

DESENVOLVIMENTO E AVALIAÇÃO DE ALGORITMOS DE FILTRAGEM E JANELAMENTO PARA PROCESSAMENTO DE SINAIS DE VIBRAÇÃO MECÂNICA

**DEVELOPMENT AND EVALUATION OF FILTERING AND WINDOWING
ALGORITHMS FOR MECHANICAL VIBRATION SIGNAL PROCESSING**

Ciências Exatas e da Terra, Engenharias • 31/08/2026

REGISTRO DOI: [10.70773/revistatopicos/788159978](https://doi.org/10.70773/revistatopicos/788159978)

Lucas Barçante Cunha¹

Hygor Santiago Lara²

RESUMO

Este trabalho aborda os fundamentos e a aplicação prática do Processamento Digital de Sinais (DSP) como elemento de ligação entre fenômenos físicos contínuos e o ambiente computacional discreto. Diante do desafio de mitigar ruídos estocásticos e interferências ambientais que contaminam dados de sensores no cenário industrial, o objetivo deste estudo é desenvolver um algoritmo robusto na linguagem Python para realizar uma análise comparativa de diferentes técnicas de filtragem, janelamento e análise espectral. A fundamentação teórica baseia-se no Teorema da Amostragem de Nyquist-Shannon para prevenção do fenômeno de *aliasing*, no emprego de filtros lineares e invariantes no tempo (LTI) de topologias passa-baixas, passa-altas e passa-banda, e na aplicação de funções de janela (Hann, Hamming e Blackman) para atenuação do vazamento espectral. A transição para o domínio da frequência é realizada por meio da Transformada Rápida de Fourier (FFT), e a integridade dinâmica dos sinais é quantificada através de descritores estatísticos como média, valor quadrático médio (RMS), variância e fator de crista espectrais, validados pelos testes estatísticos de Levene e ANOVA. A metodologia experimental computacional utiliza sinais reais de vibração mecânica provenientes de um acelerômetro triaxial acoplado a um motor que gira em torno de 1800 rpm, amostrados a 3000 Hz. Os resultados buscam avaliar quantitativamente o desempenho e a aplicabilidade de cada combinação de tratamento na extração precisa de assinaturas de frequência e no isolamento de componentes harmônicos correlacionados a falhas estruturais.

Palavras-chave: Processamento Digital de Sinais; Transformada Rápida de Fourier; Filtragem Digital; Janelamento; Vibrações Mecânicas.

ABSTRACT

This paper addresses the fundamentals and practical application of Digital Signal Processing (DSP) as a bridge between continuous physical phenomena and the discrete computational environment. Facing the challenge of mitigating stochastic noise and environmental interference that contaminate sensor data in industrial scenarios, the objective of this study is to develop a robust algorithm in Python to perform a comparative analysis of different filtering, windowing, and spectral analysis techniques. The theoretical framework is based on the Nyquist-Shannon Sampling Theorem to prevent the aliasing phenomenon, the use of linear time-invariant (LTI) filters with low-pass, high-pass, and band-pass topologies, and the application of window functions (Hann, Hamming, and Blackman) to attenuate spectral leakage. The transition to the frequency domain is performed through the Fast Fourier Transform (FFT), and the dynamic integrity of the signals is quantified using statistical descriptors such as spectral mean, root mean square (RMS), variance, and crest factor, validated by Levene and ANOVA statistical tests. The computational experimental methodology uses real mechanical vibration signals from a triaxial accelerometer coupled to an motor that spins around 1800 rpm, sampled at 3000Hz. The results seek to quantitatively evaluate the performance and applicability of each treatment combination in the precise extraction of frequency signatures and the isolation of harmonic components correlated with structural faults.

Keywords: Digital Signal Processing; Fast Fourier Transform; Digital Filtering; Windowing; Mechanical Vibrations.

1. INTRODUÇÃO

O Processamento de Sinais é uma subárea da engenharia e da ciência da computação dedicada à análise, modificação, síntese e interpretação de variáveis físicas que carregam algum tipo de informação, chamadas de sinais. Essa disciplina atua como uma ponte essencial entre os fenômenos do mundo real e os sistemas computacionais, utilizando ferramentas matemáticas para converter dados brutos que podem assumir infinitos valores em um intervalo de tempo em formatos discretos compreensíveis para computadores. Seja lidando com ondas sonoras, sinais biomédicos, imagens ou ondas eletromagnéticas, o processamento de sinais busca extrair padrões úteis e traduzir o comportamento de sistemas dinâmicos complexos através de sinais analógicos ou digitais.

Na engenharia, um grande desafio existente na área é a presença inevitável de ruídos e interferências que degradam a qualidade dos dados captados no ambiente real. Na análise de vibrações em maquinários e estruturas industriais, por exemplo, o sinal de interesse frequentemente sofre com a sobreposição de vibrações de fundo da planta fabril, interferências eletromagnéticas na instrumentação e ruídos complexos gerados por componentes adjacentes, como engrenagens e bombas. Para contornar esse problema, pesquisadores como Zhang *et al.* (2023) desenvolveram filtros adaptativos utilizando aprendizado de máquina (*machine learning*) capazes de se ajustar dinamicamente às variações não estacionárias desses ruídos mecânicos e operacionais, resolvendo as limitações dos filtros estáticos antigos na detecção de falhas. Liu *et al.* (2024) criaram um algoritmo de filtragem adaptativa capaz de se reconfigurar automaticamente à medida que a velocidade da máquina muda, garantindo que o sinal filtrado permaneça limpo mesmo sob condições dinâmicas e de alta interferência. Dentro desses cenários críticos, técnicas de processamento se tornam

indispensáveis, pois por meio de algoritmos de filtragem e condicionamento de sinais, torna-se possível isolar as frequências desejadas, como assinaturas indicativas de defeitos, eliminando impurezas, garantindo a integridade e a fidelidade da informação que será analisada para o diagnóstico do sistema.

Atualmente, o campo recebe muita pesquisa voltada para a fusão entre técnicas tradicionais de processamento de sinais e o aprendizado de máquina (*Machine Learning*). Existe muito foco no desenvolvimento de algoritmos de filtragem adaptativa altamente inteligentes, capazes de se ajustar dinamicamente a ruídos variáveis em tempo real, dispensando a parametrização manual estática. Além disso, a popularização de ecossistemas de código aberto e linguagens de programação de alto nível, especialmente o Python, democratizou a implementação de análises espectrais e transformadas rápidas de Fourier (FFT), permitindo o desenvolvimento ágil de soluções robustas em plataformas que vão desde servidores em nuvem até dispositivos embarcados de baixo custo.

O futuro dessa disciplina reserva um potencial extraordinário para a consolidação da manutenção preditiva inteligente e do desenvolvimento de gêmeos digitais (*digital twins*) no ecossistema da Indústria 4.0. A evolução constante dos algoritmos permitirá decodificar, com precisão inédita, assinaturas de vibração extremamente fracas e mascaradas por ruídos severos em regime transiente, viabilizando a identificação precoce de microfissuras e desgastes microscópicos em rolamentos e engrenagens antes que ocorra qualquer sintoma macroscópico de falha (LV *et al.*, 2024). Essa transição de ferramentas puramente analíticas para sistemas preditivos ultrarrápidos consolida o processamento de sinais como

um pilar indispensável para a evolução da inteligência artificial aplicada e da Internet das Coisas (IoT).

Diante do exposto, o presente trabalho tem como objetivo desenvolver um algoritmo robusto de processamento digital de sinais utilizando a linguagem Python, bem como realizar uma análise comparativa de diferentes técnicas de filtragem, janelamento e análise espectral. Busca-se, com isso, avaliar o desempenho e a aplicabilidade de cada abordagem na mitigação de ruídos e na extração de assinaturas de frequência.

2. FUNDAMENTAÇÃO TEÓRICA

Um sinal é uma grandeza física que carrega algum tipo de informação, mensagem ou dado, se algo no mundo físico muda e a transmissão dessa mudança ocorre, isso é classificado como um sinal. Todo sinal possui duas características que permitem a sua identificação: Uma variável independente que mostra quando e onde ele acontece, podendo ser o tempo ou o espaço, e uma amplitude que determina a força ou intensidade do sinal. Para melhor classificação, os sinais são divididos em dois grupos: digitais e analógicos.

Sinais analógicos são contínuos no tempo e na intensidade. Isso significa que podem assumir qualquer valor em um intervalo de tempo infinito, a natureza é analógica. Sinais digitais são discretos tanto no tempo quanto na intensidade, eles não são contínuos, e sim, são representados por uma sequência de valores numéricos bem definidos. Matematicamente, um sinal é apenas uma função. Se o sinal varia com o tempo, ele é chamado de uma função do tempo. O processamento digital de sinais é a ponte entre o mundo

físico contínuo (analogico) e o mundo dos computadores (digital). O objetivo principal é modificar, analisar, extrair informações ou melhorar esses sinais para torná-los mais úteis ou compreensíveis. Como computadores não conseguem ler sinais analógicos por serem contínuos no tempo e na intensidade, é necessário para que um computador possa processar esses sinais, passar por duas etapas básicas: Conversão Analógico-Digital (ADC) em que o sinal analógico é amostrado e transformado em uma sequência de números e Processamento de sinais digital (DSP), em que um processador matemático executa algoritmos complexos em cima desses números (filtragem, compressão, amplificação, etc.).

2.1. Topologias de Filtros

Para modificar o espectro de amplitude e fase de um sinal, atenuando seletivamente determinadas bandas de frequência e permitindo a passagem de outras, utilizam-se filtros, que são sistemas lineares e invariantes no tempo (LTI). A filtragem não consiste em um corte abrupto ou binário do espectro, mas sim em uma modificação contínua onde os componentes indesejados são submetidos a atenuadores que reduzem sua potência a níveis insignificantes, enquanto sua fase é deslocada. A topologia passa-baixas (Low-Pass Filter) permite a passagem de componentes espectrais situadas abaixo de uma frequência de corte definida, aplicando uma atenuação progressiva às frequências superiores, e atua obrigatoriamente como filtro *anti-aliasing* colocado imediatamente antes do amostrador analógico para remover frequências acima do limite de Nyquist, que define que para converter um sinal analógico em digital sem perda de informações, a frequência de amostragem deve ser no mínimo o dobro da maior frequência presente no sinal. Por outro lado, a topologia passa-altas

(High-Pass Filter) atenua componentes de baixa frequência localizadas aquém da frequência de corte, permitindo o fluxo das componentes superiores, sendo amplamente empregada na eliminação de ruídos de baixa frequência de natureza falsa, como o acoplamento da rede elétrica residencial de 60 Hz em equipamentos de áudio ou vibrações mecânicas subsônicas. Segundo Silva (2015) Devido ao seu desempenho, filtros digitais são muito utilizados para fazer a filtragem de sinais contínuos. Deste modo, os sinais são convertidos para o formato digital através da amostragem e quantização, processados num computador digital ou processador digital de sinais, e por fim, convertê-lo novamente para a forma contínua. A autora também adiciona que a filtragem de sinais é essencial para separar frequências de sons de interesse no âmbito da separação de sinais de áudio.

Recentemente, o refinamento dessas técnicas de filtragem digital e otimização de janelamento evoluiu para o processamento de sinais biomédicos e reconhecimento de padrões complexos, mitigando o vazamento espectral em análises de altíssima precisão dinâmica (ROUBHI et al, 2026). Infere-se, portanto, que a evolução dessas técnicas de tratamento de sinais desempenha um papel crucial na engenharia contemporânea. A engenharia de filtros digitais estabelece o padrão de sensibilidade e fidelidade exigido para a modernização de diagnósticos industriais e tecnológicos.

No domínio do processamento digital de sinais (DSP), as equações e os coeficientes dos filtros são frequentemente expressos em termos de frequências normalizadas para eliminar a dependência de valores absolutos em Hertz e tornar o algoritmo independente da taxa de amostragem do hardware. A frequência de corte normalizada (ω_c) é obtida pela razão entre a frequência de corte analógica (f_c) e a

frequência de Nyquist (f_n), de modo que a frequência de Nyquist é mapeada para a unidade (1) ou para π radianos por amostra, seguindo a formulação (PROAKIS; MANOLAKIS, 2007):

$$\omega_c = \frac{f_c}{f_n} = \frac{f_c}{f_s/2}$$

Matematicamente, a atuação do filtro sobre a Transformada Rápida de Fourier (FFT) que será explicada em breve, é regida pelo Teorema da Convolução. A filtragem no domínio do tempo equivale a uma multiplicação ponto a ponto no domínio da frequência entre a FFT do sinal de entrada $X(f)$ e a resposta em frequência do filtro $H(f)$, resultando no espectro filtrado $Y(f)$:

$$Y(f) = X(f) \cdot H(f)$$

Por essa razão, os fenômenos de distorção provocados pelas funções de janelamento, como o surgimento de lóbulos laterais e o consequente vazamento espectral (*spectral leakage*), também se manifestam no comportamento dos filtros digitais, especialmente os de Resposta ao Impulso Finita (FIR), cujo truncamento da série temporal exige a aplicação de janelas para suavizar a transição da banda de passagem para a banda de rejeição.

Em um estudo de caso prático operando com uma taxa de amostragem de 48 kHz, a frequência de Nyquist estabelecida é de 24 kHz. Se o projeto requer um filtro com corte em 12 kHz, o coeficiente de corte normalizado será calculado por:

$$\omega_c = \frac{12.000}{24.000} = 0,5$$

Este modelo matemático permite a portabilidade do algoritmo para diferentes arquiteturas de hardware, garantindo que o

comportamento dinâmico da atenuação e a integridade da FFT modificada permaneçam consistentes independentemente do sistema físico de implementação.

2.2. Técnicas de Janelamento

A análise computacional de sinais exige a manipulação de sequências de dados finitas por restrições de memória de armazenamento dos sistemas digitais, sendo essa partição viabilizada por meio da técnica chamada de janelamento (*windowing*). A Transformada Discreta de Fourier (DFT) e a Transformada Rápida de Fourier assumem que o bloco de dados analisado, de comprimento finito N , é periódico e se repete indefinidamente no tempo. Caso o início e o fim do bloco amostrado apresentem amplitudes distintas, ocorre uma descontinuidade temporal abrupta nas bordas do recorte que atua como um degrau matemático artificial. Após a realização da FFT, essa transição abrupta nas bordas introduz componentes de alta frequência artificiais no domínio da frequência, gerando o fenômeno conhecido como vazamento espectral (*spectral leakage*), caracterizado pela dispersão da energia de uma frequência central isolada para as caixas (*bins*) de frequências adjacentes, degradando severamente a seletividade e a precisão do sistema de análise. (HARRIS, 1978).


Para mitigar o vazamento espectral, o bloco de dados bruto $x[n]$ é multiplicado termo a termo por uma função de janela $w[n]$, cuja característica principal é apresentar ganho unitário no centro do intervalo e decaimento suave em direção a zero nas extremidades do sinal. A operação matemática é definida pela equação:

$$y[n] = x[n] \cdot w[n]$$

O resultado é um sinal janelado que força as extremidades do bloco a zero, o que atenua as discontinuidades nos pontos de emenda de corte do sinal e confina a energia espectral de forma mais precisa.

Dentro de um sinal janelado, existem picos de energia que são classificados em lobos principais e lobos secundários. Lobos principais, do inglês *main lobes*, se concentram nas regiões centrais do espectro de frequência onde a maior parte da energia do sinal está concentrada. No gráfico de análise espectral (FFT), o lobo principal é representado pelo pico mais alto e largo, cuja ponta indica a frequência exata da vibração ou do sinal que está sendo medido. A largura deste lobo define a resolução de frequência do sistema: quanto mais estreito ele for, maior é a capacidade de distinguir duas frequências que estejam muito próximas uma da outra. Em contrapartida, os lobos secundários ou *side lobes* são os picos menores que aparecem nas laterais do lobo principal. Eles não representam frequências reais do fenômeno físico, mas sim o resultado do vazamento espectral causado pelo corte do sinal no tempo vindo do janelamento.

Figura 1. Exemplo de lobos principais e secundários



Fonte: Researchgate

A altura desses lobos secundários em relação ao principal determina o nível de isolamento do filtro ou da janela utilizada: lobos secundários elevados significam que a energia vazou para as bandas vizinhas, o que pode mascarar ou esconder sinais reais de baixa amplitude que estejam próximos a um pico de grande intensidade. A aplicação de uma janela altera a largura do lobo principal e o nível dos lobos secundários no espectro de frequências, estabelecendo um *trade-off* em que a redução do vazamento espectral resulta no alargamento do lobo principal, o que degrada a resolução de frequência do sistema. A janela retangular realiza um corte seco e mantém excelente resolução de frequência devido ao seu lobo principal estreito, porém apresenta um péssimo isolamento de vazamento espectral por conta de seus lobos secundários elevados, sendo restrita a sinais transientes rápidos ou harmônicos exatos da taxa de amostragem. As janelas de Hann e Hamming utilizam curvas co-senoidais suaves em formato de sino que oferecem uma resolução moderada com baixo vazamento espectral, sendo a opção mais interessante disponível no mercado. Já a janela de Blackman aplica uma atenuação ainda mais agressiva nas extremidades, resultando em uma resolução de frequência reduzida com lobo principal largo, porém garantindo um vazamento espectral mínimo, ideal para a identificação de componentes de baixa amplitude próximas a sinais de forte intensidade (HARRIS, 1978). Desse modo, conclui-se que a escolha da janela ideal não deve ser arbitrária, mas sim guiada pela natureza do fenômeno monitorado. Enquanto sistemas de identificação de harmônicos próximos exigem alta resolução, com janelas mais estreitas, o rastreamento de falhas ocultas por ruído precisa de alto isolamento dinâmico e janelas com menores lobos secundários.

2.3. Transformada de Fourier

A partir do momento em que o sinal janelado está estruturado, o computador precisa traduzir essa informação para o domínio da frequência através de uma transformada. A Transformada Contínua de Fourier (FT), representa a teoria pura e perfeita. A essência desta transformada é projetar um sinal no domínio do tempo sobre uma base ortogonal de funções senoidais para determinar o conteúdo espectral (amplitude e fase).

A matemática dela cruza o sinal bruto com ondas de teste para descobrir quais frequências fazem parte daquela vibração. A formulação matemática dessa integral projeta o sinal original em um espectro contínuo:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-i2\pi ft} dt$$

Apesar de sua robustez teórica, a transformada contínua é computacionalmente impossível para aplicação em sistemas digitais, já que dispositivos computacionais operam exclusivamente com dados finitos, discretizados e limitados por restrições de memória de hardware.

Para viabilizar a análise espectral no ambiente discreto onde o sinal foi previamente amostrado e janelado, aplica-se a Transformada Discreta de Fourier (DFT). Essa abordagem consiste na discretização da transformada contínua, onde a variável de tempo contínuo é substituída por índices de amostragem discretos, enquanto a frequência contínua dá lugar a índices de frequência discretos chamados de *bins*. A integral analítica se converte em um somatório finito sobre o bloco de dados, conforme descrito pela equação:

$$x[k] = \sum_{n=0}^{N-1} x[n]e^{-i\pi \frac{2kn}{N}}$$

Onde N representa o número total de amostras contidas no bloco analisado e $x[n]$ constitui o vetor de dados amostrados e janelados obtido na prática. Cada *bin* de frequência k possui uma frequência real associada em Hertz, calculada pela relação entre o índice do *bin*, a taxa de amostragem do sistema e o número total de amostras. A mecânica desse algoritmo exige o cálculo do produto interno do vetor do sinal com o vetor da exponencial complexa para cada um dos índices de frequência. Essa estrutura impõe uma limitação severa relacionada ao tempo de processamento, já que o cálculo direto de cada um dos N *bins* requer a multiplicação e a varredura de todas as N amostras, resultando em uma ordem de complexidade algorítmica de $O(N^2)$ operações aritméticas, o que inviabiliza o processamento de grandes volumes de dados em tempo real.

A superação dessa limitação computacional ocorre por meio da implementação da Transformada Rápida de Fourier (FFT), que não altera os fundamentos matemáticos ou os resultados analíticos da DFT, mas atua estritamente como um algoritmo de otimização computacional para acelerar o processamento do bloco previamente preparado. A eficiência da FFT baseia-se na exploração das propriedades de periodicidade e simetria das exponenciais complexas, matematicamente definidas como fatores de giro ou *twiddle factors*:

$$W_N^n = e^{-j\frac{2\pi n}{N}}$$

Por meio de uma estratégia de divisão e conquista, o algoritmo decompõe sucessivamente a DFT de tamanho N em DFTs menores de sequências pares e ímpares, combinando os resultados subsequentes, o que exige, por restrição de projeto, que o tamanho do bloco N seja obrigatoriamente uma potência de base dois. Essa

reestruturação matemática reduz drasticamente a complexidade algorítmica do sistema. (COOLEY; TUKEY, 1965).

Em termos práticos de engenharia, para um bloco contendo 1024 amostras, o processamento direto via DFT demandaria aproximadamente 1.048.576 operações aritméticas, ao passo que o algoritmo da FFT soluciona a mesma equação utilizando cerca de 10.240 operações, conferindo o ganho de desempenho necessário para viabilizar o diagnóstico de falhas e a análise espectral em tempo real dentro de hardwares com restrições severas de consumo e processamento. Gustavo Bazan (2020) destaca que atualmente, no Brasil, existe um interesse crescente em aplicar técnicas de ensemble learning e redes neurais para interpretar dados de vibração via FFT. Esta tendência consolidou-se globalmente por meio de arquiteturas híbridas inteligentes; pesquisas de ponta combinam a Transformada Rápida de Fourier e a decomposição de sinais a algoritmos de aprendizado de máquina baseados em *Ensemble* e redes profundas, permitindo o diagnóstico automatizado e precoce de falhas estruturais sob severas variações de carga mecânica e ruído industrial (KUMAR et al, 2024). À luz dessas inovações, infere-se que a transição do cálculo quadrático para o quase-linear proporcionada pela FFT não foi apenas uma melhoria computacional de época, mas um marco habilitador que hoje ajuda no desenvolvimento da Inteligência Artificial e a análise preditiva na Indústria 4.0, tornando viável a extração instantânea de atributos espectrais para alimentar modelos de tomada de decisão automatizada.

2.4. Técnicas de Avaliação Qualitativa de Sinal

A avaliação da integridade dinâmica de um espectro de sinal a partir de dados de acelerometria exige metodologias capazes de transcender a mera inspeção visual dos gráficos de frequência. Para isso, é possível utilizar ferramentas quantitativas estatísticas para identificar, medir e validar de forma rigorosa as diferenças estruturais e energéticas que ocorrem no espectro de magnitude $X(k)$, obtido via Transformada Rápida de Fourier (FFT). Esses descritores estatísticos atuam mapeando matematicamente as alterações na distribuição de energia mecânica entre os componentes harmônicos e estocásticos do sistema (RANDALL, 2011). Assim, transformam variações visuais do espectro em dados numéricos precisos, capazes de discriminar quantitativamente o estado de operação do ativo sendo analisado. A primeira métrica fundamental neste domínio é a Média Espectral (μ_{spec}), que quantifica o valor central das magnitudes de aceleração distribuídas ao longo de todo o espectro de frequências analisado, sendo expressa matematicamente por:

$$\mu_{\text{spec}} = \frac{1}{M} \sum_{k=1}^M |x(k)|$$

Em termos de interpretação dinâmica aplicável à acelerometria, este parâmetro reflete o nível do piso de ruído espectral, caracterizado como o nível de fundo contínuo do gráfico resultante da Transformada Rápida de Fourier (FFT). Esse piso representa a soma de todas as energias não correlacionadas com a rotação da máquina, sendo composto por ruídos oriundos do próprio sensor acelerômetro, cabos e circuitos de digitalização (conversor A/D), além do ruído mecânico estocástico e aleatório, ou seja, dos ruídos indesejados (SINIRO, 2018). Sob condições operacionais normais, a energia vibratória de uma máquina rotativa não se distribui de forma aleatória, mas sim, manifesta-se de maneira contínua, sendo

gerada diretamente pelas forças cinemáticas dos componentes mecânicos em movimento (WOWK, 1991). As principais frequências que concentram essa energia compreendem a frequência de rotação da máquina, seus harmônicos superiores e as frequências de componentes específicos, o que atua mantendo a média espectral em níveis reduzidos (MOBLEY, 1999). Todavia, fenômenos de degradação generalizada por atrito severo, como a escassez de lubrificação, processos de cavitação em bombas hidráulicas ou o ruído branco de origem estrutural, elevam as amplitudes de forma difusa em bandas largas, provocando o incremento linear da média espectral (AL-GHAZAL, 2015).

Para a avaliação da intensidade efetiva da energia vibratória distribuída na frequência, segundo a norma ISO 20816-1:2016, utiliza-se o Valor Quadrático Médio Espectral (RMSspec), equacionado como:

$$\text{RMSpec} = \frac{1}{M} \sum_{k=1}^M |x(k)|^2$$

Respaldado pelo Teorema de Parseval, essa técnica valida a conservação de energia entre os domínios do tempo e da frequência, mostrando-se diretamente proporcional à raiz da potência total da vibração do ativo (OPPENHEIM; SCHAFER, 2010). A principal vantagem metodológica de sua aplicação no domínio da frequência reside na capacidade de cálculo em sub-bandas específicas. Essa propriedade viabiliza o monitoramento isolado da energia em faixas críticas e de interesse, tais como a banda de baixas frequências onde se manifestam desalinhamentos e desbalanceamentos, tipicamente situados entre 1× e 3× a rotação síncrona ou bandas de alta frequência que estejam associadas à

ressonância estrutural de componentes internos (ISO 10816-1, 1995; RAO, 2018).

Complementarmente, a Variância Espectral (σ_{spec}) é empregada para medir o grau de dispersão ou espalhamento das magnitudes das linhas de frequência em relação à média espectral, conforme a seguinte formulação:

$$\sigma_{\text{spec}} = \frac{1}{M} \sum_{k=1}^M (|x(k)| - \mu_{\text{spec}})^2$$

Este indicador atua como um índice de heterogeneidade do espectro, ou seja, quantifica o grau de disparidade entre as amplitudes das frequências, indicando o quanto elas diferem entre si, de modo que uma variância espectral reduzida aponta para um espectro homogêneo e plano, característica típica de assinaturas dominadas por ruído estocástico ou desgaste severo distribuído (ANTONI, 2006). Por outro lado, uma variância elevada mostra um espectro marcado pela presença de picos harmônicos que se sobressaem drasticamente ao piso de ruído. Essa sensibilidade à oscilação das amplitudes torna a variância uma ferramenta estatística fundamental para identificar o surgimento de frequências de falha bem definidas, com por exemplo, das frequências cinemáticas de rolamentos, como a frequência de passagem das esferas pela pista externa (BPFO), pista interna (BPFI) ou rotação dos elementos rolantes (BSF) (SHRIVASTAVA et al., 2021).

Por fim, o Fator de Crista Espectral (CFspec) define-se como a razão matemática entre a amplitude máxima absoluta registrada no espectro, correspondente ao pico espectral, e o seu valor efetivo global (RMSspec):

$$CF_{\text{spec}} = \frac{\max(|x(k)|)}{RMS_{\text{spec}}}$$

Enquanto no domínio temporal o fator de crista exibe alta sensibilidade a choques rápidos de curtíssima duração, no domínio da frequência ele quantifica a dominância de componentes harmônicos (DYER; STEWART, 1978). Ele indica se a energia do sinal está concentrada em uma única frequência principal ou se está distribuída de maneira simétrica pelo espectro. Desta forma, um valor elevado de CF_{spec} consolida-se como um forte indicador de anomalias que excitam componentes de alta magnitude, tais como o desbalanceamento dinâmico severo de rotores ou o acoplamento de frequências de engrenamento sob condições de sobrecarga localizada (NANDI, 2005).

A fim de fazer uma avaliação comparativa de fatores qualitativos de um sinal, é possível usar de métodos estatísticos a fim de comparar parâmetros extraídos do sinal, como variância e média (HAIR et al., 2019). O teste de Levene é um método estatístico usado para avaliar a igualdade de variâncias de uma variável calculada para dois ou mais grupos, esse teste testa a hipótese nula de que as variâncias populacionais são iguais, chamada homocedasticidade (LEVENE, 1960). Se o valor-p resultante do teste de Levene for menor que algum nível de significância definido, normalmente sendo 0,05, é improvável que as diferenças obtidas nas variâncias amostrais tenham ocorrido com base na amostragem aleatória de uma população com variâncias iguais. Assim, a hipótese nula é rejeitada e pode-se concluir que existe diferença entre as variâncias na população, e vice-versa.

A estatística de teste, W , é definida da seguinte forma:

$$W = \frac{\sum_{i=1}^{K^{**}} N_i (Z_i - \bar{Z} \dots)^2}{\sum_{i=1}^{K^{**}} \sum_{j=1}^{N_i^{**}} (Z_{ij} - Z_i)^2} \cdot \frac{N - k}{k - 1}$$

Onde k é o número de grupos diferentes aos quais os casos amostrados pertencem, N_i é o número de casos no i-ésimo grupo, N é o número total de casos em todos os grupos e Y_{ij} é o valor da variável medida para o j-ésimo caso do i-ésimo grupo. A variável transformada Z_{ij} pode ser calculada de duas formas a partir dos desvios absolutos: $Z_{ij} = |Y_{ij} - \bar{Y}_i|$, onde $\bar{Y}_i$ é a média do grupo i; ou $Z_{ij} = |Y_{ij} - Y_{\sim i}|$, onde $Y_{\sim i}$ é a mediana do grupo i (BROWN; FORSYTHE, 1974).

O teste de ANOVA é outra técnica estatística que pode ser usada para fins comparativos entre grupos, usado para comparar a média de três ou mais grupos e verificar se há diferenças significativas entre eles (MONTGOMERY, 2019). A hipótese nula (H_0) afirmaria que não há diferença significativa nas médias entre os grupos analisados, enquanto a hipótese alternativa (H_1) sugeriria o contrário. A estatística de teste da ANOVA, denotada por F, avalia a razão entre a variação entre os grupos e a variação dentro dos grupos, sendo calculada por:

$$F = \frac{\frac{\sum_{i=1}^{K^{**}} N_i (Y_i - \bar{Y} \dots)^2}{k - 1}}{\frac{\sum_{i=1}^{K^{**}} \sum_{j=1}^{N_i^{**}} (Y_{ij} - Y_i)^2}{N - k}}$$

Onde Y_i representa a média do i-ésimo grupo e $\bar{Y} \dots$ corresponde à média global de todas as observações combinadas. Da mesma forma que no teste de Levene, se o valor-p associado à estatística F for imenor que o nível de significância adotado de 0,05, rejeita-se a hipótese nula (H_0). Essa rejeição permite concluir que as médias de pelo menos dois grupos diferem significativamente entre si,

confirmando de forma estatística que as alterações observadas nos parâmetros do sinal são causadas pelas diferentes condições ou estados operacionais analisados.


Através de uma análise do espectro de um sinal de vibrações, é possível identificar e prever falhas que podem acontecer em diversos equipamentos, como o desalinhamento. Esse defeito acontece após o desvio dos centros coaxiais de rotação de dois ou mais eixos acoplados, fazendo com que as forças dinâmicas atuem fora do centro geométrico projetado para o sistema. No domínio da frequência, o desalinhamento se manifesta tipicamente por meio de picos de grande amplitude na frequência de rotação do eixo e, de forma muito característica, em seus harmônicos subsequentes, especialmente em e , ocasionalmente, $2e$. Desalinhamentos do tipo angular geram altas forças axiais e forte presença na frequência de rotação do eixo, já desalinhamentos paralelos induzem forças radiais dominantes em e . As relações de amplitude e fase entre essas componentes espectrais mudam de acordo com o tipo de desalinhamento presente, fornecendo uma assinatura de frequência clara para o diagnóstico precoce da severidade do problema antes que ocorra a fadiga dos acoplamentos ou danos severos aos rolamentos.

3. METODOLOGIA E RESULTADOS

Foi desenvolvido um código em Python capaz de processar o sinal demodulado por meio de técnicas de filtragem e janelamento, entregando resultados confiáveis e passíveis de diagnóstico. Gráficos comparativos foram gerados entre diferentes topologias de filtros e o sinal original no domínio do tempo, assim como gráficos dos diferentes filtros combinados a diferentes janelas, com amostras


tanto no domínio do tempo quanto na frequência. Por último, foram obtidas duas tabelas de informações qualitativas do sinal, uma contendo dados o erro RMS e outra contendo informações de média, variância e fator de crista de cada combinação. Após uma análise comparativa dos gráficos gerados e dados brutos tabelados, foi identificado uma performance superior da janela de hamming na supressão de ruídos no domínio da frequência e mitigação do vazamento espectral, seguido pela janela de Hann e de Blackman.

Figura 2. Resultados das comparações do efeito das janelas nos picos de frequência combinadas ao filtro Passa Banda - Eixo X




Fonte: Autoria própria

Figura 3. Resultados das comparações do efeito das janelas nos picos de frequência combinadas ao filtro Passa Banda - Eixo Y



Fonte: Autoria própria

Figura 4. Resultados das comparações do efeito das janelas nos picos de frequência combinadas ao filtro Passa Banda- Eixo Z



Fonte: Autoria própria

Como é possível ver nas figuras acima, a janela de Hamming possui um lóbulo principal relativamente estreito e consegue uma atenuação inicial muito rápida dos lóbulos secundários mais próximos. A janela de Hann possui um lobo principal com exatamente a mesma largura do lóbulo de Hamming, mas a atenuação do seu primeiro lóbulo lateral é menor, à medida que se afasta do pico principal, os lóbulos secundários da janela de Hann decaem muito mais rápido do que os de Hamming. Por último, a janela de Blackman apresentou a menor amplitude dentre todas, como o lóbulo principal é muito largo, a energia do pico de vibração foi distribuída sobre uma banda de frequência maior, o que reduziu a amplitude máxima do pico central.

Ao analisar os dados brutos, observou-se que a janela de Hamming apresentou a menor variância numérica entre as abordagens. Esta diferença de variabilidade foi confirmada estatisticamente pelo Teste de Levene ($p = 0.0000$). Embora pequenas oscilações numéricas tenham sido observadas entre as médias das amplitudes, a ANOVA de Welch indicou que não há diferença estatisticamente

significativa entre as médias ($p = 0.082$), demonstrando que os filtros alteraram a dispersão do sinal sem deslocar sua tendência central.

Além da menor variabilidade, a janela de Hamming também resultou no menor erro RMS. Em contrapartida, a janela de Blackman destacou-se por oferecer a menor média de amplitude e a menor variância residual entre as demais combinações.

Tabela 1. Resultados tabelados dos erros RMS no eixo X

	Eixo	Filtro	Janela	RMS_Error
0	X	Passa-Alta	Hamming	3.42
1	X	Passa-Alta	Hann	3.72
2	X	Passa-Alta	Blackman	4.13
3	X	Passa-Baixa	Hamming	6.01
4	X	Passa-Baixa	Hann	6.01
5	X	Passa-Baixa	Blackman	6.01
6	X	Passa-Banda	Hamming	6
7	X	Passa-Banda	Hann	6
8	X	Passa-Banda	Blackman	6

Fonte: Autoria própria

Tabela 2. Resultados dos cálculos de média variância e fator de crista no eixo X para as combinações de janela junto a topologia de filtro Passa Alta e para o sinal no domínio do tempo não janelado e não filtrado.

	Eixo	Filtro	Janela	Métrica	Valor
0	X	Original	Nenhuma	Fator de Crista	4.8
1	X	Original	Nenhuma	Média	0.0007
2	X	Original	Nenhuma	Variância	36
3	X	Passa-Alta	Blackman	Fator de Crista	7.9
4	X	Passa-Alta	Blackman	Média	-4.9e-07
5	X	Passa-Alta	Blackman	Variância	11
6	X	Passa-Alta	Hamming	Fator de Crista	6.9
7	X	Passa-Alta	Hamming	Média	-4.4e-05
8	X	Passa-Alta	Hamming	Variância	14
9	X	Passa-Alta	Hann	Fator de Crista	7.1
10	X	Passa-Alta	Hann	Média	-1.4e-06
11	X	Passa-Alta	Hann	Variância	13

Fonte: Autoria própria

Tabela 3. Resultados dos cálculos de média variância e fator de crista no eixo X para as combinações de janela junto a topologia de filtro Passa Baixa.

12	X	Passa-Baixa	Blackman	Fator de Crista	3.6
13	X	Passa-Baixa	Blackman	Média	-0.00047
14	X	Passa-Baixa	Blackman	Variância	0.00077
15	X	Passa-Baixa	Hamming	Fator de Crista	3.1
16	X	Passa-Baixa	Hamming	Média	-0.00075
17	X	Passa-Baixa	Hamming	Variância	0.001
18	X	Passa-Baixa	Hann	Fator de Crista	3.2
19	X	Passa-Baixa	Hann	Média	-0.00058
20	X	Passa-Baixa	Hann	Variância	0.00095

Fonte: Autoria própria

Tabela 4. Resultados dos cálculos de média variância e fator de crista no eixo X para as combinações de janela junto a topologia de filtro Passa Banda.

21	X	Passa-Banda	Blackman	Fator de Crista	3.5
22	X	Passa-Banda	Blackman	Média	-8.3e-07
23	X	Passa-Banda	Blackman	Variância	0.057
24	X	Passa-Banda	Hamming	Fator de Crista	3.1
25	X	Passa-Banda	Hamming	Média	0.0003
26	X	Passa-Banda	Hamming	Variância	0.075
27	X	Passa-Banda	Hann	Fator de Crista	3.2
28	X	Passa-Banda	Hann	Média	-2.3e-06
29	X	Passa-Banda	Hann	Variância	0.07

Fonte: Autoria própria

Foi possível através da análise da magnitude dos harmônicos do sinal, identificar um desalinhamento na bancada de estudo em que foram coletados os dados utilizados no estudo, se mostrando através de picos nos harmônicos de rotação da bancada no sinal.

4. CONCLUSÃO

O presente trabalho cumpriu com êxito o objetivo de desenvolver uma ferramenta em Python eficaz para o processamento e diagnóstico do sinal demodulado. A metodologia empregada, que combinou diferentes topologias de filtros e técnicas de janelamento, mostrou-se robusta e confiável tanto no domínio do tempo quanto no da frequência.

A análise comparativa e a validação estatística trouxeram respostas claras sobre o comportamento do sinal. A janela de Hamming destacou-se como a solução mais eficiente para a mitigação do vazamento espectral e atenuação de ruídos, apresentando também o menor erro RMS e a menor variância confirmada pelo Teste de Levene ($p < 0,0001$).

Essas diferenças de performance se deram devido às propriedades matemáticas de cada função de transferência no domínio da frequência e ao *trade-off* estabelecido entre a resolução espectral e

o vazamento de energia (*spectral leakage*). A janela de Hamming possui coeficientes otimizados para atenuar o primeiro lóbulo secundário por meio de interferência destrutiva. Em contrapartida, a janela de Hann decai exatamente a zero nas bordas do intervalo discreto. Essa suavização contínua confere-lhe um decaimento assintótico muito mais rápido. Por fim, a janela de Blackman adiciona um termo cosseno de segunda ordem à sua formulação, esta suavização extrema reduz o primeiro lóbulo secundário mas expande fisicamente a largura do lóbulo principal, fazendo com que a energia espectral fosse dispersada por uma banda maior, reduzindo a amplitude máxima registrada nas frequências de desalinhamento.

A ANOVA de Welch ($p=0,082$) comprovou que as filtragens aplicadas conseguiram reduzir a dispersão e o ruído do sinal sem distorcer ou deslocar a sua média original. Por último, a janela de Blackman mostrou-se uma alternativa viável para cenários onde a minimização da média de amplitude e da variância residual seja a prioridade.

Em suma, os gráficos gerados e os dados brutos tabelados fornecem uma avaliação precisa e segura, sendo tal afirmação comprovada através do diagnóstico do desalinhamento na bancada de estudo utilizando os mesmos, validando o código desenvolvido como uma ferramenta de alta fidelidade para o processamento de sinais nas três coordenadas espaciais (Eixos X, Y e Z). Para trabalhos futuros, recomenda-se a aplicação desta mesma estrutura algorítmica em sinais com maiores taxas de ruído térmico para testar os limites de supressão das janelas analisadas.

REFERÊNCIAS BIBLIOGRÁFICAS

ANTONI, J. The spectral kurtosis: a useful tool for characterising non-stationary signals. **Mechanical Systems and Signal Processing**, v. 20, n. 2, p. 282-307, 2006. Disponível em: <https://doi.org/10.1016/j.ymssp.2004.07.001>. Acesso em: 22 jul. 2026.

BAZAN, G. **Análise de vibração aplicada ao diagnóstico de falhas em máquinas rotativas utilizando inteligência artificial**. Dissertação (Mestrado) – Universidade Federal, Brasil, 2020. Disponível em: <https://repositorio.ufsc.br/handle/123456789/215000>. Acesso em: 21 jul. 2026.

BROWN, M. B.; FORSYTHE, A. B. Robust tests for the equality of variances. **Journal of the American Statistical Association**, v. 69, n. 346, p. 364-367, 1974. Disponível em: <https://doi.org/10.1080/01621459.1974.10482955>. Acesso em: 24 jul. 2026.

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. Disponível em: <https://doi.org/10.1090/S0025-5718-1965-0178586-1>. Acesso em: 21 jul. 2026.

DYER, D.; STEWART, R. M. Detection of rolling element bearing damage by statistical vibration analysis. **Journal of Mechanical Design**, v. 100, n. 2, p. 229-235, 1978. Disponível em: <https://doi.org/10.1115/1.3453905>. Acesso em: 21 jul. 2026.

HAIR, J. F. et al. **Análise de dados multivariados**. 8. ed. Porto Alegre: Bookman, 2019.

HARRIS, F. J. On the use of windows for harmonic analysis with the discrete Fourier transform. **Proceedings of the IEEE**, v. 66, n. 1, p. 51-

83, 1978. Disponível em: <https://doi.org/10.1109/PROC.1978.10837>. Acesso em: 22 jul. 2026.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 10816-1:1995**: Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts — Part 1: General guidelines. Geneva: ISO, 1995.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 20816-1:2016**: Mechanical vibration — Measurement and evaluation of machine vibration — Part 1: General guidelines. Geneva: ISO, 2016.

KUMAR, A. et al. Ensemble learning and deep neural networks for advanced vibration signal diagnosis under severe industrial noise. **IEEE Transactions on Industrial Informatics**, v. 20, p. 112-125, 2024. Disponível em: <https://doi.org/10.1109/TII.2023.3285000>. Acesso em: 14 jul. 2026.

LEVENE, H. Robust tests for equality of variances. In: OLKIN, I. et al. (Ed.). **Contributions to Probability and Statistics**: Essays in Honor of Harold Hotelling. Stanford: Stanford University Press, 1960. p. 278-292.

LIU, Z. et al. Adaptive filtering algorithm for vibration signal processing under dynamic speed conditions. **Mechanical Systems and Signal Processing**, v. 208, p. 104-118, 2024. Disponível em: <https://doi.org/10.1016/j.ymssp.2023.110900>. Acesso em: 17 jul. 2026.

LV, Y. et al. Vibration signal-based early fault prognosis: status quo and applications. **Advanced Engineering Informatics**, v. 52, art. no. 101609, 2022. Disponível em: <https://doi.org/10.1016/j.aei.2022.101609>. Acesso em: 15 jul. 2026.

MOBLEY, R. K. **Root Cause Failure Analysis**. Boston: Butterworth-Heinemann, 1999.

MONTGOMERY, D. C. **Design and Analysis of Experiments**. 10. ed. New York: John Wiley & Sons, 2019.

NANDI, S. Detection of rotor faults in induction machines using spectral analysis. **IEEE Transactions on Industry Applications**, v. 41, n. 1, p. 203-211, 2005. Disponível em: <https://doi.org/10.1109/TIA.2004.840972>. Acesso em: 11 jul. 2026.

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

PROAKIS, J. G.; MANOLAKIS, D. G. **Digital Signal Processing: Principles, Algorithms, and Applications**. 4. ed. Upper Saddle River: Pearson Prentice Hall, 2007.

RANDALL, R. B. **Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications**. Chichester: John Wiley & Sons, 2011.

RAO, S. S. **Mechanical Vibrations**. 6. ed. Boston: Pearson, 2018.

ROUBHI, A. et al. Advanced Digital Filtering and Windowing Optimization for Biomedical and Pattern Recognition Applications. **Journal of Signal Processing Systems**, v. 98, p. 45-59, 2026. Disponível em: <https://doi.org/10.1007/s11265-025-01900-x>. Acesso em: 21 jul. 2026.

SHRIVASTAVA, S. et al. Vibration signature analysis for bearing fault diagnosis using statistical features. **Journal of Failure Analysis and**

Prevention, v. 21, n. 4, p. 1245-1258, 2021. Disponível em: <https://doi.org/10.1007/s11668-021-01180-3>. Acesso em: 22 jul. 2026.

SILVA, M. **Processamento Digital de Sinais: Teoria e Aplicações**. São Paulo: Editora Blucher, 2015.

SINIRO, F. Metodologias de calibração e análise de ruído em acelerômetros industriais. **Revista Brasileira de Metrologia**, v. 12, n. 2, p. 89-102, 2018. Disponível em: <https://www.rbmetrologia.org.br/artigo/v12n2/89-102.pdf>. Acesso em: 21 jul. 2026.

WOWK, V. **Machinery Vibration: Measurement and Analysis**. New York: McGraw-Hill, 1991.

ZHANG, Y. et al. Adaptive machine learning-based filtering for dynamic noise mitigation in industrial sensors. **IEEE Sensors Journal**, v. 23, n. 14, p. 15680-15692, 2023. Disponível em: <https://doi.org/10.1109/JSEN.2023.3280000>. Acesso em: 15 jul. 2026.

¹ Discente do Curso Superior de engenharia mecânica da universidade Federal de São João Del Rey Campus Santo Antônio. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Doutor em Engenharia Mecânica da Universidade Estadual de Campinas. E-mail: [acesse o artigo original para visualizar o e-mail](#)