento. Já em c), esses mesmos *pixels* apresentam uma movimentação maior.

### 3.2.3 Caracterização de Falha no Equipamento - PCA

A caracterização das falhas utilizou PCA para separar as condições de operação do motor (normal, desbalanceado e falta de fase). Os vídeos foram divididos em trechos de 2 segundos e, de cada trecho, foram extraídas séries temporais referentes à variação de intensidade de três linhas no ROI. Após FFT, foram calculadas energia total, frequência dominante, média e desvio padrão espectral, concatenadas em um vetor de características. Os dados foram normalizados com *z-score*, os rótulos codificados e, em seguida, aplicou-se PCA reduzindo para três dimensões principais. Essa redução permitiu observar o agrupamento visual das classes. Por fim, os dados foram divididos em treino (70%) e teste (30%) e classificados com *Random Forest* (random state = 42), avaliando precisão, *recall* e *F1 score*.

## 4. Resultados e Discussões

Esta seção apresenta os experimentos realizados e seus resultados, a fim de validar os algoritmos desenvolvidos neste trabalho.

Para a execução dos algoritmos, foram registrados doze vídeos, em que seis são do conjunto motor-disco e seis possuem imagem focada no disco. Neste trabalho, serão apresentados apenas os resultados dos vídeos do conjunto motor-disco. Os dados do sensor VibXpert® II foram utilizados como base comparativa (*ground truth*) para o conjunto em vídeo, eles estão dispostos nas Tabelas 1 e 2. Todos os resultados obtidos desta etapa encontram-se no link: <https://shre.ink/resultados-tcc-2025>.

Os algoritmos foram implementados em um computador disponível no Laboratório de Soluções e Estudos Avançados do Ifes - Campus Guarapari, cujas características são:

- Processador: Intel(R) Core(TM) i7-6850K CPU @ 3.60GHz;

- GPU: 2x NVIDIA GeForce RTX 2080;
- Armazenamento: 500 GB;
- Memória RAM: 31 GB.

**Tabela 1.** Dados do sensor de vibração com a alimentação do motor a 40Hz.

| Estado do Motor | Frequência (Hz) | Amplitude (mm/s) |
|-----------------|-----------------|------------------|
| Normal          | 20              | 1,002            |
|                 | 40              | 0,465            |
|                 | 58              | 0,439            |
|                 | 59,5            | 0,393            |
|                 | 38,5            | 0,200            |
|                 | 99,5            | 0,144            |
| Desbalanceado   | 20              | 3,242            |
|                 | 40              | 0,609            |
|                 | 59              | 0,564            |
|                 | 100             | 0,224            |
|                 | 60,5            | 0,194            |
|                 | 139,5           | 0,176            |
| Falta de Fase   | 20              | 0,612            |
|                 | 161,5           | 0,453            |
|                 | 120             | 0,433            |
|                 | 39              | 0,418            |
|                 | 59              | 0,416            |
|                 | 122             | 0,405            |

### 4.1 Análise de Espectrograma

O primeiro experimento realizado foi a análise de espectrograma. Os espectrogramas apresentados são gráficos de frequência (Hz) x tempo (s), com uma escala de cores representando a amplitude em dB dos dados. São apresentados, também, os correspondentes gráficos de FFT, para melhor visualização dos picos de frequência.

Anterior à análise do espectrograma, é utilizado o YOLO (no mesmo algoritmo) para detectar a região de interesse (motor) nos vídeos.

#### 4.1.1 Vídeos com Alimentação de 40Hz

As Figuras 4, 5 e 6 mostram, em a), o espectrograma e, em b), o gráfico de FFT obtidos a partir dos vídeos do motor funcionando em estado normal de operação, desbalanceado e com falta de fase, respectivamente, alimentado em 40Hz. No espectrograma das Figuras 4 e 6, é possível ver que o valor de amplitude se destaca mais na faixa de 20Hz, enquanto na FFT esse mesmo valor apresenta o maior pico. Esse valor pode ser comparado com a Tabela 1, que mostra o *ground truth*. Dessa forma, comprova-se que o algoritmo conseguiu detectar de forma correta o valor da frequência principal da vibração do motor nesses vídeos.

Já na Figura 5, é possível ver que o maior valor de amplitude se encontra em 40Hz e, em seguida, em 20Hz. Ao comparar esse valor com os dados da Tabela 1, constata-se

**Tabela 2.** Dados do sensor de vibração com a alimentação do motor a 60Hz.

| Estado do Motor | Frequência (Hz) | Amplitude (mm/s) |
|-----------------|-----------------|------------------|
| Normal          | 30              | 1,077            |
|                 | 58              | 0,902            |
|                 | 29              | 0,738            |
|                 | 89,5            | 0,547            |
|                 | 60              | 0,456            |
|                 | 118,5           | 0,401            |
| Desbalanceado   | 30              | 15,617           |
|                 | 60              | 2,540            |
|                 | 119,5           | 0,488            |
|                 | 88,5            | 0,329            |
|                 | 121,5           | 0,321            |
|                 | 241,5           | 0,264            |
| Falta de Fase   | 30              | 0,940            |
|                 | 58              | 0,926            |
|                 | 89,5            | 0,631            |
|                 | 29              | 0,613            |
|                 | 60              | 0,535            |
|                 | 118,5           | 0,398            |

que o algoritmo não conseguiu detectar corretamente o valor da frequência principal, que de acordo com os dados do sensor é de 20Hz. Isso pode ter acontecido por falha na integridade dos dados coletados em vídeo, como interferência de ruídos e movimentação indevida da câmera, fazendo com que surgissem mais componentes a 40Hz.




**Figura 4.** Gráficos de espectrograma e FFT do motor em condição normal de operação com alimentação de 40Hz.

#### 4.1.2 Vídeos com Alimentação de 60Hz

As Figuras 7, 8 e 9 mostram, em a), o espectrograma e, em b), o gráfico de FFT obtidos a partir dos vídeos do motor funcionando em estado normal de operação, desbalanceado e com falta de fase, respectivamente, alimentado em 60Hz. No espectrograma de cada figura, é possível ver que o valor de amplitude se destaca mais na faixa de 30Hz, enquanto na FFT esse mesmo valor apresenta o maior pico. Esse valor pode ser comparado com os dados da Tabela 2, que mostra o *ground truth*. Dessa forma, comprova-se que o algoritmo conseguiu detectar de forma correta o valor da frequência principal da vibração do motor nesses vídeos.

Dessa forma, todos os gráficos obtidos a partir dos vídeos do motor com alimentação de 60Hz conseguiram identificar




**Figura 5.** Gráficos de espectrograma e FFT do motor desbalanceado com alimentação de 40Hz.




**Figura 6.** Gráficos de espectrograma e FFT do motor com falta de fase com alimentação de 40Hz.




**Figura 7.** Gráficos de espectrograma e FFT do motor em condição normal de operação com alimentação de 60Hz.




**Figura 8.** Gráficos de espectrograma e FFT do motor desbalanceado com alimentação de 60Hz.




**Figura 9.** Gráficos de espectrograma e FFT do motor com falta de fase com alimentação de 60Hz.

a frequência dominante dos vídeos corretamente, de acordo com os dados obtidos pelo sensor de vibração.

Além disso, observa-se que o comportamento dos gráficos de todos os vídeos com alimentação de 60Hz seguem o padrão: o motor em estado normal tem amplitude maior do que o motor com falta de fase, e menor do que o motor

desbalanceado. Sendo esse padrão visto também nos dados obtidos pelo sensor de vibração registrados na Tabela 2.

## 4.2 Aumento de Vibração em Vídeo

O próximo experimento realizado foi com o algoritmo de aumento de vibração do motor com pirâmide de Riesz, a partir da frequência principal estimada pelo primeiro algoritmo. Foi utilizado um valor de  $\alpha = 15$  [11].

### 4.2.1 Vídeos com Alimentação de 40Hz

A Figura 10 apresenta, em a), um *frame* do vídeo do motor em estado normal de operação alimentado em 40Hz. Nele, está marcada uma linha destacando *pixels* monitorados para extrair uma imagem temporal da vibração. O objetivo é exemplificar e apresentar o resultado do algoritmo utilizado neste trabalho. Em b), é mostrada uma imagem temporal da área demarcada em a) ao longo de 150 *frames* do vídeo original e, em c), é mostrada essa mesma área com movimento amplificado.




**Figura 10.** Vibração aumentada do vídeo com motor operando em estado normal a 40Hz. Em a), está marcada uma linha destacando *pixels* monitorados para extrair uma imagem temporal da vibração. Em b), uma imagem temporal da área demarcada sem amplificação e, em c), é mostrada essa mesma área com movimento amplificado.

Na Figura 10, do motor com alimentação de 40Hz, é possível observar, comparando b) e c), um aumento visível na curvatura da linha ao longo do tempo.

### 4.2.2 Vídeos com Alimentação de 60Hz

A Figura 3 apresenta, em a), um *frame* dos vídeos do motor com falta de uma fase, alimentado em 60Hz. Nele está uma linha marcada que foi utilizada para extrair uma imagem temporal da vibração. Em b), é mostrada uma imagem temporal da área demarcada em a) ao longo de 150 *frames* do vídeo original e, em c), é mostrada essa mesma área com movimento amplificado.

Na Figura 3, do motor com alimentação de 60Hz, também é possível observar, comparando b) e c), um aumento visível na curvatura da linha ao longo do tempo.

## 4.3 Classificação das Condições do Motor

No último experimento, foi utilizado um algoritmo combinado de análise de PCA e *Random Forest* para tentar classificar os modos de operação do motor nos vídeos.

A fim de tentar diferenciar as características das três classes de operação do motor, foi utilizado PCA de três dimensões, considerando quatro características que representam os dados em vídeos, como descrito na Subseção 3.2.3. No entanto, a terceira componente apresentou porcentagem de variância muito baixa em relação às outras no conjunto de vídeos do motor alimentado em 60Hz, como mostrado nas Tabelas 3 e 4, por isso, ela foi utilizada apenas no conjunto de vídeos do motor alimentado a 40Hz (Tabela 3).

Após a análise de PCA, foi utilizado um classificador *Random Forest* para classificar os trechos de cada vídeo. Para isso, foi feito um treinamento com 70% dos dados totais, enquanto 30% foram utilizados para validação. A partir disso, foram plotados gráficos 2D e 3D, em que são destacados os dados reais (caracterizados por formatos diferentes, em que o círculo é a classe "desbalanceado", o quadrado é "falta de fase" e o triângulo é "normal"), e os dados preditos (caracterizados por cores diferentes, em que vermelho é "desbalanceado", verde é "falta de fase" e azul é "normal") dos vídeos.

**Tabela 3.** Valores de variância de cada componente PCA do conjunto de vídeos do motor alimentado a 40Hz.

| Componente | Variância (%) |
|------------|---------------|
| 1          | 41            |
| 2          | 32,4          |
| 3          | 20,4          |

**Tabela 4.** Valores de variância de cada componente PCA do conjunto de vídeos do motor alimentado a 60Hz.

| Componente | Variância (%) |
|------------|---------------|
| 1          | 81,2          |
| 2          | 11            |
| 3          | 4,2           |

### 4.3.1 Vídeos com Alimentação de 40Hz

A Figura 11 mostra o gráfico obtido por meio da análise de PCA dos vídeos do motor funcionando em condição normal, desbalanceado e com falta de fase, alimentado em 40Hz. Considerando três componentes, o PCA conseguiu alcançar um valor de 93,8% de variância total. Como parte desses dados foi utilizado para o treinamento do modelo e a outra parte para a validação, a Tabela 5 mostra os valores de métricas obtidos para o modelo treinado com esse conjunto de dados.

A partir da Tabela 5 e da Figura 11, nota-se que neste caso o algoritmo conseguiu diferenciar todos os dados de validação. Dessa forma, todas as métricas analisadas obtiveram resultados de 100%, isso é, para cada trecho predito, o modelo conseguiu identificar a sua classe corretamente.

### 4.3.2 Vídeos com Alimentação de 60Hz

A Figura 12 mostra o gráfico obtido por meio da análise de PCA dos vídeos do motor funcionando em condição normal, desbalanceado e com falta de fase, alimentado em 60Hz. Considerando duas componentes, o PCA conseguiu alcançar um




Figura 11. Resultado da análise de PCA do motor a 40Hz.

**Tabela 5.** Resultados obtidos do treinamento do modelo com os vídeos do motor a 40Hz.

| Classe        | Precisão | Recall | F1 Score |
|---------------|----------|--------|----------|
| Normal        | 1        | 1      | 1        |
| Desbalanceado | 1        | 1      | 1        |
| Falta de fase | 1        | 1      | 1        |

valor de 92,2% de variância total. Como parte desses dados foi utilizado para o treinamento do modelo e a outra parte para a validação, a Tabela 6 mostra os valores de métricas obtidos para o modelo treinado com esse conjunto de dados.

A partir da Tabela 6 e da Figura 12, nota-se que neste caso o algoritmo conseguiu diferenciar a maior parte dos dados de validação, confundindo as classes "normal" e "falta de fase". Dessa forma, todas as métricas analisadas obtiveram resultados de 100% apenas em relação à classe "desbalanceado". No gráfico, é possível ver que um trecho do vídeo "normal" foi classificado como "falta de fase".

**Tabela 6.** Resultados obtidos do treinamento do modelo com os vídeos do motor a 60Hz.

| Classe        | Precisão | Recall | F1 Score |
|---------------|----------|--------|----------|
| Normal        | 1        | 0,75   | 0,86     |
| Desbalanceado | 1        | 1      | 1        |
| Falta de fase | 0,86     | 1      | 0,92     |

Vale a pena ressaltar que, apesar dos resultados serem considerados razoavelmente bons, foi trabalhado com uma pequena quantidade de dados, pois o equipamento apresentava elevada demanda de utilização no local, o que limitou a disponibilidade para realização de experimentos ao longo do período do projeto.




Figura 12. Resultado da análise de PCA do motor a 60Hz.

## 5. Conclusão e Trabalhos Futuros

Neste trabalho, foi desenvolvido um sistema para o aumento de vibração de uma região de interesse em vídeo e para a classificação do estado de operação do motor presente na filmagem em três classes (normal, desbalanceado e falta de fase). Os códigos foram implementados em *Python* e o objetivo foi de auxiliar na manutenção preditiva de equipamentos. No desenvolvimento, o sistema foi dividido em três frentes: análise de espectrograma, aumento de movimento em vídeo com pirâmide de Riesz e análise de PCA.

Para validar o sistema, foram registrados dados de um sensor de vibração e dados em vídeo com uma câmera de alta taxa de captura, considerando uma visão ampla do conjunto motor-disco, totalizando seis vídeos. Ainda, essas informações foram registradas com a alimentação do motor a 40Hz e 60Hz.

Os experimentos realizados evidenciaram a eficiência da análise de espectrograma, que identificou corretamente a frequência dominante em cinco dos seis vídeos avaliados. Supõe-se que a discrepância observada em um dos casos pode estar relacionada a problemas na integridade da captura, como interferência de ruídos e movimentação indevida da câmera.

Já em relação ao algoritmo de aumento de movimento, conseguiu-se modificar o vídeo de forma a aumentar visualmente a vibração do motor em todos os vídeos.

Por último, o algoritmo de análise de PCA conseguiu obter resultados com valores maiores que 90% de variância em todos os vídeos, ao diferenciar as características das classes de estado de operação do motor, e o classificador *Random Forest* conseguiu classificar corretamente as classes com precisão de pelo menos 86%.

Os gráficos e tabelas apresentados demonstraram que o sistema obteve bons resultados em comparação com os dados do sensor de vibração (*ground truth*). Como trabalhos futuros, a fim de melhorar o sistema e torná-lo mais robusto, recomenda-se a captura de mais dados em vídeo, utilizando

diferentes motores em diferentes cenários. Além disso, seria interessante que na etapa da análise de frequência da região de interesse fossem testadas outras técnicas para a demarcação da região de interesse. Exemplos seriam: utilizar um modelo de segmentação ao invés de *bounding box*; e a identificação de melhores regiões de interesse do motor para uma boa detecção da vibração. Com o intuito de caracterizar melhor os estados de operação do motor, pode-se, também, escolher outras características que descrevem melhor o espectro de frequência dos vídeos.

Dessa forma, o trabalho desenvolvido serve como base para novas pesquisas e posterior implementação em indústrias, sendo uma alternativa com menos custo em comparação ao uso de diversos sensores de vibração, uma vez que consegue analisar uma ampla área utilizando apenas uma câmera.

## Contribuição dos Autores

Loureni Monteiro Coutinho foi responsável pelo desenvolvimento do projeto e produção textual; Leonardo de Assis Silva contribuiu com ajuda no desenvolvimento do projeto e na produção textual; Fabricio Bortolini de Sá contribuiu com ajuda na aquisição do banco de dados utilizado no projeto.

## References

- [1] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 5462*: Confiabilidade e manutenibilidade. Rio de Janeiro, 1994. 37 p.
- [2] SILVA, D. L. F. F. d.; ABREU, T. C. d.; DUARTE, J. P. B. d. S. Análise de vibração e os seus benefícios no ambiente industrial. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, v. 9, n. 10, p. 3451–3462, nov. 2023. Disponível em: <https://periodicorease.pro.br/rease/article/view/11673>. Acesso em 16 mai. 2025.
- [3] AROEIRA, C. *Análise de vibrações em motores elétricos*. 2024. Disponível em: <https://www.dmc.pt/analise-de-vibracoes-em-motores-eletricos/>. Acesso em 23 out. 2024.
- [4] ŠMIEJA, M. et al. Motion magnification of vibration image in estimation of technical object condition-review. *Sensors*, v. 21, n. 19, 2021. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/21/19/6572>.
- [5] LUO, K. et al. Motion magnification for video-based vibration measurement of civil structures: A review. *Mechanical Systems and Signal Processing*, v. 220, p. 111681, 2024. ISSN 0888-3270. Disponível em: <https://www.sciencedirect.com/science/article/pii/S088832702400579X>.
- [6] JASIM, H.; ALSALAET, J. Detecting vibration problems in machines and structures using motion capturing by camera. *Basrah journal of engineering science*, v. 21, p. 38–49, 02 2021.
- [7] ZHAO, H. et al. Research on rotating machinery fault diagnosis based on an improved eulerian video motion magnification. *Sensors*, v. 23, n. 23, 2023. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/23/23/9582>.
- [8] LIU, C. et al. Motion magnification. *ACM Trans. Graph.*, v. 24, p. 519–526, 07 2005.
- [9] WU, H.-Y. et al. Eulerian video magnification for revealing subtle changes in the world. *ACM Transactions on Graphics (Proc. SIGGRAPH 2012)*, v. 31, n. 4, 2012.
- [10] WADHWA, N. et al. Phase-based video motion processing. *ACM Trans. Graph. (Proceedings SIGGRAPH 2013)*, v. 32, n. 4, 2013.
- [11] WADHWA, N. et al. Riesz pyramids for fast phase-based video magnification. In: IEEE. *Computational Photography (ICCP), 2014 IEEE International Conference on*. [S.l.], 2014.
- [12] JOCHER, G.; QIU, J. *Ultralytics YOLO11*. 2024. Disponível em: <https://github.com/ultralytics/ultralytics>. Acesso em 23 abr. 2025.