

## DESENVOLVIMENTO E COMPARAÇÃO DE MODELOS DE GERAÇÃO DE CURVAS FFT A PARTIR DE IMAGENS DE TEMPERATURA × TEMPO PARA CLASSIFICAÇÃO DE LUBRIFICAÇÃO EM MANCAIS DE ROLAMENTO

## DEVELOPMENT AND COMPARISON OF FFT CURVE GENERATION MODELS FROM TEMPERATURE–TIME IMAGES FOR LUBRICATION CLASSIFICATION IN ROLLING BEARINGS

## DESARROLLO Y COMPARACIÓN DE MODELOS PARA LA GENERACIÓN DE CURVAS FFT A PARTIR DE IMÁGENES DE TEMPERATURA–TIEMPO PARA LA CLASIFICACIÓN DE LA LUBRICACIÓN EN COJINETES DE RODILLOS

**Bruno da Cunha Diniz**

Doutor em Engenharia Mecânica, Universidade Federal da Bahia, Brasil

E-mail: [bruno.diniz@ufba.br](mailto:bruno.diniz@ufba.br)

**Ranya Mota Carvalho**

Graduanda em Engenharia Mecânica, Universidade Federal da Bahia, Brasil

E-mail: [ranyacarvalho@ufba.br](mailto:ranyacarvalho@ufba.br)

**Talisson de Jesus Alves Carvalho**

Engenheiro Mecânico, Universidade Federal da Bahia, Brasil

E-mail: [talisson.jesus@ufba.br](mailto:talisson.jesus@ufba.br)

### Resumo

Este trabalho apresenta o desenvolvimento e a comparação de cinco variantes de um modelo computacional destinado à conversão de imagens de curvas temperatura × tempo em representações espectrais por meio da Transformada Rápida de Fourier (FFT). As imagens utilizadas — 387 no total — foram geradas a partir dos arquivos .csv do KAIST Bearing Run-to-Failure Dataset (2020) e representam três regimes de lubrificação em mancais de rolamento (healthy, marginal e starved). Cada variante do modelo emprega estratégias específicas de suavização, ponderação por energia e realce espectral, com o objetivo de gerar curvas FFT adequadas para posterior classificação automática por redes neurais convolucionais (CNNs). Os resultados indicam que as versões FFT-Weighted, FFT-Composite e FFT-1D-Plus apresentaram melhor desempenho visual e estatístico, proporcionando espectros com maior estabilidade global e detalhamento local. Essa combinação favorece a diferenciação entre classes, uma vez que fornece padrões texturais e contrastes espectrais mais consistentes para o aprendizado convolucional. Conclui-se que a aplicação de FFT às curvas térmicas amplia a expressividade dos dados e constitui uma etapa promissora na preparação de datasets para reconhecimento de regimes de

lubrificação em mancais de rolamento por CNNs.

**Palavras-chave:** Transformada Rápida de Fourier; Mancais de Rolamento; Lubrificação; Redes Neurais Convolucionais; Processamento de Sinais.

## Abstract

This study presents the development and comparison of five computational model variants designed to convert temperature–time curve images into frequency-domain representations using the Fast Fourier Transform (FFT). A total of 387 images were generated from .csv files of the KAIST Bearing Run-to-Failure Dataset (2020), representing three bearing lubrication regimes (healthy, marginal, and starved). Each model variant applies specific strategies for smoothing, energy-based weighting, and spectral enhancement to produce FFT curves suitable for subsequent classification by convolutional neural networks (CNNs). The results show that the FFT-Weighted, FFT-Composite, and FFT-1D-Plus versions achieved superior performance, generating spectra with both high global stability and local spectral detail. This balance enhances class differentiation by providing consistent textural and frequency-domain patterns for convolutional learning. The findings demonstrate that applying FFT to thermal signals increases data expressiveness and represents a promising preprocessing stage for CNN-based classification of bearing lubrication regimes.

**Keywords:** Fast Fourier Transform; Rolling Bearings; Lubrication; Convolutional Neural Networks; Signal Processing.

## Resumen

Este estudio presenta el desarrollo y la comparación de cinco variantes de un modelo computacional diseñado para convertir imágenes de curvas temperatura–tiempo en representaciones espectrales mediante la Transformada Rápida de Fourier (FFT). Se utilizaron 387 imágenes generadas a partir de archivos .csv del KAIST Bearing Run-to-Failure Dataset (2020), que representan tres regímenes de lubricación en cojinetes de rodillos (healthy, marginal y starved). Cada variante aplica estrategias específicas de suavizado, ponderación energética y realce espectral para producir curvas FFT adecuadas para la clasificación automática mediante redes neuronales convolucionales (CNN). Los resultados indican que las versiones FFT-Weighted, FFT-Composite y FFT-1D-Plus ofrecen un desempeño superior, generando espectros con alta estabilidad global y buen nivel de detalle local. Este equilibrio mejora la diferenciación entre clases, proporcionando patrones texturales y contrastes espectrales consistentes para el aprendizaje convolucional. Se concluye que la aplicación de la FFT a las curvas térmicas incrementa la expresividad de los datos y constituye una etapa prometedora en la preparación de conjuntos de datos para el reconocimiento de regímenes de lubricación mediante CNN.


**Palabras clave:** Transformada Rápida de Fourier; Cojinetes de Rodillos; Lubricación; Redes Neuronales Convolucionales; Procesamiento de Señales.

## 1. Introdução

A análise de sinais no domínio da frequência, por meio da Transformada Rápida de Fourier (FFT), constitui uma etapa crítica em aplicações de monitoramento de condição e diagnóstico de falhas em mancais e máquinas rotativas. Esta técnica permite converter séries temporais — nas quais flutuações térmicas ou vibratórias podem se misturar ao ruído — em representações espectrais, nas quais as componentes harmônicas e os picos de energia tornam-se mais evidentes. Estudos demonstram que o processamento de sinais por FFT possibilita a detecção de frequências características associadas a avarias mecânicas ou deficiências na lubrificação, ao reduzir interferências e realçar componentes relevantes (Zhou *et al.*, 2015; Sensors, 2022).

Estudos recentes têm explorado o uso de técnicas de processamento de imagens e aprendizado profundo para o diagnóstico de condições de lubrificação em mancais de rolamento. Nesse contexto, Carvalho, Carvalho e Diniz (2025) propuseram um modelo capaz de converter sinais térmicos do KAIST *Bearing Run-to-Failure Dataset* (2020) em imagens de curvas de temperatura  $\times$  tempo, utilizadas no treinamento de uma rede neural convolucional (CNN) do tipo ResNet-18 adaptada. O objetivo do estudo foi classificar diferentes regimes de lubrificação — *Healthy*, *Marginal* e *Starved* — a partir do comportamento térmico dos mancais. As curvas de temperatura  $\times$  tempo correspondentes a cada classe, como mostradas na Figura 1, permitem visualizar o padrão temporal original dos mancais antes da aplicação de qualquer transformação espectral, evidenciando variações térmicas características de cada regime de lubrificação.

**Figura 1 – Exemplo de curvas de temperatura em função do tempo dos mancais do conjunto de dados *KAIST Bearing Run-to-Failure* (2020): à esquerda, condição *Healthy*; ao centro, *Marginal*; e à direita, *Starved*.**



No contexto de classificação automática por redes neurais convolucionais (CNN), a conversão para o domínio da frequência assume ainda maior relevância. Ao transformar curvas de temperatura  $\times$  tempo em espectros ou imagens de frequência, a representação bruta temporal é convertida em uma estrutura com padrões espaciais e “texturais” que podem ser mais facilmente capturados por filtros convolucionais (Xu *et al.*, 2024; Carvalho *et al.*, 2025). A presente proposta consiste na extensão dessa abordagem, transformando imagens de curvas temperatura  $\times$  tempo em representações no domínio da frequência por meio da FFT 1-D, gerando um conjunto de imagens-FFT que podem ser utilizadas em experimentos subsequentes de classificação por CNN.

A utilização das representações no domínio da frequência apresenta vantagens significativas em relação às curvas originais de temperatura  $\times$  tempo. Enquanto estas últimas correspondem a sinais unidimensionais de baixa densidade espacial — frequentemente representados por traços finos que ocupam uma fração mínima da imagem —, suas transformadas espectrais oferecem uma distribuição mais ampla de energia ao longo do eixo de frequência, favorecendo a extração de padrões robustos e discriminativos. A análise no domínio da frequência permite evidenciar componentes harmônicas e oscilações características que, no domínio do tempo, podem estar mascaradas por ruído ou variações lentas de temperatura (Cooley e Tukey, 1965; Oppenheim e Schafer, 2010). Além disso, as imagens-FFT resultantes possuem maior densidade informacional e uniformidade visual, características que facilitam o aprendizado por redes convolucionais (CNN), as quais dependem de padrões espaciais consistentes para otimizar sua capacidade de generalização (LeCun *et al.*, 2015). Assim, a conversão das curvas temperatura

× tempo em representações espectrais constitui uma etapa fundamental para aprimorar a expressividade e a eficácia dos modelos de classificação baseados em CNN.

Para isso, foram desenvolvidas cinco implementações em *Python*, cada uma aplicando estratégias distintas de extração, normalização e realce de componentes espectrais. As implementações são descritas detalhadamente, destacando suas particularidades e distinções. Métodos híbridos, como a combinação de FFT, decomposição por valores singulares (SVD) e arquiteturas CNN-LSTM (arquitetura híbrida de redes neurais que combina Redes Neurais Convolucionais com *Long Short-Term Memory networks* para aproveitar os pontos fortes de cada uma em tarefas que envolvem dados espaciais e temporais), têm demonstrado ganhos significativos em acurácia para o diagnóstico de falhas de mancais rotativos, evidenciando a eficácia do pré-processamento espectral (Actuators, 2025; Xu *et al.*, 2024).


Portanto, a aplicação de FFT às curvas térmicas de mancais permite gerar conjuntos de dados espectrais nos quais diferenças entre regimes de lubrificação podem se manifestar com maior clareza. Essa abordagem fornece entradas mais expressivas para arquiteturas CNN, favorecendo tanto o aprendizado de características discriminantes quanto a robustez frente a ruído e variabilidade operacional (Zhou *et al.*, 2015; Sensors, 2022; Actuators, 2025; Carvalho *et al.*, 2025).

## 2. Metodologia

O procedimento geral seguido em todas as implementações está representado no fluxograma conceitual apresentado na Figura 2, que compreende as etapas de leitura das imagens, conversão para escala de cinza e inversão de intensidade (de modo que cada pixel passa de  $p$  para  $255 - p$ ), projeção vertical para extração da curva unidimensional, suavização, aplicação da transformada rápida de Fourier (FFT), processamento espectral e normalização. As imagens utilizadas correspondem a um total de 387 curvas de temperatura × tempo,

previamente geradas a partir dos arquivos .csv do banco de dados KAIST *Bearing Run-to-Failure Dataset* (Korea Advanced Institute of Science and Technology, 2020). Essas operações são executadas de forma sequencial, compondo o núcleo comum das cinco variantes do modelo computacional desenvolvidas neste estudo.

**Figura 2 – Fluxograma conceitual do processo de geração das curvas FFT a partir de imagens de temperatura × tempo.**



O processo de geração das curvas FFT a partir das imagens de temperatura × tempo segue um conjunto de etapas fundamentais aplicadas de maneira sistemática em todas as versões dos modelos computacionais. Inicialmente, as imagens no formato PNG, obtidas a partir das curvas de temperatura versus tempo do banco de dados KAIST (2020), são lidas e convertidas para escala de cinza. A inversão dos valores de intensidade é aplicada para realçar o traçado da curva original, de modo que regiões mais claras na imagem passem a representar maiores valores de temperatura relativa. A seguir, realiza-se a projeção vertical da imagem, obtendo-se uma curva 1-D representativa da variação de intensidade ao longo do eixo horizontal. Essa curva é calculada, em geral, pela mediana dos

valores de cada coluna, o que proporciona maior robustez frente a ruídos de pixel isolados e irregularidades visuais no traçado.

A etapa de suavização é então aplicada ao sinal obtido, utilizando um filtro gaussiano unidimensional (*scipy.ndimage.gaussian\_filter1d*). O objetivo é reduzir flutuações aleatórias e ruído de alta frequência, preservando as tendências gerais do comportamento térmico. O parâmetro de suavização ( $\sigma$ ) é ajustado conforme a classe de lubrificação (*healthy*, *marginal* ou *starved*), de modo a adequar a sensibilidade do modelo às características específicas de cada regime.

Em seguida, aplica-se a transformada rápida de Fourier (FFT), que converte o sinal do domínio do tempo para o domínio da frequência. Essa transformação decompõe a curva temporal em suas componentes harmônicas, permitindo representar o comportamento do sinal em termos de frequência (Hz) e amplitude espectral, a qual indica a intensidade relativa de cada componente. No presente trabalho, a FFT é calculada pelo método *numpy.fft.rfft*, que retorna apenas o semi-espectro positivo, e o eixo de frequência é obtido por meio de *numpy.fft.rfftfreq*, considerando uma taxa de amostragem normalizada de 1 Hz.

A partir do espectro obtido, são aplicadas as transformações espectrais que diferenciam as variantes do modelo. O sinal de amplitude é dividido em sub-bandas de frequência, que correspondem a intervalos específicos do espectro, como faixas de baixa, média e alta frequência. Essa divisão permite aplicar diferentes ponderações ou filtros a cada região, enfatizando ou atenuando faixas conforme o regime de lubrificação analisado. Em cada sub-banda, calcula-se a energia espectral, definida como a soma dos quadrados das amplitudes naquela faixa de frequência. Esse parâmetro expressa o conteúdo energético associado às oscilações térmicas do mancal de rolamento e fornece um indicador quantitativo do nível de instabilidade do sistema.

As versões mais avançadas do modelo utilizam essas informações para ajustar o peso relativo de cada sub-banda, realizar compressões não lineares (como transformações logarítmicas e de potência) e aplicar derivadas de primeira e segunda ordem sobre o espectro, com o objetivo de realçar picos ou transições abruptas. O resultado final é uma curva FFT processada e normalizada pelo

método *min–max*, de forma que todos os valores sejam escalados para o intervalo  $[0,1]$ , permitindo comparações consistentes entre amostras e entre classes.

Complementarmente, todas as implementações foram desenvolvidas em linguagem *Python*, utilizando bibliotecas consolidadas para processamento numérico e científico, como *NumPy*, *Pandas*, *Matplotlib*, *SciPy* e *Pillow*. As versões compartilham parâmetros operacionais padronizados, assegurando a comparabilidade dos resultados. O mesmo procedimento de leitura, projeção, suavização, cálculo da FFT e normalização foi aplicado a todas as variantes, de modo que as diferenças observadas nos resultados derivam exclusivamente das estratégias de ponderação espectral e das transformações específicas introduzidas em cada modelo.

### 3. Descrição dos modelos computacionais

A geração das curvas FFT a partir das imagens de temperatura  $\times$  tempo foi realizada por meio de cinco versões de um modelo computacional, cada uma incorporando variações metodológicas destinadas a aprimorar a representação espectral dos sinais térmicos. Todas as versões seguem uma estrutura comum composta pelas etapas de leitura das imagens, projeção da curva térmica, suavização, cálculo da transformada rápida de Fourier (FFT), normalização e geração das imagens resultantes. As diferenças principais residem nas estratégias adotadas em cada versão para o realce espectral, ponderação por banda de frequência e manipulação não linear das amplitudes. Os nomes atribuídos a cada modelo — *FFT-AdvV2*, *FFT-Weighted*, *FFT-Composite*, *FFT-1D* e *FFT-1D-Plus* — refletem a principal característica conceitual ou operacional que diferencia suas abordagens, permitindo uma identificação direta das variações metodológicas entre as versões e facilitando a análise comparativa dos resultados.

A primeira implementação, denominada *FFT-AdvV2*, representa uma abordagem inicial voltada à exploração da curvatura espectral e à identificação de componentes locais relevantes. Após a leitura e conversão da imagem para escala de cinza, é aplicada uma projeção vertical baseada na mediana, seguida de

suavização gaussiana ajustada por classe de lubrificação. A transformada de Fourier é então calculada e dividida em três sub-bandas — baixa, média e alta frequência — às quais são atribuídos pesos diferenciados. Além disso, o algoritmo identifica picos locais de amplitude e os reforça por meio de um fator de amplificação, combinando posteriormente os resultados com transformações não lineares, como logaritmo e segunda derivada da curva espectral. O resultado é uma representação que enfatiza variações abruptas e harmônicos, útil para evidenciar assinaturas de falhas, ainda que mais sensível ao ruído.

A segunda versão, denominada *FFT-Weighted*, apresenta uma evolução conceitual ao empregar ponderação dinâmica entre sub-bandas com base nas energias relativas calculadas para cada região espectral. Essa estratégia busca equilibrar o conteúdo energético entre as faixas de frequência, reduzindo a influência de regiões dominantes e atenuando as bordas do espectro. São aplicadas transformações derivativas e logarítmicas para compressão de amplitude e realce de componentes significativos. Em comparação à versão anterior, o resultado é um espectro mais estável, com melhor separação visual entre as classes e menor suscetibilidade a variações locais de ruído, servindo como um modelo intermediário robusto para geração de conjuntos de dados.

A terceira variante, *FFT-Composite*, tem como foco a formação de curvas médias representativas de cada classe. O modelo mantém a sequência de pré-processamento e cálculo espectral, mas introduz o armazenamento das curvas FFT de todas as amostras pertencentes a uma mesma classe, permitindo o cálculo de perfis compostos que sintetizam o comportamento espectral médio de cada condição de lubrificação. Essa abordagem fornece uma visão estatística mais robusta do padrão térmico e facilita a análise comparativa entre as classes *healthy*, *marginal* e *starved*. Além disso, o parâmetro de peso das derivadas é ajustado por classe, permitindo controlar a sensibilidade do modelo a variações rápidas no espectro e avaliar a consistência intra-classe.

A quarta versão, denominada *FFT-1D*, foi concebida como uma implementação simplificada e interpretável, mantendo apenas as transformações essenciais para a análise espectral. O processamento é conduzido de maneira

mais direta, com sub-bandas igualmente espaçadas e combinações ponderadas de amplitude, logaritmo e derivadas. Essa versão busca servir como referência metodológica, permitindo avaliar o impacto das técnicas adicionais introduzidas nas variantes mais complexas. O resultado é uma curva FFT mais suave e consistente, preservando as tendências gerais de cada regime de lubrificação com menor interferência de operações não lineares.

Por fim, a quinta variante, *FFT-1D-Plus*, foi concebida como uma extensão aprimorada da anterior, incorporando análises estatísticas locais, como o cálculo da variância de cada sub-banda, e a aplicação de uma compressão não linear do tipo gama. Essa estratégia permite ajustar a resposta espectral de acordo com a dispersão de energia em cada faixa de frequência, suavizando picos excessivos e equilibrando a distribuição de amplitudes. O modelo também realiza uma mistura entre a versão suavizada e a versão ponderada do espectro, resultando em curvas mais estáveis e visualmente limpas, com melhor contraste entre as classes.


#### 4. Resultados e Discussão

As Figuras 3 à 7 apresentam as curvas FFT normalizadas para as três classes de regime de lubrificação dos mancais — healthy, marginal e starved — obtidas a partir das cinco variantes do modelo de processamento. Cada espectro reflete a distribuição de energia em frequência de uma ou mais curvas de temperatura  $\times$  tempo, evidenciando as diferenças na estabilidade térmica e nas oscilações características de cada condição operacional.

Nas versões *AdvV2* e *FFT-Weighted* (Figuras 3 e 4), as curvas foram geradas a partir de um único exemplo de cada classe, permitindo observar a variabilidade individual dos sinais. Em ambas, verifica-se uma separação nítida das classes principalmente nas baixas frequências ( $< 0,1$  Hz), com a condição *starved* apresentando maior amplitude espectral e cauda mais longa, indicativas de flutuações térmicas amplas e instabilidade de regime. A classe *healthy* apresenta rápida atenuação de amplitude, o que denota um comportamento mais estável e previsível. Entre as duas, a *FFT-Weighted* se destaca por exibir curvas mais


suavizadas e consistentes, reflexo da ponderação por energia entre sub-bandas, que reduz o ruído e preserva as formas dominantes da resposta espectral. Esse comportamento tende a ser vantajoso para uma CNN, uma vez que fornece padrões mais limpos e espacialmente coerentes para o aprendizado convolucional.

**Figura 3 – Espectros FFT da versão *FFT-AdvV2* para diferentes regimes de lubrificação de mancais.**




A versão *FFT-Composite* (Figura 5) combina múltiplas FFTs de cada classe em uma curva média ponderada, resultando em representações mais estáveis e menos suscetíveis a ruído. Nota-se que o ordenamento energético entre as classes é preservado (*starved* > *marginal* > *healthy*), e as amplitudes mantêm coerência espectral ao longo da faixa de 0 a 0,3 Hz. Essa abordagem apresenta uma vantagem estatística, pois consolida variações intra-classe, oferecendo uma representação média fiel e adequada para a síntese de conjuntos de treinamento.

**Figura 4 - Espectros FFT da versão *FFT-Weighted* mostrando distribuição equilibrada de amplitudes por classe de lubrificação.**




**Figura 5 - Perfis espectrais médios por classe obtidos com *FFT-Composite*.**



Na *FFT-1D* (Figura 6), a média direta das curvas FFT individuais de cada classe promove uma suavização excessiva, resultando em espectros mais uniformes, porém com menor presença de picos harmônicos. Embora as diferenças


entre classes permaneçam visíveis, a perda de detalhe pode limitar o aprendizado de *features* mais finas nas primeiras camadas convolucionais de uma CNN.

**Figura 6 - Curvas médias de amplitude por frequência na versão *FFT-1D*.**



A *FFT-1D-Plus* (Figura 7) aprimora esse comportamento ao aplicar ponderações espectrais adicionais e uma suavização controlada. O resultado é um espectro mais equilibrado, com manutenção dos picos locais e clara separação entre as três classes em toda a faixa de frequência. Essa combinação de estabilidade global e detalhamento local indica que a *FFT-1D-Plus* gera representações mais ricas em textura espectral, característica desejável para reconhecimento por CNNs.

**Figura 7 - Curvas médias espectrais da versão *FFT-1D-Plus* com estatísticas de variância por sub-banda e compressão gama.**



De modo geral, os resultados mostram coerência entre as diferentes variantes do modelo, com todas mantendo a relação esperada entre amplitude espectral e regime de lubrificação. As condições *starved* e *marginal* concentram maior energia nas baixas frequências, refletindo maior oscilação térmica e instabilidade mecânica, enquanto a condição *healthy* apresenta espectros mais planos e amplitudes reduzidas, associadas à operação estável do mancal. Entre as variantes analisadas, as versões *FFT-Weighted*, *FFT-Composite* e *FFT-1D-Plus* apresentaram desempenho superior em termos de clareza, estabilidade e discriminação entre classes. A transição das representações individuais (modelos *FFT-AdvV2* e *FFT-Weighted*) para as médias compostas (modelos *FFT-Composite*, *FFT-1D* e *FFT-1D-Plus*) demonstra a progressiva robustez e consistência estatística das curvas FFT, evidenciando o ganho metodológico na preparação de *datasets* para aplicação em redes neurais convolucionais. Para sintetizar as diferenças entre as versões, a Tabela 1 apresenta uma comparação estruturada considerando critérios técnicos e o potencial estimado de desempenho em redes neurais convolucionais.

**Tabela 1 – Comparação entre as variantes FFT desenvolvidas para geração de imagens espectrais.**

| Modelo               | Tipo de amostragem                     | Tratamento espectral                                | Comportamento observado                                                                                                              | Potencial para CNN                                                                                                                 |
|----------------------|----------------------------------------|-----------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------|
| <b>AdvV2</b>         | Exemplo único por classe               | FFT direta com suavização leve                      | Espectros individualizados com alta variabilidade; boa separação entre classes, mas presença de ruído e irregularidades locais.      | <b>Moderado</b> – útil para análise exploratória, mas com baixo controle de ruído e pouca consistência entre amostras.             |
| <b>FFT-Weighted</b>  | Exemplo único por classe               | Ponderação por energia entre sub-bandas             | Curvas mais estáveis e suavizadas; redução do ruído e melhor definição das diferenças espectrais entre classes.                      | <b>Alto</b> – espectros limpos e bem definidos favorecem extração de <i>features</i> convolucionais estáveis.                      |
| <b>FFT-Composite</b> | Média de todas as FFTs por classe      | Composição ponderada global                         | Representação robusta e representativa de cada classe; preserva hierarquia energética ( <i>starved &gt; marginal &gt; healthy</i> ). | <b>Alto</b> – ideal para síntese de <i>datasets</i> de referência e treinamento de CNNs.                                           |
| <b>FFT-1D</b>        | Média unidimensional simples           | Suavização global uniforme                          | Espectros excessivamente suavizados, perda de detalhes locais e picos harmônicos; reduz contraste interclasse.                       | <b>Moderado-Baixo</b> – estabilidade boa, mas informação espectral limitada para aprendizado profundo.                             |
| <b>FFT-1D-Plus</b>   | Média ponderada com ajustes espectrais | Suavização otimizada e ponderação por energia local | Espectros equilibrados, com picos bem definidos e separação clara entre classes; ruído minimizado.                                   | <b>Muito alto</b> – combinação ideal de estabilidade e detalhamento espectral; maior potencial para reconhecimento visual por CNN. |

Essa combinação de estabilidade global e detalhamento espectral local observada na versão *FFT-1D-Plus* representa uma condição particularmente favorável para reconhecimento automático por redes neurais convolucionais

(CNNs). A estabilidade global — obtida pela suavização otimizada e pela normalização consistente entre as curvas — garante que o espectro apresente padrões contínuos e comparáveis entre amostras de uma mesma classe, minimizando variações aleatórias que poderiam ser interpretadas pela rede como ruído. Em paralelo, o detalhamento espectral — preservado pela manutenção de picos locais e gradientes de amplitude — assegura que as diferenças estruturais entre classes distintas (por exemplo, *healthy*, *marginal* e *starved*) permaneçam visíveis e quantificáveis no espaço da imagem. Estudos clássicos como o de Cooley e Tukey (1965) estabeleceram a FFT como uma das ferramentas fundamentais para decomposição eficiente de sinais no domínio da frequência, permitindo análises espectrais de alta resolução.

Em termos de aprendizado de máquina, uma CNN aprende a distinguir classes com base em padrões espaciais e texturais presentes nas imagens de entrada. No caso das FFTs, esses padrões correspondem à disposição e intensidade relativa das componentes de frequência. Representações espectrais bem estruturadas foram demonstradas como altamente eficazes para extração de *features* discriminantes em tarefas de diagnóstico de falhas e monitoramento de condição (Zhang *et al.*, 2022; Wu *et al.*, 2023). Um espectro excessivamente suave tende a eliminar variações locais de energia que são essenciais para a identificação de assinaturas específicas de cada regime de lubrificação, enquanto um espectro muito ruidoso introduz artefatos que dificultam a generalização do modelo. Assim, a FFT-1D-Plus alcança um equilíbrio ótimo entre consistência intra-classe e contraste inter-classe, o que favorece a extração de *features* convolucionais discriminantes. Essa configuração permite que a CNN identifique, de forma mais robusta, os padrões de energia típicos de cada condição térmica do mancal, resultando em melhor desempenho preditivo e maior estabilidade do treinamento.

## 5. Conclusão

Os cinco modelos computacionais desenvolvidos constituem um conjunto coerente de estratégias para transformar imagens de curvas temperatura  $\times$  tempo

(KAIST) em assinaturas no domínio da frequência, oferecendo diferentes níveis de interpretação e robustez. Cada variante apresenta um compromisso específico entre interpretabilidade, sensibilidade a picos e curvatura, e sofisticação adaptativa — incluindo ponderação por energia ou variância e compressão de espectros. De modo geral, os resultados mostram coerência entre as diferentes variantes do modelo, mantendo a relação esperada entre amplitude espectral e regime de lubrificação: as condições *starved* e *marginal* concentram maior energia nas baixas frequências, refletindo maior oscilação térmica e instabilidade mecânica, enquanto a condição *healthy* apresenta espectros mais planos e amplitudes reduzidas, associadas à operação estável do mancal.

Entre as variantes analisadas, as versões *FFT-Weighted*, *FFT-Composite* e *FFT-1D-Plus* apresentaram desempenho superior quanto à clareza espectral, estabilidade global e capacidade discriminativa entre as classes de lubrificação. A transição das representações individuais (*FFT-AdvV2* e *FFT-Weighted*) para as médias compostas (*FFT-Composite*, *FFT-1D* e *FFT-1D-Plus*) evidenciou um ganho consistente em robustez estatística e regularidade estrutural, aspectos essenciais para a formação de *datasets* destinados a redes neurais convolucionais. A síntese desses resultados, conforme apresentado na Tabela 1, demonstra que os modelos baseados em composições e ponderações espectrais oferecem uma melhor separabilidade visual e maior homogeneidade intra-classe, características desejáveis para reconhecimento de padrões por CNNs.

Em perspectivas futuras, pretende-se empregar as curvas FFT geradas neste estudo como imagens de entrada em modelos convolucionais, avaliando empiricamente a capacidade de cada variante em identificar, de forma autônoma, o regime de lubrificação (*Healthy*, *Marginal* e *Starved*) a partir apenas de suas assinaturas espectrais. Espera-se que as versões com melhor equilíbrio entre estabilidade e detalhamento — notadamente a *FFT-1D-Plus* — apresentem desempenho superior em tarefas de classificação, consolidando a aplicação de representações no domínio da frequência como uma etapa de pré-processamento eficaz na análise térmica de mancais de rolamento.

## Referências

ACTUATORS. *The Fault Diagnosis of Rolling Bearings Based on FFT SE TCN*

*SVM. Actuators*, v. 14, n. 3, p. 152, 2025. Disponível em:

<https://www.mdpi.com/2076-0825/14/3/152>. Acesso em: 31 out. 2025.

CARVALHO, R. M.; CARVALHO, T. J. A.; DINIZ, B. C. *Development of an Image Processing Model for Bearing Lubrication Classification Using Convolutional Neural Networks*. In: XI SIINTEC – International Symposium on Innovative Technologies, 2025, Salvador. *Proceedings: XI SIINTEC*, 2025.

COOLEY, J. W.; TUKEY, J. W. *An algorithm for the machine calculation of complex Fourier series. Mathematics of Computation*, v. 19, n. 90, p. 297–301, 1965.

KOREA ADVANCED INSTITUTE OF SCIENCE AND TECHNOLOGY (KAIST).

*Bearing Run-to-Failure Dataset*. Daejeon, South Korea, 2020.

LECUN, Y.; BENGIO, Y.; HINTON, G. *Deep learning. Nature*, v. 521, n. 7553, p. 436–444, 2015.

OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-Time Signal Processing*. 3. ed. Upper Saddle River: Prentice Hall, 2010.

SENSORS. *Bearing Fault Diagnosis Using Lightweight and Robust One Dimensional Convolution Neural Network in the Frequency Domain. Sensors*, v. 22, n. 15, p. 5793, 2022. Disponível em: <https://www.mdpi.com/1424-8220/22/15/5793>. Acesso em: 31 out. 2025.

WU, X.; YANG, C.; ZHENG, H.; LI, X. *Intelligent fault diagnosis of rotating machinery based on improved CNN with frequency–domain feature fusion. Sensors*, v. 23, n. 8, p. 3921, 2023.

XU, M.; YU, Q.; CHEN, S.; LIN, J. *Rolling Bearing Fault Diagnosis Based on CNN-LSTM with FFT and SVD. Information*, v. 15, n. 7, p. 399, 2024. Disponível em: <https://www.mdpi.com/2078-2489/15/7/399>. Acesso em: 31 out. 2025.

ZHANG, H.; ZHOU, Y.; WANG, Z.; LI, J. *Fault diagnosis of rolling bearings based on time–frequency representation and convolutional neural networks. Mechanical Systems and Signal Processing*, v. 181, p. 109484, 2022.

ZHOU, J.; QIN, Y.; KOU, L.; YUWONO, M.; SU, S. *Fault detection of rolling bearing based on FFT and classification. Journal of Advanced Mechanical Design, Systems, and Manufacturing*, v. 9, n. 5, 2015. Disponível em: [https://www.jstage.jst.go.jp/article/jamdsm/9/5/9\\_2015jamdsm0056/article](https://www.jstage.jst.go.jp/article/jamdsm/9/5/9_2015jamdsm0056/article). Acesso em: 31 out. 2025.