

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA - CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE ELETROTÉCNICA
CURSO SUPERIOR DE ENGENHARIA ELÉTRICA**

GUSTAVO DE CARVALHO ESTÁCIO

**ESTIMATIVA DE VIDA REMANESCENTE DE ROLAMENTOS DE ALTA
ROTAÇÃO EM AEROGERADORES A PARTIR DE SÉRIES
TEMPORAIS DE VIBRAÇÃO MECÂNICA**

FLORIANÓPOLIS, 2025.

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA - CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE ELETROTÉCNICA
CURSO SUPERIOR DE ENGENHARIA ELÉTRICA**

GUSTAVO DE CARVALHO ESTÁCIO

**ESTIMATIVA DE VIDA REMANESCENTE DE ROLAMENTOS DE ALTA
ROTAÇÃO EM AEROGERADORES A PARTIR DE SÉRIES
TEMPORAIS DE VIBRAÇÃO MECÂNICA**

Trabalho de Conclusão de Curso
submetido ao Instituto Federal de
Educação, Ciência e Tecnologia de Santa
Catarina como parte dos requisitos para
aprovação na unidade curricular
TCC22009.

Orientador:
Prof. Sérgio Luciano Ávila, Dr. Eng.

FLORIANÓPOLIS, 2025.

RESUMO

A expansão da geração de energia elétrica de origem eólica, aliada à crescente complexidade dos aerogeradores, demanda o desenvolvimento de estratégias avançadas de Operação e Manutenção (O&M) para garantir maior disponibilidade dos equipamentos e reduzir os custos operacionais. Neste contexto, a estimativa de falhas em componentes críticos, como os rolamentos de alta velocidade da caixa de transmissão, torna-se fundamental para a manutenção. Este trabalho propõe uma metodologia baseada na análise de séries temporais de vibração mecânica para estimar a vida útil remanescente (RUL) desses rolamentos. A investigação é fundamentada num conjunto de dados, abrangendo etapas desde o pré-processamento dos sinais até a modelagem da degradação. A metodologia inclui a extração e seleção de características nos domínios do tempo e da frequência, com critérios baseados em monotonicidade, além da redução dimensional por meio da Análise de Componentes Principais (PCA). Para a estimativa do RUL, adotou-se um modelo de degradação exponencial aplicado ao indicador de saúde (HI) derivado. Os resultados evidenciam que métricas impulsivas, como a Curtose Espectral combinada com análise de tendência, permitem a detecção antecipada de falhas, enquanto a validação pelo critério α - λ confirma a robustez da abordagem para suporte a decisões de manutenção e redução de paradas não planejadas.

Palavras-chave: Aerogeradores. Análise de Vibração. Estimativa de falhas. Vida Útil Remanescente. Manutenção. Séries Temporais.

ABSTRACT

This work addresses the growing need for advanced Operation and Maintenance (O&M) strategies in wind energy systems due to increasing complexity and data availability. A methodology is proposed for fault prognosis of high-speed shaft bearings in wind turbine gearboxes, using mechanical vibration time series. The study utilizes a dataset, covering signal preprocessing, feature extraction in time and frequency domains, feature selection based on monotonicity, and dimensionality reduction via Principal Component Analysis (PCA). An exponential degradation model is applied to a health indicator for Remaining Useful Life (RUL) estimation. Results show that impulsive metrics, such as spectral kurtosis combined with trend analysis, allow early fault detection. Model validation using the α - λ metric confirms the approach's effectiveness, supporting predictive maintenance decisions and reducing unplanned downtime.

Keywords: Wind Turbines. Vibration Analysis. Fault Prognostics. Remaining Useful Life. Maintenance. Time Series.

ESTIMATIVA DE VIDA REMANESCENTE DE ROLAMENTOS DE ALTA ROTAÇÃO EM AEROGERADORES A PARTIR DE SÉRIES TEMPORAIS DE VIBRAÇÃO MECÂNICA

GUSTAVO DE CARVALHO ESTÁCIO

Este trabalho foi julgado adequado para obtenção do título de Engenheiro(a) Eletricista e aprovado na sua forma final pela banca examinadora do Curso de Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

Florianópolis, 15 de dezembro de 2025.

Banca Examinadora:

Sérgio Luciano Ávila, D. Eng.

Juliano Bitencourt Padilha, D. Eng.

Leandro de Medeiros Sebastião, Me. Eng.

Ficha de identificação da obra elaborada pelo autor.

Estácio, Gustavo

ESTIMATIVA DE VIDA REMANESCENTE DE ROLAMENTOS DE ALTA ROTAÇÃO EM AEROGERADORES A PARTIR DE SÉRIES TEMPORAIS DE VIBRAÇÃO MECÂNICA / Gustavo Estácio; orientação de Sérgio Avila. - Florianópolis, SC, 2026.

59 p.

Trabalho de Conclusão de Curso (TCC) - Instituto Federal de Santa Catarina, Câmpus Florianópolis. Bacharelado em Engenharia Elétrica. Departamento Acadêmico de Eletrotécnica.

Inclui Referências.

1. Aerogeradores. 2. Análise de Vibração. 3. Estimativa de falhas. 4. Vida Útil Remanescente. 5. Séries Temporais. I. Avila, Sérgio. II. Instituto Federal de Santa Catarina. III. ESTIMATIVA DE VIDA REMANESCENTE DE ROLAMENTOS DE ALTA ROTAÇÃO EM AEROGERADORES A PARTIR DE SÉRIES TEMPORAIS DE VIBRAÇÃO MECÂNICA.

LISTA DE FIGURAS

Figura 1 - Visualização dos componentes de um aerogerador <i>onshore</i> .	9
Figura 2 - Relação de número de falhas e desligamento de Aerogeradores	10
Figura 3 - Aerogeradores <i>gearbox</i> e acionamento direto simplificados	15
Figura 4 - Componentes da caixa de transmissão (<i>gearbox</i>) de um aerogerador	16
Figura 5 - Vista explodida de um rolamento de elementos rolantes	16
Figura 6 - Curva S (relação da potência gerada e velocidade do vento)	17
Figura 7 - Processo completo de análise de vibração: aquisição de sinais, condicionamento e modelagem preditiva	18
Figura 8 - Localização dos sensores de vibração no conjunto <i>gearbox</i> -gerador	18
Figura 9 - Fotografias das posições de instrumentação do conjunto <i>gearbox</i> -gerador (AN1-AN12)	19
Figura 10 - Integração entre sensores físicos, modelos virtuais e planejamento de manutenção	20
Figura 11 - Sinais brutos, no domínio do tempo, de vibração numa <i>gearbox</i>	
Figura 12 - Sinais brutos, no domínio da frequência, de vibração numa <i>gearbox</i>	21
Figura 13 - Comparação de FFT com WPT	22
Figura 14 - Processo de filtragem, retificação e análise espectral aplicado aos sinais de vibração	23
Figura 15 - Evolução de estratégias de manutenção ao longo do tempo	24
Figura 16 - Prognóstico proposto para identificação de falhas em rolamentos	25
Figura 17 - Comportamento da taxa de falhas: período inicial, vida útil e desgaste	27
Figura 18 - Visualização no domínio do tempo do conjunto de dados	39
Figura 19 - Visualização no domínio da frequência do conjunto de dados no dia 1	40
Figura 21 - Visualização tridimensional domínio da frequência durante o período de operação	41
Figura 22 - Evolução da degradação em dados brutos	44
Figura 23 - Monotonicidade das características	45
Figura 24 - Indicadores de saúde da máquina	46
Figura 25 - Modelo de degradação dos dias 21 e 30	47
Figura 26 - Gráfico α - λ	49

LISTA DE TABELAS

Tabela 1 - Rótulos e posições de sensores de vibração apresentados na Figura 8	
Tabela 2 - Características e suas definições	28
Tabela 3 - Disposição das medidas de vibração e tacômetro da máquina	34
Tabela 4 - Fórmula das características extraídas	35
Tabela 5 - Indicadores extraídos no primeiro e último dia de operação	42

LISTA DE ABREVIATURAS E SIGLAS

O&M	Operação e Manutenção
SCADA	<i>Supervisory Control and Data Acquisition</i> (Supervisão, Controle e Aquisição de Dados)
CMS	<i>Condition Monitoring System</i> (Monitoramento da condição do sistema)
RMS	<i>Root Mean Square</i> (Valor eficaz)
WPT	<i>Wavelet Packet Transform</i> (Transformada de Pacotes de <i>Wavelets</i>)
FFT	<i>Fast Fourier Transform</i> (Transformada Rápida de Fourier)
RUL	<i>Remaining Useful Life</i> (Estimativa da Vida Remanescente)
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
HI	<i>Health Indicator</i> (Indicador de Saúde)

SUMÁRIO

1 INTRODUÇÃO.....	8
1.1 Justificativa.....	10
1.2 Definição do problema.....	12
1.3 Objetivo geral.....	12
1.4 Objetivos específicos.....	13
1.5 Estrutura do trabalho.....	13
2 FUNDAMENTAÇÃO TEÓRICA.....	14
2.1 Aerogeradores.....	15
2.2 Estratégias de manutenção e monitoramento de condição.....	18
2.3 Séries temporais e comportamento dinâmico de aerogeradores.....	23
2.4 Estimativa de vida remanescente.....	26
2.5 Identificação de anomalias em sinais de vibração em aerogeradores....	29
2.6 Indicadores no domínio do tempo e frequência.....	32
2.7 <i>Fusão de características e métrica α-λ</i>	33
2.8 Modelo de degradação.....	34
3 DADOS E METODOLOGIA.....	36
3.1 Estrutura geral da metodologia.....	36
3.1.1 Conjunto de dados e aquisição das características.....	37
3.1.2 Pré-processamento dos sinais.....	38
3.1.3 Seleção da métrica representativa de degradação.....	39
3.1.4 Transformação final do Indicador de saúde.....	40
3.1.5 Ajuste no modelo de degradação.....	40
3.1.6 Avaliação da qualidade de prognóstico.....	40
3.1.7 Limitações e considerações do conjunto de dados.....	41
4 RESULTADOS E ANÁLISES.....	42
4.1 Visualização do conjunto de dados.....	42
4.2 Indicadores.....	44
4.3 Processamento dos sinais.....	45
4.4 Seleção de características.....	47
4.5 Seleção de dados para treinamento.....	48
4.6 Redução de dimensão e fusão de características.....	48
4.7 Ajuste de modelos de degradação exponencial para RUL.....	49
4.8 Análise de desempenho.....	50
5 CONCLUSÃO.....	52
5.1 Trabalhos futuros.....	52
REFERÊNCIAS.....	54

1 INTRODUÇÃO


A crescente demanda por energia elétrica, somada à preocupação com os impactos ambientais decorrentes da queima de combustíveis fósseis, reforça a necessidade de uma transição da matriz energética para fontes mais sustentáveis. As fontes renováveis ganham destaque nesse cenário, pois oferecem alternativas capazes de atender às necessidades globais ao mesmo tempo em que preservam os recursos naturais. Entre elas, a conversão eletromecânica a partir da energia eólica se sobressai como uma das opções mais promissoras, tanto pela abundância desse recurso em diversas regiões do planeta quanto pela sua contribuição para a redução da emissão de gases poluentes (WOJTASZEK et al., 2025).

De acordo com Badihi et al. (2022), o avanço tecnológico dos aerogeradores, assim como o aprimoramento dos sistemas de monitoramento, vem tornando a geração de energia elétrica de origem eólica cada vez mais eficiente e sustentável. A redução dos custos de instalação e operação é decisiva para consolidar essa tecnologia como uma alternativa viável, favorecendo sua maior participação na matriz energética. A combinação dos indicadores econômicos e ambientais tornam a energia de origem eólica um dos principais elementos na transição energética, direcionando para uma economia de baixo carbono e um futuro energético mais sustentável (Orsted, 2022). O Brasil encontra-se entre os 10 países que mais investem nessa geração de energia em projeções da próxima década (GWEC, 2024). O contexto da matriz energética brasileira acompanha essa tendência de expansão em fontes renováveis. O país dispõe de características geográficas e climáticas favoráveis a geração de energia eólica, destaque principal para as regiões litorâneas do Nordeste e Sul, onde ventos de maior constância e intensidade facilitam essa transmissão do potencial eólico (EPE, 2024).

Os aerogeradores ou turbinas eólicas são máquinas complexas que convertem a energia cinética do vento em energia elétrica através de elementos mecânicos e elétricos integrados. Estes componentes estão sujeitos a cargas dinâmicas e condições de intempéries severas, os maiores desafios deste tipo de geração. A Figura 1 apresenta uma construção possível de um aerogerador, aqui incluindo os principais componentes: pás, rotor, eixo principal, caixa de transmissão

(*gearbox*) e o gerador.

Figura 1 - Visualização dos componentes de um aerogerador *onshore*.



Fonte: Adaptado de Emexidis, 2024

A coleta de dados em grandes volumes e em tempo real se deve ao avanço tecnológico da digitalização de sistemas e da coleta de dados através de sensores instalados conforme normas ISO. Os sensores monitoram continuamente as variáveis de interesse, como por exemplo: temperatura, velocidade de rotação, torque, corrente elétrica e vibração mecânica. No caso específico de vibrações, a análise destes sinais demonstra eficácia para a detecção precoce de falhas em máquinas (BAGRI et al., 2024). Ao observar o comportamento dos sinais vibratórios, é possível identificar padrões de uma futura falha, estes sendo: degradação, desalinhamento, desbalanceamentos e outros fenômenos que precedem estas falhas mecânicas (ALMUTAIRI; SINHA, 2023). A análise dos sinais vibratórios insere desafios particulares dessa geração, as condições de operação por serem dinâmicas e por dependerem da velocidade e direção do vento, acabam tornando o comportamento vibratório extremamente variável e estocástico. Além disso, as estruturas mecânicas são de grande escala e os sensores encontram-se em diferentes regiões da máquina, dificultando a relação, sincronização e correlação das

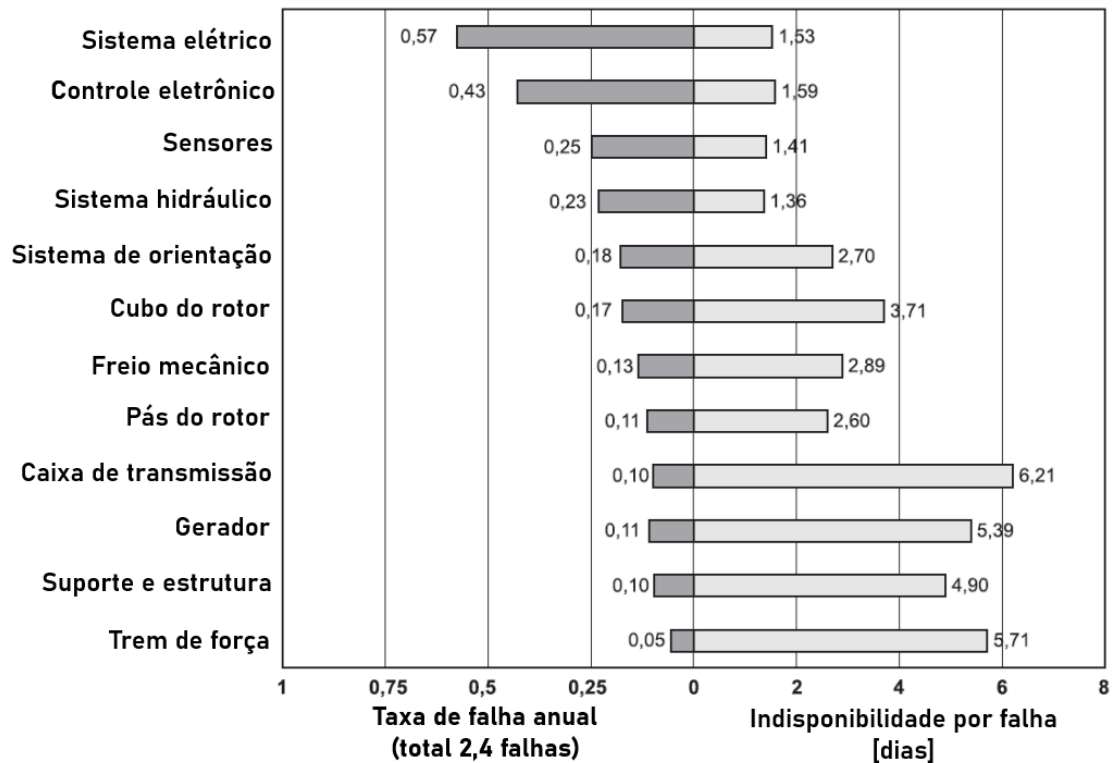
medidas apuradas (XIAO et al., 2020). Sendo assim, a análise das vibrações requer métodos de pré-processamento, filtragem e interpretação para que os dados extraídos sejam confiáveis e relevantes.

Este trabalho tem como objetivo estabelecer uma base metodológica para aplicar técnicas de estimativa a partir da análise temporal e de frequência dos sinais de vibração em aerogeradores. São discutidos procedimentos de tratamento de séries temporais, a extração de métricas e a avaliação de diferentes indicadores na detecção de falhas.

1.1 Justificativa

A crescente produção de energia de origem eólica na matriz elétrica reforça a importância de práticas de manutenção que garantam a confiabilidade e a disponibilidade dos aerogeradores. Os custos de operação e manutenção (O&M) podem representar entre 11% e 30% do custo total de geração ao longo da vida útil de um parque eólico (IRENA, 2012). De acordo com Sheng (2013), as falhas em aerogeradores apresentam comportamento altamente concentrado, em que apenas 25% das falhas são responsáveis por aproximadamente 95% do tempo total de máquina parada e o componente que maior apresenta tempo de não operação é a *gearbox* como indica a Figura 2.

Figura 2 - Relação de número de falhas e desligamento de Aero geradores



Fonte: Adaptado de BUDISETYAWAN et al. (2025).

O planejamento da manutenção surge como uma abordagem relevante para enfrentar esses desafios, utilizam-se dados de monitoramento para prever as falhas e otimizar o planejamento da manutenção, reduzindo custos e tempos de máquina parada inesperados (NUNES; SANTOS; ROCHA, 2023). Entre os métodos de monitoramento, a análise de vibração é amplamente utilizada por sua elevada sensibilidade à degradação mecânica (CAESARENDRA; TJAHJOWIDODO, 2017). Os sinais vibracionais permitem prever o defeito de 5 a 6 meses antes da ocorrência, enquanto a metodologia *Supervisory Control and Data Acquisition* (SCADA) normalmente indica o problema apenas cerca de um mês antes. Além disso, algoritmos baseados em vibração atingem acurácia muito próxima a 100%, superior aos métodos baseados apenas em SCADA (CASTELLANI et al., 2020). A análise das vibrações exige conhecimento multidisciplinar, envolvendo fundamentos de engenharia, processamento de sinais, estatística e ciência de dados. Métodos imprecisos ou extração de características irrelevantes podem levar à perda de informações decisivas ou até mesmo a interpretação equivocada de resultados.

O tema demonstra relevância conforme contexto brasileiro, considerando o investimento em energia de origem eólica e os planos futuros de expansão (EPE, 2024), assim como o crescente volume de estudos técnicos que abordam a análise temporal de vibrações (CHATTERJEE; DETHLEFS, 2021). Sendo assim, o trabalho justifica-se pela relevância técnica e regional, além do seu potencial de aplicação.

1.2 Definição do problema

Apesar do avanço e da abundância de dados oriundos dos sistemas SCADA e CMS, a análise de vibração enfrenta desafios significativos que comprometem sua eficácia no diagnóstico e prognóstico de falhas. As séries temporais exibem diferentes taxas de amostragem, contaminação por ruído estrutural e ausência de rotulagem clara das condições de saúde do componente ou de regimes de falha. A distribuição dos sensores em posições distintas da máquina resulta na captura de fenômenos mecânicos diferentes, o que dificulta a integração multissensorial e a correlação espectral dos sinais. Neste contexto, o problema central investigado neste trabalho consiste em estabelecer um conjunto sistematizado de práticas para o tratamento, organização, extração de características e análise de séries temporais de vibração, de modo a permitir uma interpretação confiável do comportamento estrutural e apoiar métodos modernos de manutenção preditiva em aerogeradores.

1.3 Objetivo geral

Sistematizar e aplicar um conjunto de boas práticas para o tratamento, a transformação e a análise de séries temporais de vibração mecânica de rolamentos de alta rotação de aerogeradores, com o propósito de aprimorar o monitoramento de condição e fornecer subsídios para técnicas de diagnóstico e estimativa de vida remanescente útil. Este trabalho foca o estudo do banco de dados público *Wind Turbine High-Speed Bearing Prognosis Data*, disponibilizado pela MathWorks (2018), conforme repositório oficial.

1.4 Objetivos específicos

Para atingir o objetivo geral, este trabalho propõe os seguintes objetivos específicos, os quais orientam a estrutura metodológica e norteiam as etapas de coleta, preparação e análise dos dados investigados:

- a) caracterizar o conjunto de dados de vibração utilizado, identificando particularidades das séries temporais quanto à frequência de amostragem, variabilidade operacional e fenômenos físicos associados;
- b) aplicar procedimentos adequados de pré-processamento, incluindo filtragem, remoção de tendência temporal dos sinais;
- c) realizar transformações nos domínios do tempo e da frequência, com ênfase na extração de indicadores estatísticos e espectrais relevantes para o monitoramento estrutural;
- d) investigar métricas capazes de evidenciar alterações de comportamento e identificar anomalias ou padrões iniciais de degradação mecânica;
- e) avaliar a eficácia do conjunto de técnicas adotadas na construção de um *pipeline* analítico compatível com aplicações futuras de manutenção preditiva e estimativa;
- f) consolidar diretrizes metodológicas que possam ser replicadas ou adaptadas para outros contextos de estimativa de vida útil em máquinas rotativas.

1.5 Estrutura do trabalho

Este trabalho está organizado em cinco capítulos, estruturados de maneira a contextualizar o tema, fundamentar teoricamente a proposta, descrever o conjunto de dados utilizado, apresentar a metodologia de tratamento e análise aplicada, discutir os resultados obtidos e, por fim, sintetizar as contribuições alcançadas.

No Capítulo 1, apresenta-se a contextualização do tema, a justificativa, a definição do problema e os objetivos que orientam o estudo.

O Capítulo 2 reúne a fundamentação teórica necessária, abordando energia eólica, componentes de aerogeradores, estratégias de manutenção e monitoramento, comportamento de séries temporais, métodos de análise vibratória, detecção de anomalias e fundamentos de prognóstico.

No Capítulo 3, descreve-se o conjunto de dados analisados, incluindo origem, variáveis disponíveis, formato dos registros, características de amostragem e limitações operacionais.

No Capítulo 4, são apresentados e discutidos os resultados obtidos a partir das técnicas aplicadas, com ênfase na interpretação dos sinais, no desempenho dos indicadores e na estimativa de vida útil restante.

Por fim, o Capítulo 5 apresenta as conclusões gerais, as contribuições do estudo, suas limitações e sugestões de trabalhos futuros voltados ao aprimoramento de prognóstico e manutenção preditiva em aerogeradores.

2 FUNDAMENTAÇÃO TEÓRICA

O aumento de investimentos em parques eólicos amplia a necessidade de garantir a disponibilidade dos aerogeradores, estes que operam em ambientes de intempéries e cargas dinâmicas. Nesse contexto, a engenharia de manutenção assume papel essencial através de um melhor planejamento da manutenção dessas máquinas para garantir o alto padrão de disponibilidade, em média, de 91% para *onshore* e 88,3% para *offshore* (PFAFFEL et al. 2017). Entre as técnicas avançadas de monitoramento baseado em dados, a análise vibratória em séries temporais destaca-se não apenas como uma prática recomendada, mas como uma necessidade operacional para assegurar a confiabilidade dos sistemas eólicos modernos.

Diante desse contexto, este capítulo apresenta os principais fundamentos relacionados à operação e manutenção de aerogeradores, com foco nas práticas modernas de monitoramento, análise de sinais e técnicas de prognóstico aplicadas à detecção de falhas e estimativa de vida útil.

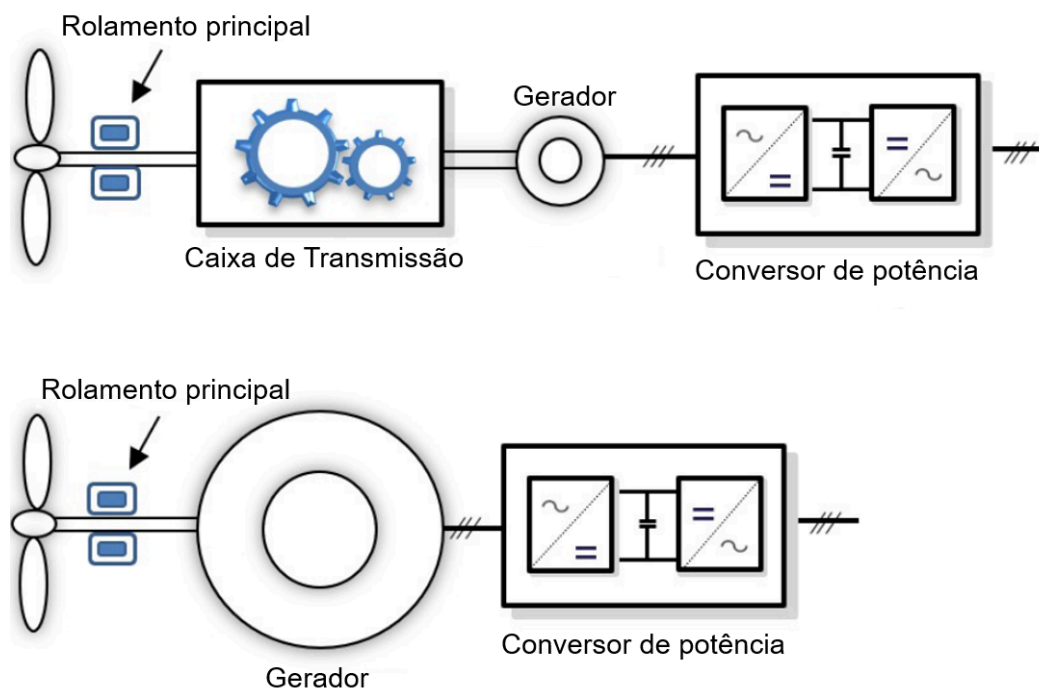
2.1 Aerogeradores

O aerogerador é uma máquina complexa, repleta de componentes elétricos e mecânicos. A nacele, que tem como objetivo principal a conversão da energia cinética do vento para energia elétrica, pode ser composta pelo rotor, eixo principal, rolamentos, acoplamentos, caixa de transmissão (*gearbox*) e um gerador. Apesar de existirem turbinas eólicas de acionamento direto que não necessitam da *gearbox*, o arranjo com *gearbox* é predominante no mercado devido à sua relação de custo-benefício e melhor acesso (NEJAD et al., 2022). A Figura 3 evidencia a diferença da geração entre os 2 tipos de aerogeradores utilizados em parques eólicos através de um esquema simplificado.

A principal diferença entre aerogeradores *onshore* e *offshore* está na velocidade de rotação das pás. Em alto-mar, os ventos são mais intensos e estáveis do que em terra firme, permitindo a adoção de rotores maiores que operam a menores rotações. Essa característica reduz a velocidade necessária para a geração

elétrica e possibilita a utilização de geradores de baixa rotação sem a necessidade de um *gearbox* (NEJAD et al., 2022).

Figura 3 - Aerogeradores *gearbox* e acionamento direto simplificados




Fonte: Adaptado de Nejad et al. (2022)

Em turbinas eólicas *onshore*, é comum a utilização de *gearbox* para converter a rotação lenta e o alto torque do rotor em uma velocidade adequada ao gerador, permitindo o uso de máquinas elétricas menores, mais leves e de menor custo. Sem essa conversão, o gerador precisaria ser significativamente maior, o que aumentaria o custo e o volume da turbina (MANWELL; MCGOWAN; ROGERS, 2010). A *gearbox* também é o componente que se identifica a maior concentração de falhas severas, isso se deve a sua complexidade mecânica e ao elevado número de elementos girantes como os rolamentos e eixos, que permanecem em movimento durante a operação do aerogerador (MENG et al., 2025).


Nas Figuras 4 e 5 são apresentados uma *gearbox* e um esquema dos rolamentos, estes que representam 76% das falhas de *gearbox* e gerador (STRÖMBERGSSON et al., 2020). Embora o custo de um rolamento individual seja relativamente baixo, cerca de US\$ 5.000, falhas não detectadas podem evoluir para intervenções que podem custar US\$ 250.000 ou mais, considerando substituição de *gearbox* e paradas prolongadas não esperadas (AIKIN, 2023).

Figura 4 - Componentes da caixa de transmissão (*gearbox*) de um aerogerador



Fonte: Adaptado de REZAMAND et al. (2020).

Figura 5 - Vista explodida de um rolamento de elementos rolantes

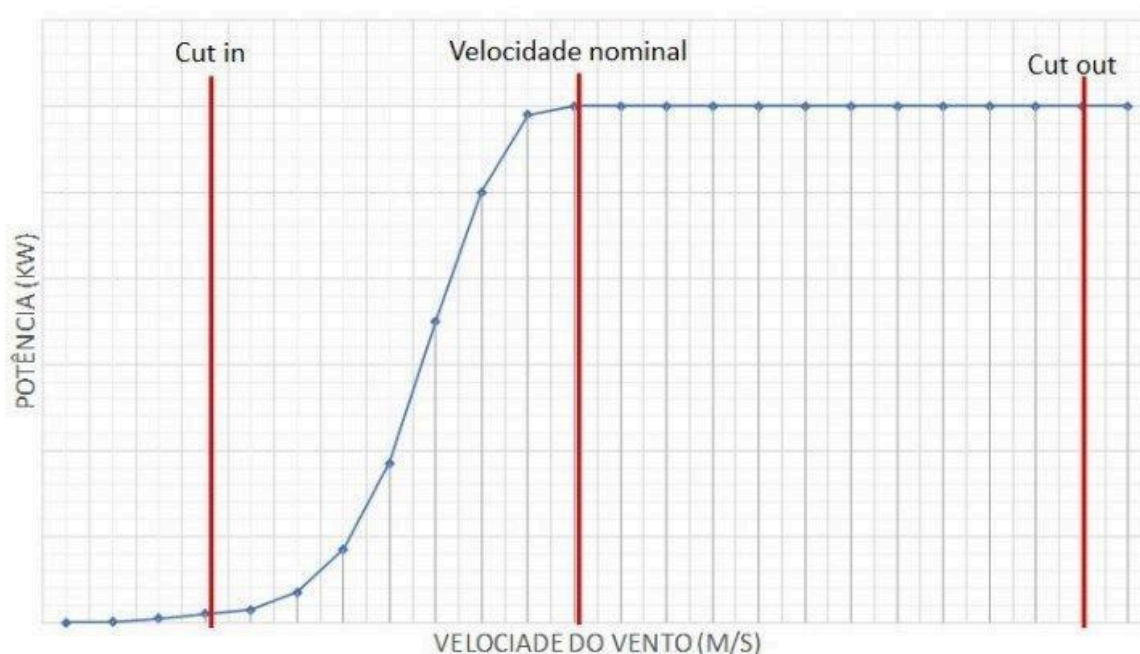


Fonte: Adaptado de REZAMAND et al. (2020).

Os aerogeradores são capazes de converter parte da energia cinética até um limiar máximo de potência, caso o limite de potência gerado pelo gerador for atingido, os freios da máquina acionam para que a velocidade de rotação excessiva não danifique os componentes da nacela. Essa correlação não linear entre a curva de geração de potência e velocidade do vento é denominada de Curva S (SILVA;

ABREU-HARBICH, 2017), que está representada na Figura 6. A atuação do aerogerador no limiar de potência é o mais desejado devido a maior conversão de energia, mas também segundo Escaler e Mebarki (2018), é o que mais gera oscilações nas vibrações mecânicas, estas que podem indicar dano na máquina caso estejam inadequadas durante a operação.

Figura 6 - Curva S (relação entre a velocidade do vento e potência gerada)



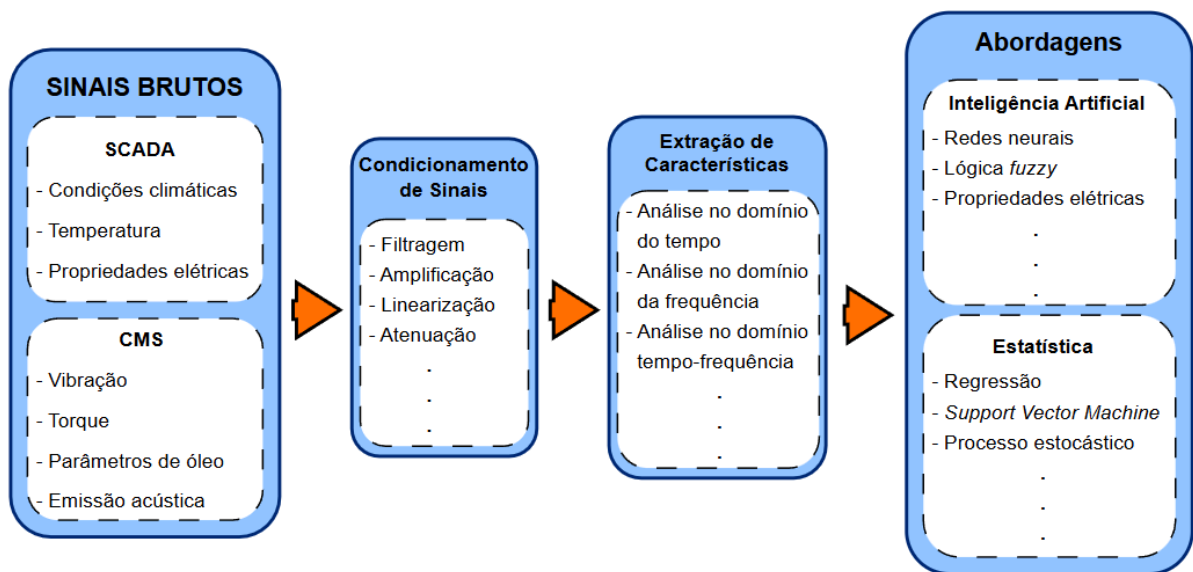
Fonte: SILVA; ABREU-HARBICH (2017).

2.2 Estratégias de manutenção e monitoramento de condição

O estudo de vibrações mecânicas oferece uma base teórica para compreender o comportamento dos aerogeradores. A vibração consiste em um movimento oscilatório dentro de um ponto de equilíbrio, que ocorre de forma livre ou forçada, com características lineares ou não lineares, sua intensidade depende das características estruturais do sistema (RAO, 2017). Nos aerogeradores, o ambiente de operação é variável devido às oscilações naturais da velocidade do vento, que induzem o torque e a variação de velocidade nas pás, resultando em sinais de vibração complexos e de diferentes frequências (SRIKANTH; SEKHAR, 2016). O monitoramento das vibrações em aerogeradores é realizado por meio de sensores instalados em pontos estratégicos, integrados a sistemas de *Condition Monitoring System* (CMS) e *Supervisory Control and Data Acquisition* (SCADA). A Figura 7

ilustra a combinação desses sistemas. Esses sistemas registram continuamente variáveis operacionais, como velocidade do vento, potência gerada, rotação, temperatura e níveis de vibração mecânica, permitindo o acompanhamento do desempenho da máquina em tempo real.


Figura 7 - Processo completo de análise de vibração: aquisição de sinais, condicionamento e modelagem preditiva



Fonte: Adaptado de BADIHI et al. (2022).

Como a análise proposta limita-se às variáveis de vibração obtidas por CMS durante a operação da turbina, é necessário aprofundar-se nos pontos de instrumentação convencionalmente adotados para detecção de falhas. Esses locais, amplamente aceitos na prática industrial (SHENG, 2012), são apresentados na Figura 8 e 9 abaixo com suas identificações explícitas na Tabela 1.

Figura 8 - Localização dos sensores de vibração no conjunto gearbox-gerador



Fonte: Adaptado de SHENG (2012).

Tabela 1 - Rótulos e posições de sensores de vibração apresentados na Figura 8

Rótulo do Sensor	Descrição
AN1	Mancal principal radial
AN2	Mancal principal axial
AN3	Engrenagem interna radial – Posição 6h
AN4	Engrenagem interna radial – Posição 12 h
AN5	Eixo de baixa rotação (LSS) radial
AN6	Eixo intermediário (ISS) radial
AN7	Eixo de alta rotação (HSS) radial
AN8	Mancal do HSS a montante radial
AN9	Mancal do HSS a jusante radial
AN10	Porta-satélite a jusante radial
AN11	Extremidade radial do Gerador
AN12	Extremidade não motora axial do Gerador

Fonte: SHENG (2012).

Figura 9 - Fotografias das posições de instrumentação do conjunto *gearbox*-gerador



a) AN1, AN2, AN3, e AN4



b) AN5, AN6, AN7, e AN8

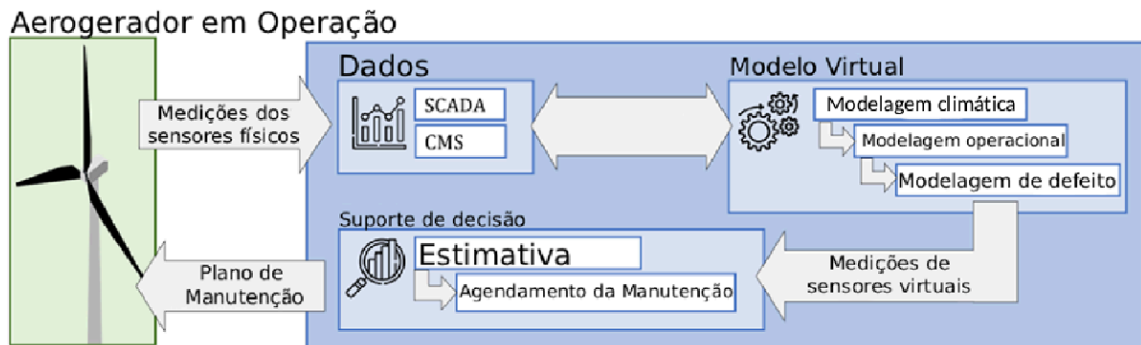


c) AN9, AN10, AN11, e AN12

Fonte: Adaptado de SHENG (2012).

De acordo com KUSIAK e LI (2011), os sistemas SCADA de turbinas eólicas registram dados operacionais em intervalos regulares de aproximadamente 10 minutos, gerando um volume significativo de informações ao longo do tempo. Esse grande conjunto de dados exige procedimentos adequados de pré-processamento, armazenamento e análise, a fim de viabilizar aplicações de diagnóstico e prognóstico de falhas e otimização da manutenção visto que os sinais apresentam comportamento aleatório e não linear. Um diagrama funcional apresentado na Figura 10 exemplifica a coleta de dados utilizando CMS e SCADA para a tomada de decisão.


Figura 10 - Integração entre sensores físicos, modelos virtuais e planejamento de manutenção



Fonte: Adaptado de ZIEGLER et al. (2023).

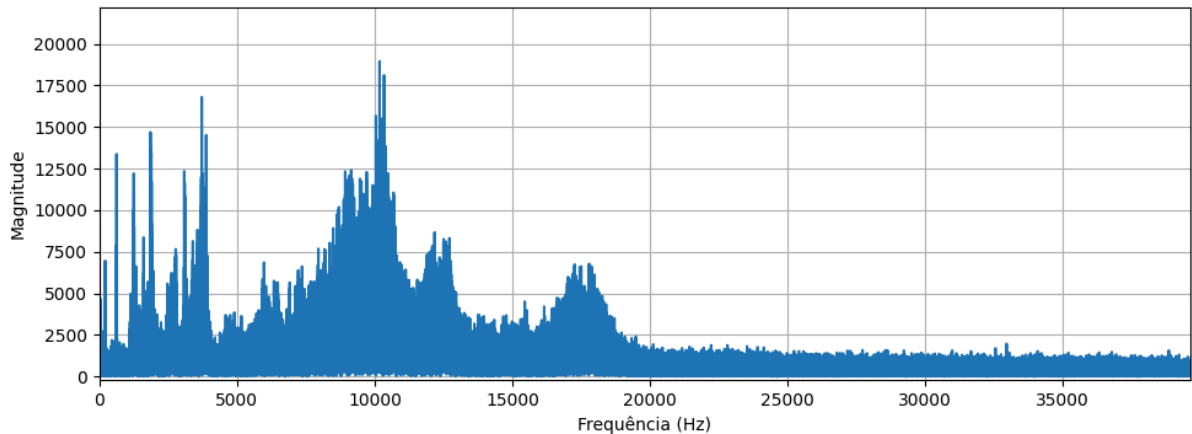
Dados obtidos por SCADA e CMS são geralmente dados climáticos, sinais de vibração e dados de operação do aerogerador, estes são fundamentais para caracterizar o comportamento estocástico do comportamento extraído da *gearbox*. A representação temporal permite observar a evolução do sinal, enquanto a análise da frequência destaca os componentes periódicos associados às características mecânicas da *gearbox* e dos mancais, como a vibração. As Figuras 11 e 12 apresenta exemplos do domínio do tempo e da frequência respectivamente, evidenciando como cada abordagem revela aspectos distintos do mesmo sinal.

Figura 11 - Sinais brutos, no domínio do tempo, de vibração numa *gearbox*



Fonte: Elaboração própria (2025).

Figura 12 - Sinais brutos, no domínio da frequência, de vibração numa *gearbox*



Fonte: Elaboração própria (2025).

2.3 Séries temporais e comportamento dinâmico de aerogeradores

Com os dados capturados é possível analisá-los através de séries temporais devido a sua observação de longo prazo na operação dos aerogeradores, estas séries temporais representam ruído, tendências, ciclos e mudanças abruptas no comportamento vibracional estocástico. Nas turbinas eólicas, essas séries temporais apresentam comportamento não estacionário, implicando na variação média e variância conforme o regime operacional (AVENDAÑO-VALENCIA; FASSOIS, 2014). A análise adequada exige técnicas capazes de lidar com essas variabilidades do sistema, isso é possível através de segmentação do tempo de estudo, transformadas espectrais e modelos de extração de características que representam um fenômeno físico e real que descreve uma possível falha na máquina.

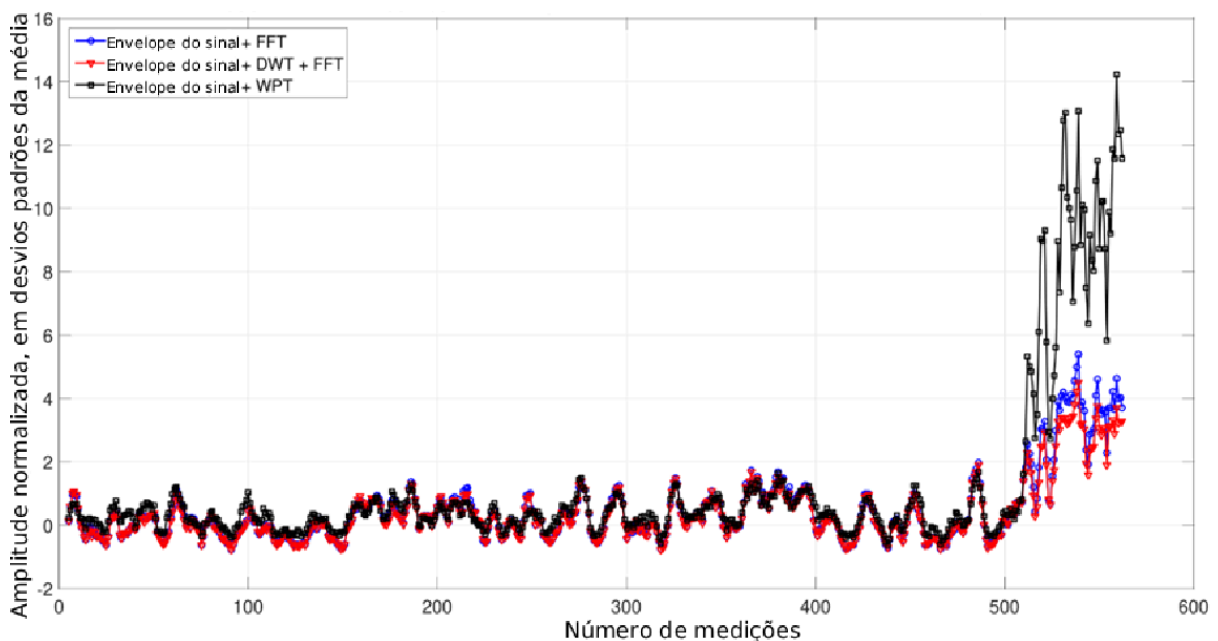
De acordo com Randall (2011), as análises dos sinais de vibração no domínio do tempo e da frequência devem ser utilizadas de forma complementar em máquinas rotativas. No domínio do tempo, indicadores como o valor eficaz (RMS) ou o valor de pico permitem detectar alterações de amplitude e transientes impulsivos; no domínio da frequência, é possível evidenciar assinaturas de falha como frequências harmônicas de rolamentos, engrenagens e mancais. Essa combinação de abordagens facilita o diagnóstico de falhas nestes componentes rotativos.

Ferramentas de análise nos domínios do tempo e da frequência são fundamentais para a caracterização do comportamento dinâmico de sistemas

rotativos e a detecção de possíveis falhas em seus componentes. No domínio do tempo, indicadores como o valor RMS, o valor de pico e a curtose permitem avaliar diretamente a evolução do sinal, possibilitando a identificação de comportamentos impulsivos característicos de defeitos mecânicos. Já no domínio da frequência, a aplicação da Transformada Rápida de Fourier (FFT) se destaca por possibilitar a identificação de picos espectrais associados a falhas em rolamentos, excitações harmônicas e passagens de dentes de engrenagens.

Métodos avançados de decomposição, como a Transformada Wavelet Packet (WPT), revelam-se particularmente eficazes em regimes operacionais complexos. Conforme Strömbergsson, Marklund e Berglund (2020), tanto a FFT quanto a WPT conseguem diagnosticar falhas quando estas emergem claramente no espectro de frequência. A FFT, contudo, sobressai pela baixa complexidade computacional, simplicidade de implementação e precisão na detecção de frequências características de defeitos. Por outro lado, embora demande maior custo computacional, a WPT oferece sensibilidade superior, identificando o defeito com mais que o dobro da amplitude normalizada em comparação à FFT e antecipando sua detecção em até quatro dias, conforme demonstrado na Figura 13.

Figura 13 - Comparação de FFT com WPT



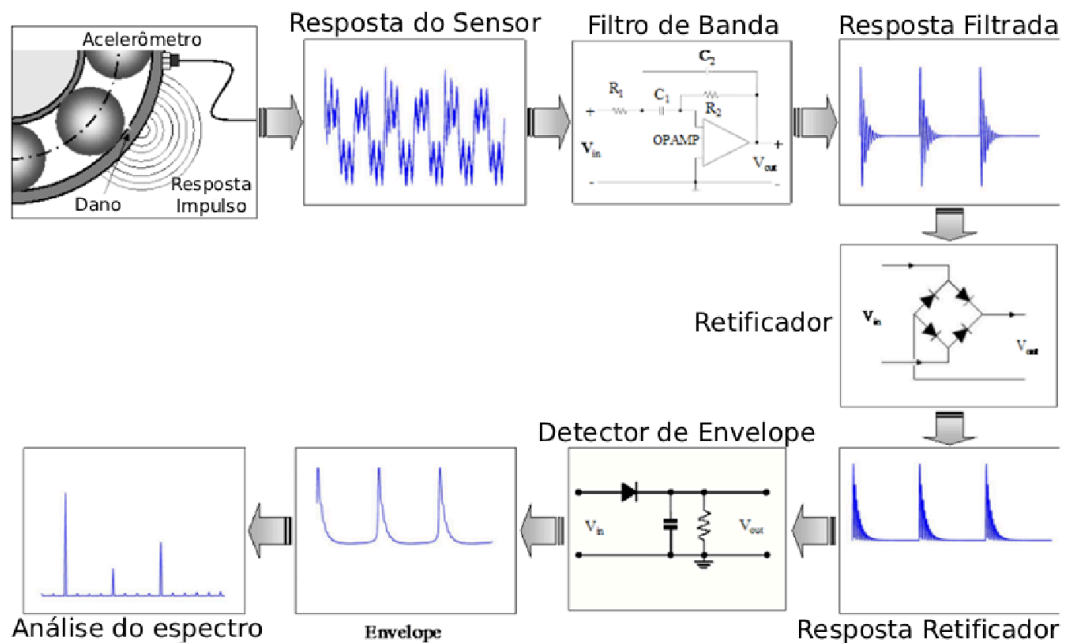
Fonte: Adaptado de STRÖMBERGSSON et al. (2020).

Para utilização do domínio do tempo e de frequência é necessário um tratamento prévio dos dados da série temporal assim como normalizações para facilitar a interpretação e adequação das informações coletadas da máquina. Em aerogeradores, esses métodos são essenciais para distinguir vibrações associadas à rotação do rotor, à *gearbox*, e fenômenos de operação normativa.

O pré-processamento dos sinais vibratórios busca remover componentes que não estão associados às assinaturas impulsivas de falhas. Ruídos de baixa frequência e tendências lentas podem elevar artificialmente a variância do sinal e mascarar eventos transitórios característicos de defeitos. Conforme demonstrado por Eftekharnjad et al. (2011), níveis elevados de ruído e componentes não relacionados à dinâmica impulsiva do defeito ocultam transientes e dificultam a identificação das assinaturas características em rolamentos.

A aplicação de filtros passa-alta também é necessária para remover vibrações estruturais de baixa frequência relacionadas à rotação lenta, balanço do rotor e cargas de vento, e realçar as faixas onde ocorrem as assinaturas de falha. Segundo Kim, Antoni e Lee (2013), a filtragem passa-alta eleva de forma significativa a relação sinal-ruído e aprimora a identificação de impulsos característicos no domínio da frequência. O processamento do sinal de vibração é melhor representado na Figura 14.

Figura 14 - Processo de filtragem e análise espectral aplicado aos sinais de vibração

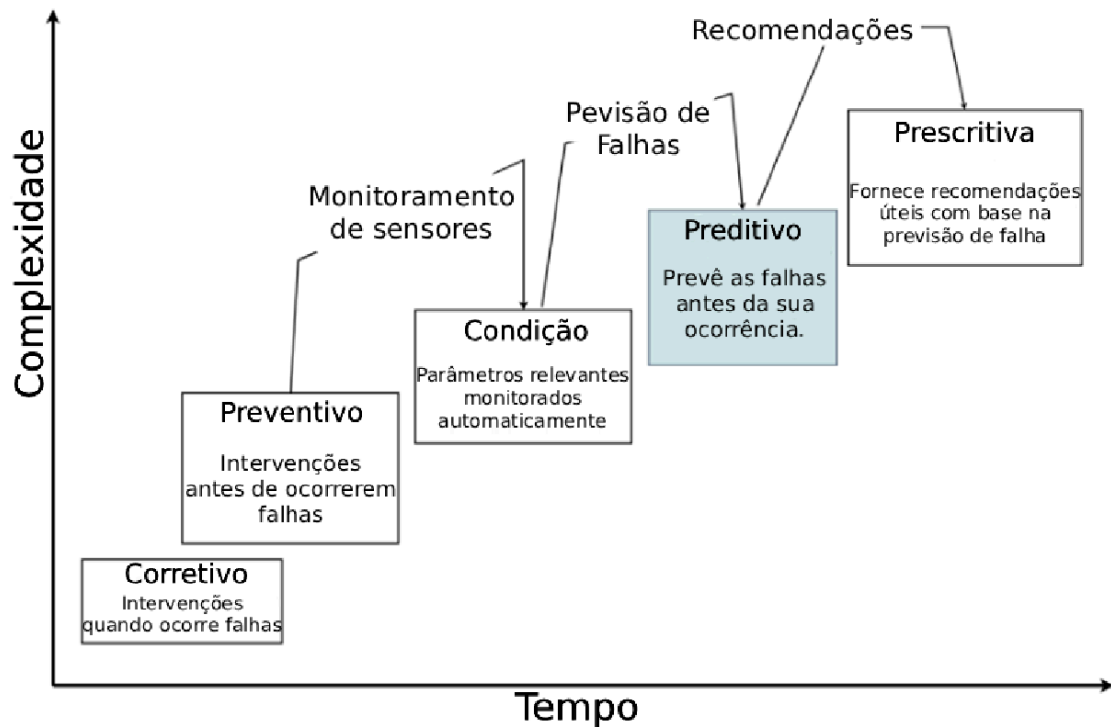


Fonte: Adaptado de SHENG (2012).

2.4 Estimativa de vida remanescente

No contexto eólico, o planejamento da manutenção torna-se particularmente relevante devido à dificuldade de acesso físico às máquinas, especialmente em parques *offshore*, e ao elevado custo logístico associado à mobilização de embarcações, equipes e infraestrutura de manutenção pesada. Conforme demonstrado por Hosseini et al. (2024), a complexidade operacional e os custos substancialmente maiores de O&M *offshore* tornam o uso de abordagens preditivas mais vantajoso do que estratégias corretivas ou preventivas convencionais. A Figura 15 mostra a linha do tempo da evolução da engenharia de manutenção.

Figura 15 - Evolução de estratégias de manutenção ao longo do tempo



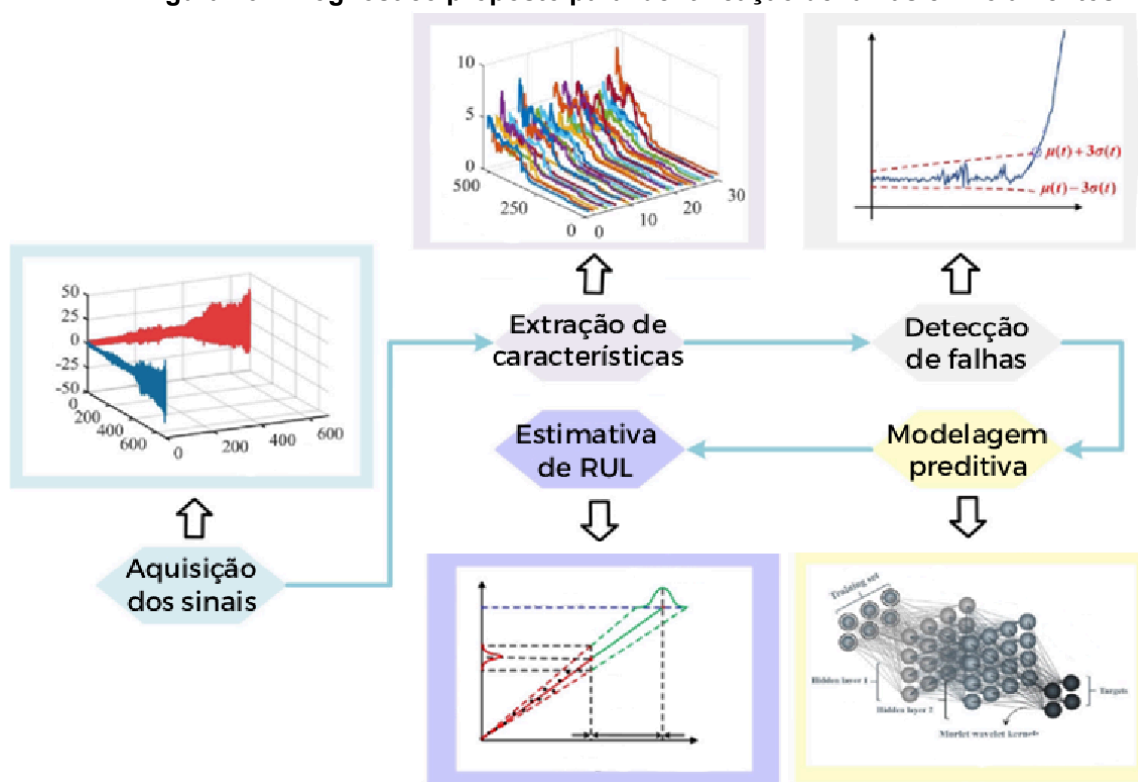
Fonte: Adaptado de NUNES; SANTOS; ROCHA (2023).

As normas internacionais consolidam critérios técnicos para o monitoramento de vibração e a avaliação da severidade em máquinas rotativas, incluindo turbinas eólicas, ISO (2017; 2018) e a IEC (2019). Nesse contexto, o prognóstico é entendido como a capacidade de estimar a evolução futura de um estado de degradação, uma extensão natural das práticas de monitoramento baseadas em vibração. De acordo com Rezamand et al. (2020) o prognóstico em aerogeradores depende da identificação de indicadores sensíveis ao dano, capazes de apresentar tendência monotônica ao longo do tempo, tal como valor RMS, curtose ou métricas derivadas de Curtose Espectral. Esses indicadores, quando organizados em séries temporais, permitem identificar o ponto de inflexão entre comportamento operacional estável, comportamento de degradação e estimativa de vida útil até a falha.

A estimativa da vida útil remanescente (RUL) pode ser realizada principalmente por meio de três categorias de métodos. A primeira delas inclui os modelos baseados em física, que buscam representar o comportamento real do componente utilizando leis de fadiga, modelos estruturais e equações que descrevem a evolução do dano ao longo do tempo. O segundo grupo reúne os

modelos baseados em dados, que utilizam informações históricas de operação e diferentes técnicas estatísticas ou de aprendizado de máquina, como regressão, análise de tendência, redes neurais ou modelos probabilísticos para identificar padrões de degradação nos sinais. Por fim, existem os modelos híbridos, que combinam elementos físicos com dados medidos, buscando equilibrar precisão e interpretação, conforme a Figura 16. Estudos recentes destacam que essa abordagem tende a ser mais robusta, especialmente em sistemas complexos como aerogeradores (Kestel et al., 2025; Rezamand et al., 2020).

Figura 16 - Prognóstico proposto para identificação de falhas em rolamentos



Fonte: Adaptado de WANG et al. (2022).

De acordo com Kestel et al. (2025), abordagens baseadas em dados tornam-se particularmente relevantes em aerogeradores devido à disponibilidade crescente de sinais de alta resolução provenientes de sensores de vibração e ao comportamento altamente não linear dos componentes, que frequentemente inviabiliza modelos puramente físicos.

Além disso, a evolução dos métodos de prognóstico acompanha a própria evolução das estratégias de manutenção propostas pelas normas IEC e ISO,

migrando de ações corretivas para preditivas baseadas em aprendizado de máquina. Esse avanço é ilustrado por *frameworks* que incluem detecção de anomalias, caracterização da tendência de degradação, previsão de estados futuros e cálculo probabilístico da vida útil remanescente.

No caso específico de rolamentos e eixos de alta rotação, a degradação manifesta-se inicialmente através de aumentos sutis no nível de impulsividade dos sinais de vibração, os quais podem ser capturados por métricas como a Curtose Espectral que servem como parâmetros de tendência. Demonstrado por Saïdi e Ali (2016), a espectral curtose pode funcionar como variável de tendência para diagnóstico de falhas em rolamentos em alta frequência (tipicamente entre 8 kHz e 12 kHz). Posteriormente, essa fase inicial evolui para detecções claras de picos impulsivos e, por fim, para um rápido crescimento dos indicadores, que proporcionam a base para RUL.

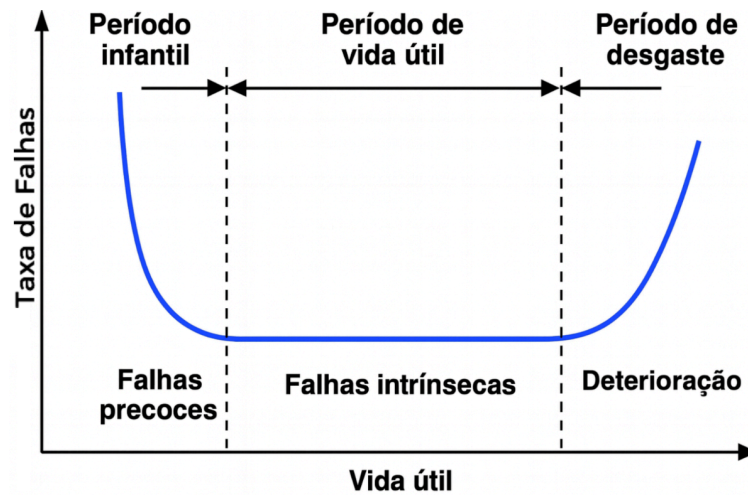
Assim, o prognóstico consolida-se como uma etapa essencial para maximizar a confiabilidade dos aerogeradores, oferecendo meios para planejar intervenções técnicas antes de falhas catastróficas, reduzir custos de O&M e prolongar a vida útil dos componentes críticos.

2.5 Identificação de anomalias em sinais de vibração em aerogeradores

A identificação de anomalias em sinais vibracionais em aerogeradores operacionais é essencial no contexto da manutenção baseada na predição de falhas. Em sistemas eólicos, anomalias aparecem de maneira sutil e progressiva, decorrentes da degradação mecânica natural dos componentes, ou podem decorrer repentinamente, motivadas por eventos transitórios e esforços estruturais intensos (QIAN et al., 2020).

Técnicas estatísticas, sinais vibratórios e dados SCADA são amplamente utilizados, tanto para extração de indicadores físicos diretos quanto modelos matemáticos de aprendizado automático capazes de caracterizar comportamentos semelhantes a máquinas que apresentam falhas. De acordo com Tchakoua et al. (2014), na Figura 17, as falhas são mais presentes num período inicial de instalação, e num período final da vida útil devido à degradação dos componentes.

Figura 17 - Comportamento da taxa de falhas: período inicial, vida útil e desgaste



Fonte: TCHAKOUA et al. (2014).

Na análise estatística, métodos baseados em limites de controle e variações de parâmetros de tendência central e dispersão são empregados para detectar desvios significativos em relação ao comportamento esperado da máquina (SCHWAB et al., 2022). Indicadores como RMS, curtose e fator de crista permanecem amplamente utilizados pela indústria devido à sua robustez e baixa complexidade computacional, apresentados na Tabela 2, sendo especialmente úteis na detecção inicial de defeitos em rolamentos e engrenagens, que representam uma fração significativa das falhas em turbinas (CAESARENDRA; TJAHJOWIDODO, 2017).

Tabela 2 - Características e suas definições

Característica	Descrição
RMS	Valor eficaz aumenta gradativamente conforme falha
Variância	Dispersão das amostras em torno da média.
Assimetria	Quantifica assimetria da distribuição média do sinal
Curtose	Quantifica o valor pico de PDF. Valor base de um rolamento regular é consolidado como 3
Fator de Forma	Relação entre energia RMS e média absoluta do sinal, informa a forma de onda
Fator de Crista	Calcula a quantidade de impacto do rolamento no contato
Entropia	Medida da incerteza e aleatoriedade da distribuição do sinal.

Fonte: Adaptado de CAESARENDRA; TJAHJOWIDODO (2017).

Técnicas de aprendizado de máquina são incorporadas para capturar padrões complexos e não lineares que não podem ser facilmente detectados por métodos tradicionais (CHEN; TORRES; LI, 2021). Algoritmos como *Support Vector Machines* (SVM), redes neurais e modelos probabilísticos baseados em aprendizado não supervisionado, como *k-means* e *autoencoders*, demonstram assertividade em aplicações reais, identificando desvios de comportamento a partir do histórico dos dados operacionais (ZHANG et al., 2022). Esses métodos permitem detectar anomalias, inferir estados de degradação e auxiliar estratégias de prognóstico com maior precisão assim como classificar o local de falha.

Outro destaque são os modelos híbridos, que combinam métodos de processamento de sinais, extração de características e algoritmos de inteligência artificial. De acordo com Chen, Torres e Li (2021), essa abordagem favorece a identificação de padrões temporais e espectrais associados a falhas incipientes, maximizando a sensibilidade dos sistemas de monitoramento em condições reais de operação. Além disso, técnicas baseadas em decomposição de sinais, como Empirical Mode Decomposition (EMD) e Wavelet Transform, demonstram eficiência na análise de sinais não estacionários, frequentes em turbinas eólicas devido à

variabilidade do vento e das condições aerodinâmicas (ANTONIOU; CHATZIS, 2022).

2.6 Indicadores no domínio do tempo e frequência

A análise de vibração em máquinas rotativas depende fortemente da extração de características que sintetizam o comportamento dinâmico do sinal. Esses indicadores permitem identificar padrões associados à degradação, impactos, transientes impulsivos e alterações estruturais, sendo amplamente empregados em aplicações de diagnóstico e prognóstico de rolamentos (CAESARENDRA; TJAHJOWIDODO, 2017). No domínio do tempo, indicadores estatísticos clássicos incluem:

- a) Valor RMS (*Root Mean Square*): representa a energia global do sinal, tende a aumentar com o desgaste;
- b) Variância e desvio padrão: quantificam a dispersão do sinal e indicam aumento da instabilidade vibratória.
- c) Assimetria: grau de simetria da distribuição, defeitos costumam produzir assimetrias devido a impulsos irregulares.
- d) Curtose: uma das métricas mais sensíveis à presença de impulsos e picos associados a falhas iniciais de rolamentos. Valores próximos de 3 indicam condição normal; valores elevados sugerem impactos e descontinuidades (CAESARENDRA; TJAHJOWIDODO, 2017).
- e) Pico a Pico: diferença entre máximos e mínimos do sinal, útil para detectar eventos impulsivos abruptos.
- f) Fator de Crista, Margem e Impulso: a relação entre amplitude e energia média, úteis para identificar impactos repetitivos típicos no início da degradação.

No domínio da frequência, a análise espectral fornece informações complementares, sendo possível identificar bandas características de falhas de engrenagens, rolamentos e elementos acoplados. Técnicas como a Transformada Rápida de Fourier (FFT) permitem visualizar componentes harmônicas e sub-harmônicas, mas apresentam limitações quando o sinal é não estacionário,

característica comum em aerogeradores devido às variações do vento (RANDALL, 2011).

Para superar essas limitações, indicadores híbridos tempo-frequência são empregados, como a Curtose Espectral, que mede, para cada banda de frequência, o grau de impulsividade local. Segundo Saïdi e Ali (2016), essa métrica é altamente eficaz na detecção precoce de defeitos em rolamentos, especialmente em altas frequências (8 a 12 kHz), onde impulsos mecânicos se manifestam de forma mais evidente. Esses indicadores, utilizados de forma combinada, constituem a base para identificação de anomalias e construção de indicadores de saúde apresentados no Capítulo 4 deste trabalho.

2.7 Fusão de características e métrica α - λ

Quando múltiplas características são extraídas de um mesmo sinal, é comum que existam correlações significativas entre elas, o que pode gerar redundância informacional e dificultar a modelagem direta em alta dimensão. Nesse contexto, técnicas de redução de dimensionalidade, métricas de seleção de características e métodos específicos de avaliação de prognóstico tornam-se fundamentais para construir indicadores de saúde robustos e quantificar o desempenho dos modelos de RUL (KESTEL et al., 2025).

Critério clássico para seleção de características para a modelagem de degradação é a monotonicidade. Essa métrica avalia o quanto uma característica evolui de forma predominantemente crescente ou decrescente ao longo do tempo. Características monotônicas apresentam poucas inversões de tendência, sendo ideais para modelos de RUL por regressão temporal. Segundo Rezamand et al. (2020), valores acima de 0,3 indicam evolução consistente do desgaste, qualificando-as para estimativa, enquanto as de baixa monotonicidade são ruidosas e inadequadas para prognóstico.

Após a seleção das características com melhores propriedades, através da monotonicidade, aplica-se a *Principal Component Analysis* (PCA) como técnica de fusão de informações. A PCA transforma um conjunto possivelmente correlacionado de variáveis em um novo conjunto de variáveis ortogonais, denominadas

componentes principais. Cada componente principal corresponde a uma combinação linear das características originais e é construído de forma a maximizar a variância explicada, sob a restrição de ortogonalidade entre componentes (KIM; ANTONI; LEE, 2013). O primeiro componente principal (PCA1) geralmente concentra a maior parte das informações relevantes sobre a degradação, sendo comumente utilizado como indicador de saúde (HI).

A avaliação de desempenho de modelos de prognóstico exige métricas específicas que considerem tanto a precisão quanto a consistência das estimativas de RUL ao longo do tempo. Entre as métricas mais utilizadas está a α - λ , amplamente empregada em estudos de prognóstico. Essa métrica quantifica a probabilidade de que as previsões de RUL se mantenham dentro de um intervalo de erro relativo aceitável em relação ao valor verdadeiro. Em termos gerais, define-se um parâmetro λ que estabelece a largura do intervalo de tolerância em torno da RUL real, enquanto α representa a fração de previsões que permanecem dentro desse intervalo ao longo do horizonte de avaliação (SAXENA et al., 2010). Valores elevados de α indicam que o modelo é consistente e confiável, enquanto valores baixos sugerem instabilidade ou erros sistemáticos nas estimativas.

2.8 Modelo de degradação

Modelos de degradação são ferramentas matemáticas fundamentais no prognóstico de falhas, pois permitem descrever a evolução progressiva do desgaste de um componente ao longo do tempo. Em sistemas mecânicos rotativos, como rolamentos de alta rotação em aerogeradores, o processo de degradação costuma apresentar comportamento não linear, caracterizado por uma fase inicial de variação lenta, seguida por um crescimento acelerado à medida que o dano se intensifica (REZAMAND et al., 2020). Capturar essa dinâmica é essencial para estimar a vida útil remanescente (RUL) de forma confiável.

Entre os diversos modelos baseados em dados, o modelo de degradação exponencial destaca-se pela sua capacidade de capturar o crescimento acelerado observado em falhas de rolamentos, principalmente na fase em que o desgaste se intensifica e impulsos de alta frequência tornam-se mais frequentes. Esse modelo assume que o indicador de saúde cresce segundo a Equação (1).

$$h(t) = \phi + \theta e^{\beta t} + \epsilon \quad (1)$$

em que:

- a) $h(t)$ é o indicador de saúde no instante;
- b) ϕ é o valor inicial do indicador;
- c) θ controla a escala da degradação;
- d) β representa a taxa de aceleração da falha;
- e) ϵ corresponde ao ruído do processo.

O uso de modelos exponenciais é amplamente documentado para rolamentos operando em alta velocidade, devido à tendência desses sistemas de exibirem crescimento abrupto na impulsividade, detectável por métricas como RMS, curtose e Curtose Espectral (SAÏDI; ALI, 2016). Em aplicações de manutenção preditiva, esse tipo de modelo apresenta boa robustez mesmo quando a quantidade de dados disponíveis é limitada, como no caso de conjuntos de dados com poucos dias de amostragem ou registros diários curtos (MATHWORKS, 2018).

Modelos de degradação possibilitam a extrapolação da trajetória dos indicadores de saúde, gerando estimativas quantitativas do tempo remanescente até o componente alcançar o limiar de falha. Esse procedimento fundamenta o cálculo da RUL, abordado no Capítulo 4, permitindo a programação de manutenção com antecedência, reduzindo custos e prevenindo paradas não programadas da turbina. Sendo assim, os modelos de degradação funcionam como relação principal da análise de vibrações e o prognóstico de falha, convertendo variações de indicadores extraídos dos sinais em previsões confiáveis de vida útil remanescente.

3 DADOS E METODOLOGIA

Neste estudo, adotou-se um estudo de prognóstico inspirado no exemplo disponibilizado por Eric Bechhoefer (MATHWORKS, 2017). Inicia-se pela aquisição de pontos de entrada de sinais de vibração que possuem duração de 6 segundos por dia ao longo de 50 dias consecutivos para os rolamentos dos eixos de alta velocidade de um aerogerador. O aerogerador foco do estudo têm capacidade de geração de 2 MW e o mancal é acionado por uma engrenagem de pinhão de 20 dentes (MathWorks, 2018). Durante o período de 50 dias é identificada uma falha na pista interna do rolamento, tornando o conjunto de dados ideal para estudos de extração de características e de RUL.

3.1 Estrutura geral da metodologia

A metodologia adotada neste trabalho segue uma sequência estruturada composta pelas seguintes etapas:

- a) aquisição e organização das séries temporais de vibração mecânica;
- b) pré-processamento dos sinais;
- c) extração de características no domínio do tempo e no domínio tempo-frequência;
- d) avaliação de métricas de monotonicidade, tendência e suavidade para seleção de um HI;
- e) normalização e suavização do HI;
- f) ajuste de um modelo de degradação;
- g) estimativa do tempo de vida remanescente;
- h) avaliação da qualidade da estimativa por meio da métrica α - λ .

A metodologia apresentada torna capaz transformar séries temporais brutas de vibração em estimativas quantitativas de vida útil, garantindo a consistência entre dados, processamento e confiabilidade dos resultados.

3.1.1 Conjunto de dados e aquisição das características

O conjunto contém por registro diário as seguintes variáveis: *vibration*, *tach*, *Date*. A variável *date* é a data e horário do registro dos sensores. *Vibration* é dado por um vetor de aceleração com 292.968 amostras e o *tach* é o sinal de impulso do tacômetro que detecta a rotação por coleta do eixo. O formato do conjunto de dados é apresentado na Tabela 3.

Tabela 3 - Disposição das medidas de vibração e tacômetro da máquina

date	Vibration	tach
11-Mar-2013 03:00:24	{292968×1 <i>double</i> }	{180×1 <i>double</i> }
16-Mar-2013 06:56:43	{292968×1 <i>double</i> }	{187×1 <i>double</i> }
21-Mar-2013 00:33:14	{292968×1 <i>double</i> }	{188×1 <i>double</i> }
.	.	.
.	.	.
.	.	.

Fonte: MATHWORKS (2017)

A aceleração de vibração por ser um vetor de 292.968 amostras, pode-se decompor em x e y, tornando as amostras em 585.936 ocorrências no intervalo de 6 segundos, sendo assim a frequência de amostragem é 97,66 kHz.

As características extraídas do sinal vibratório possuem relação direta com os fenômenos físicos que ocorrem durante a degradação do rolamento (SAIDI et al., 2016). O valor RMS tende a aumentar em função do desgaste ou de impactos súbitos entre os componentes. Já a curtose destaca a ocorrência de impulsos de alta amplitude em comparação com os valores vizinhos, característica típica de falhas iniciais em superfícies rolantes, o que a torna uma das métricas mais sensíveis para detectar a degradação desde seus estágios iniciais. O fator de crista indica a relação entre valores de pico e energia média do sinal, sendo relevante para identificar impactos repetitivos anormais. Por sua vez, o fator de forma e a variância fornecem informações complementares sobre a forma e a dispersão do sinal, enquanto a assimetria capta desvios no formato da onda decorrentes de impactos irregulares, geralmente correlacionados com a curtose. Essas métricas são fundamentais para o

diagnóstico preciso e o monitoramento da evolução de falhas em rolamentos de aerogeradores.

Assim, a combinação dessas características possibilita representar adequadamente a evolução do comportamento vibracional do rolamento. Na Tabela 4 as características relevantes para o estudo apresentam sua fórmula para melhor entendimento.

Tabela 4 - Fórmula das características extraídas

Característica	Fórmula
RMS	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
Variância	$Var = \frac{\sum_{i=1}^N (x_i - m)^2}{(N-1)\sigma^2}$
Assimetria	$SK = \frac{\sum_{i=1}^N (x_i - m)^3}{(N-1)\sigma^3}$
Curtose	$Ku = \frac{\sum_{i=1}^N (x_i - m)^4}{(N-1)\sigma^4}$
Fator de Forma	$SF = \frac{RMS}{\frac{1}{N} \sum_{i=1}^N x_i^2}$
Fator de Crista	$CF = \frac{\max x_i }{RMS}$

Fonte: Adaptado de CAESARENDRA; TJAHJOWIDODO (2017).

3.1.2 Pré-processamento dos sinais

Após a extração de características, estas foram submetidas a um pré-processamento com o objetivo de reduzir ruído e garantir a comparação entre dias sucessivos de operação. As etapas executadas foram as seguintes:

- a) Segmentação: os dados diários foram tratados de forma independente contendo o sinal bruto de vibração.

- b) Normalização inicial: para permitir comparação entre os dias, os sinais foram normalizados linearmente.
- c) Suavização: média móvel para reduzir flutuações de alta frequência não relacionadas à degradação.
- d) Identificação do período de degradação: sinais iniciais que não apresentavam variação significativa foram classificados como fase saudável de operação, enquanto os restantes foram utilizados para modelagem do comportamento de degradação.

Esse pré-processamento é essencial para permitir que as métricas extraídas reflitam exclusivamente o comportamento do componente e não variações artificiais ou ruídos aleatórios.

3.1.3 Seleção da métrica representativa de degradação

A seleção do IS é uma etapa chave do processo, pois define a grandeza que será utilizada para modelagem da degradação e estimativa de vida útil. Para cada métrica extraída, foram calculados três indicadores de qualidade amplamente utilizados em prognóstico:

- a) Monotonicidade: razão entre incrementos positivos e negativos ao longo do tempo. Métricas mais monotônicas evoluem consistentemente com a degradação.
- b) Tendência: medida de correlação entre a métrica e o tempo, avaliando a relação entre avanço da métrica e da falha.
- c) Suavidade: medida da continuidade da evolução da métrica, penalizando oscilações abruptas.

A métrica com melhor desempenho médio nos três critérios foi selecionada como IS, por apresentar evolução clara, suave e relacionada diretamente à degradação.

3.1.4 Transformação final do Indicador de saúde

Após a seleção da métrica mais adequada, o IS foi submetido a duas transformações finais:

- a) Normalização entre 0 e 1: início da vida útil apresenta valores próximos de 0 e da falha apresenta valores próximos de 1.
- b) Suavização: nova filtragem leve por média móvel para eliminar ruído residual, resultando em uma curva adequada para modelagem.

O resultado é uma curva contínua representando a progressão do desgaste do rolamento ao longo dos dias de operação.

3.1.5 Ajuste no modelo de degradação

O comportamento crescente do IS foi modelado utilizando um modelo exponencial, amplamente adotado em prognóstico devido à sua capacidade de representar comportamentos de degradação acelerada. Esse modelo foi ajustado aos dados reais do IS por meio de mínimos quadrados não lineares. A partir do modelo ajustado, é possível extrapolar a tendência de degradação até o instante em que o IS atinge o limite de falha.

3.1.6 Avaliação da qualidade de prognóstico

Para avaliar a confiabilidade do prognóstico, utilizou-se a métrica α - λ , que quantifica a fração das estimativas de RUL que permanecem dentro de um intervalo admissível determinado por λ .

- a) λ : tolerância percentual permitida (ex.: 20%).
- b) α : proporção das estimativas de RUL que permanecem dentro de $\pm\lambda$ do valor real.

Assim, valores elevados de α indicam maior precisão do algoritmo prognóstico. Essa métrica sintetiza o desempenho do modelo e fornece uma visão clara da robustez da estimativa de RUL.

3.1.7 Limitações e considerações do conjunto de dados

O uso exclusivo de um acelerômetro posicionado no eixo de alta rotação limita a visão do comportamento de outros componente crítico da turbina como engrenagens planetárias e seus outros mancais e rolamentos, diferente de CMS que conta com múltiplos sensores distribuídos ao longo da *gearbox* (CAESARENDRA; TJAHJOWIDODO, 2017). A amostragem é curta demais para detectar fenômenos mais específicos de operação de um aerogerador, as medições também são feitas apenas 1 vez ao dia num intervalo de 6 segundo, enquanto as turbinas reais podem gerar vibrações de forma intermitente.

As 50 amostras disponibilizadas são adequadas para estudos de tendência e séries temporais e extração de características, mas são limitadas para treinar modelos de alta complexidade e podem criar uma generalização equivocada para outros aerogeradores. Não há dados de velocidade de vento ou a carga nas pás da máquina para correlacionar as vibrações à geração de energia eólica da máquina. Também não é disponibilizada a localização exata da máquina, impossibilitando a busca dos dados climáticos na região.


4 RESULTADOS E ANÁLISES

A seguir são apresentados os resultados obtidos da análise de séries temporais de vibração do rolamento de alta velocidade. As métricas extraídas no domínio do tempo e da frequência foram avaliadas com o objetivo de identificar padrões associados à degradação progressiva e estimar a vida útil remanescente.

4.1 Visualização do conjunto de dados

Os sinais brutos de vibração podem ser explorados no domínio do tempo e da frequência. A Figura 18 evidencia a visualização no domínio do tempo e as amplitudes do sinal, nessa visualização é possível identificar um aumento gradual das vibrações da máquina quando o momento da falha se aproxima.

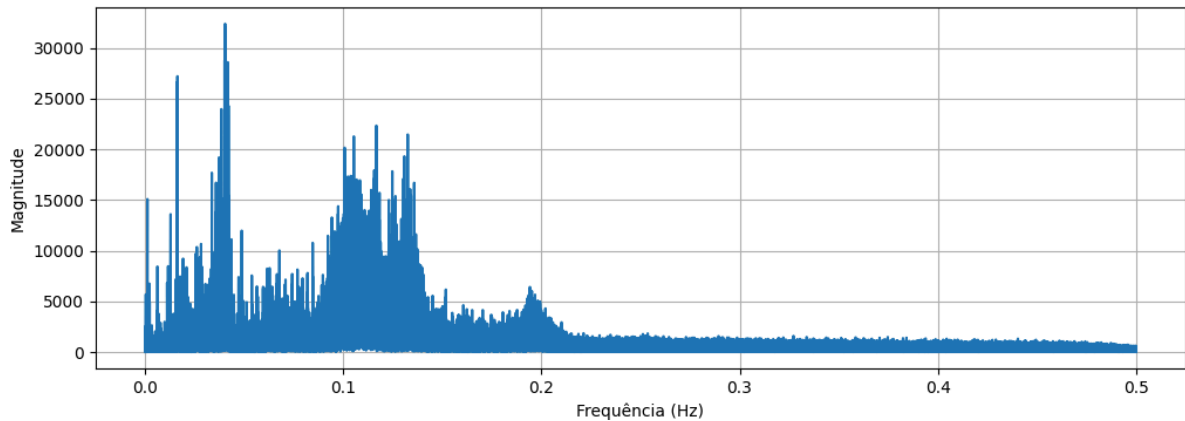
Figura 18 - Visualização no domínio do tempo do conjunto de dados



Fonte: Elaboração própria (2025) utilizando Matplotlib.

A Figura 19 apresenta o domínio da frequência da espectral de curtose no seu primeiro dia de medição. No domínio da frequência de um só dia não traz informações necessárias para qualquer conclusão assertivo, entretanto quando se combina a visualização no domínio tempo-frequência, é possível visualizar melhor a amplitude de vibração anormal no aerogerador.

Figura 19 - Visualização no domínio da frequência do conjunto de dados no dia 1

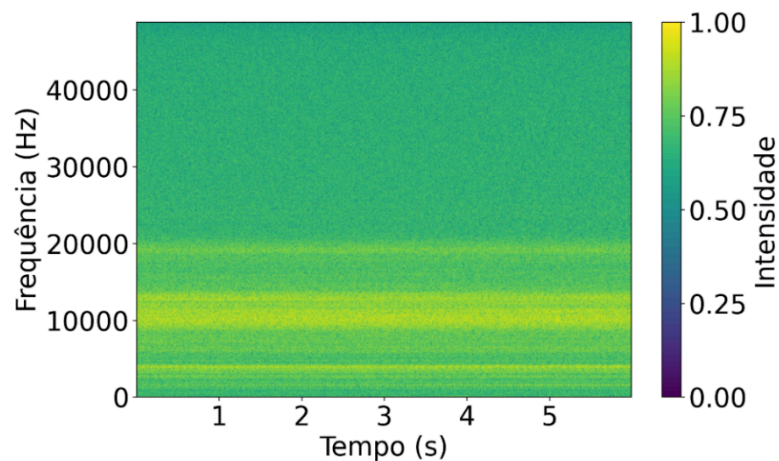


Fonte: Elaboração própria (2025) utilizando Matplotlib.

Na Figura 20 é possível identificar exatamente as harmônicas de frequências que apresentam vibração na máquina conforme a sua amplitude.


Com uma visualização tridimensional, ao longo do período de medição, é perceptível o aumento da frequência da Curtose Espectral nas faixas de 10 kHz conforme a Figura 21 apresenta.

Figura 20 - Visualização no domínio do tempo-frequência do conjunto de dados



Fonte: Elaboração própria (2025) utilizando Matplotlib.

Figura 21 - Visualização tridimensional domínio da frequência durante o período de operação



Fonte: Elaboração própria (2025) utilizando Matplotlib.

A evolução da degradação destes sinais ao longo do tempo já é perceptível observando apenas os sinais brutos dessa operação, conforme as Figuras 18 e 21, mas apesar de observáveis não são capazes de retornar uma estimativa de vida útil, para isto é necessário definir quais indicadores do sinal bruto que indicam com maior assertividade.

4.2 Indicadores

Nesta etapa a Tabela 5 indica os fatores avaliados: Média, Desvio Padrão, Variância, Curtose, Pico à Pico, RMS, Fator de Crista, Fator de Forma, Fator de Impulso, Fator de Forma Fator de Impulso, Fator de Margem, Entropia e outros parâmetros definitivos da curiose também foram medidos como desvios padrões, variâncias e média espectral da curiose.

Tabela 5 - Indicadores extraídos no primeiro e último dia de operação

Indicadores	Dia 1	Dia 21	Dia 50
Média	0,346052	0,320293074	0,257848
Desvio Padrão	2,270483	1,923361692	2,978724
Variância	0,00387	-0,007469063	0,025931
Curtose	2,995612	3,137979603	5,436978
Pico à Pico	21,62107	19,93832588	43,44453
RMS	2,296702	1,949846542	2,989858
Fator de Crista	4,914735	5,221982751	7,682359
Fator de Forma	1,253517	1,259354918	1,329824
Fator de Impulso	6,160703	6,576329662	10,21619
Fator de Margem	3,362451	4,247479444	4,54394
Entropia	3.090.717,528	2.227.670,979	2,618915
Média - Curtose Espectral	0,001301	0,013049624	0,165641
Desvio padrão - Curtose Espectral	0,02575	0,059071457	0,527569
Variância - Curtose Espectral	-0,22011	3,162100861	3,571159
SKSK	3,33919	14,39280436	16,23181

Fonte: Elaboração própria (2025).


A curtose apresenta valor próximo a 3 durante seu primeiro dia de operação, indicando um rolamento estável em condições normativas de operação (EFTEKHARNEJAD et al., 2011).

4.3 Processamento dos sinais

Após a extração de características nos domínios temporal e espectral, algumas métricas mostram alta sensibilidade a ruídos de alta frequência e variações abruptas inerentes à natureza estocástica dos sinais vibratórios, comprometendo as etapas de análise, especialmente: o cálculo da monotonicidade, que não são robustas a ruídos, a modelagem de degradação, na qual pequenas flutuações podem induzir erros no ajuste do modelo de RUL.

Com intuito de mitigar os efeitos de flutuação ou dos ruídos, aplica-se o processamento de sinais baseado em suavização causal. Esse método consiste em uma média móvel com janela de cinco amostras passadas e uma presente, sendo assim o processamento fica mais compatível com aplicações reais de prognóstico, nas quais o estado futuro do componente é desconhecido. A Figura 22 indica essa suavização do sinal das características de maior impacto.

Figura 22 - Evolução da degradação em dados brutos



Fonte: Elaboração própria (2025) utilizando Matplotlib.

4.4 Seleção de características

É necessário fazer uma seleção criteriosa das características que apresentam maior capacidade preditiva para a estimativa de vida útil. Em sistemas de monitoramento nem todas as métricas extraídas apresentam comportamento adequado para modelagem de degradação. Para quantificar o mérito de cada característica em aplicações de estimativa, utiliza-se a métrica de monotonicidade conforme a Equação (2).


$$\text{Monotonicidade}(x_i) = \frac{1}{m} \sum_{j=1}^m \frac{|n^{\circ} \text{ de diferenças positivas}(x_j^i) - n^{\circ} \text{ de diferenças negativas}(x_j^i)|}{n-1} \quad (2)$$

em que:

- a) n é o número de métricas realizadas e
- b) m é o número de máquinas analisadas

Monotonicidade abaixo de 0,3 indica que a característica não é adequada para estimativa de vida útil devido à sua baixa precisão (Zhang et al., 2015). A Figura 23 correlaciona as características extraídas com as suas respectivas monotonicidades.

Figura 23 - Monotonicidade das características



Fonte: Elaboração própria (2025) utilizando Matplotlib.

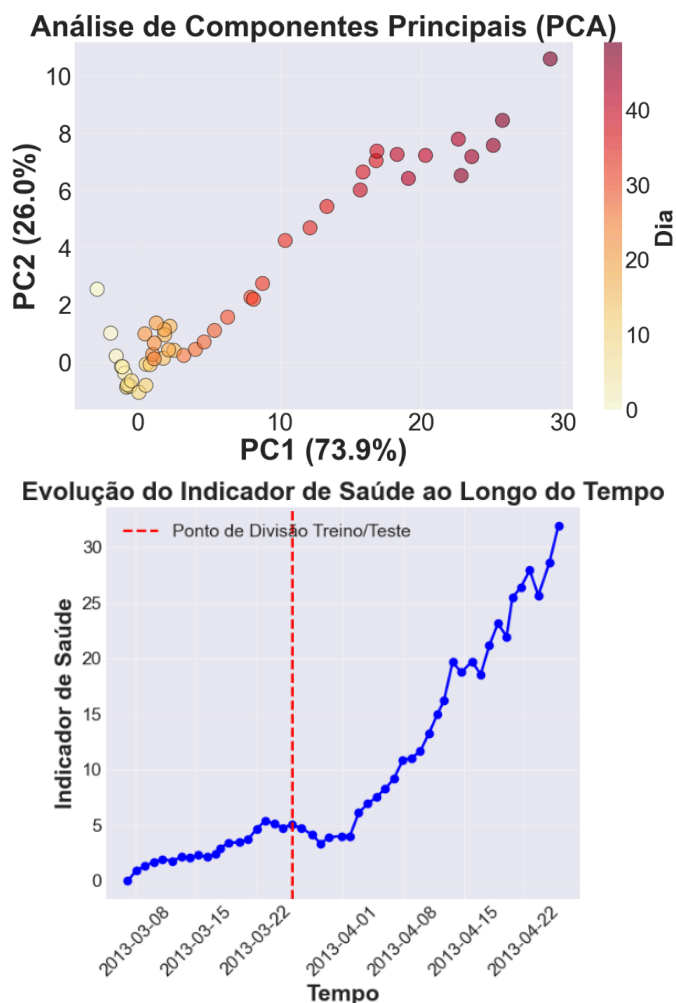
4.5 Seleção de dados para treinamento

A máquina operante tem características de máquina saudável até o dia 20, 40% do conjunto de dados disponibilizados, após o dia 20 as falhas começam a surtir maior efeito nos sinais de vibração e por isto foi definido que o conjunto de dados para treinamento são os 20 primeiros dias e os últimos 30 dias são utilizados para medir a eficácia da estimativa de vida útil.

4.6 Redução de dimensão e fusão de características

Após a etapa de seleção de características, pode existir redundância das informações decorrente das correlações lineares ou não lineares entre as variáveis extraídas. A utilização das múltiplas características independentes introduz maior complexidade e dificuldade na interpretação dos resultados, especialmente em aplicações de estimativa de RUL. Através de PCA, a Figura 24 apresenta as características de maior impacto e o indicador de saúde do aerogerador analisado.

Figura 24 - Indicadores de saúde da máquina



Fonte: Elaboração própria (2025) utilizando Matplotlib.

4.7 Ajuste de modelos de degradação exponencial para RUL

Após a construção do HI por fusão de características, ajusta-se um modelo matemático capaz de representar a evolução do dano ao longo do tempo e, dessa forma, permitir a estimativa da vida útil. Para este estudo, adotou-se um modelo de degradação exponencial, amplamente utilizado em aplicações de prognóstico de rolamentos e outros componentes mecânicos sujeitos a desgaste progressivo (MATHWORKS, 2018), conforme a Equação (3). Esse modelo é adequado porque captura o comportamento não linear e acelerado típico da degradação de rolamentos, como observado anteriormente nas figuras de tendência. Para garantir estabilidade numérica e interpretar corretamente o crescimento do dano, o indicador é deslocado de modo que começa em zero conforme Equação 3.


$$h(t) = h(t) - h(1) \quad (3)$$

Isso evita a influência do valor inicial na estimativa dos parâmetros do modelo. Como o conjunto de dados não contém informações históricas sobre a especificação física do limite de falha, foi adotado o último valor observado do indicador como limiar de falha. Assume-se que o ruído representa 10% da variação do indicador quando este se aproxima do limiar de falha. Assim, a variância do ruído é representada:

$$\sigma = \frac{0,1 * threshold}{threshold - \phi} \quad (4)$$

O uso desse valor evita que flutuações pequenas prejudiquem a estimativa da trajetória de degradação. Na Figura 25 é possível visualizar o modelo de degradação do dia 21, primeiro dado de teste, e do dia 30 ao último dia de dados de teste.

Figura 25 - Modelo de degradação dos dias 21 e 30
Modelo de Degradação Exponencial



Fonte: Elaboração própria (2025) utilizando Matplotlib.

4.8 Análise de desempenho

É necessário avaliar objetivamente a capacidade preditiva do modelo em estimar a vida útil remanescente do rolamento. Diferentemente de tarefas convencionais de classificação ou regressão, a avaliação de modelos de prognóstico requer métricas específicas que considerem a natureza temporal e a evolução dinâmica da predição de RUL. Neste estudo, utiliza-se a métrica α - λ , proposta por Saxena et al. (2010) e amplamente adotada em aplicações de prognóstico de componentes críticos. A métrica quantifica a probabilidade de que a predição de RUL esteja dentro de uma margem aceitável de erro em relação ao valor verdadeiro

de RUL, considerando um limite de confiança pré-estabelecido. Matematicamente a métrica é dada pela Equação (5).

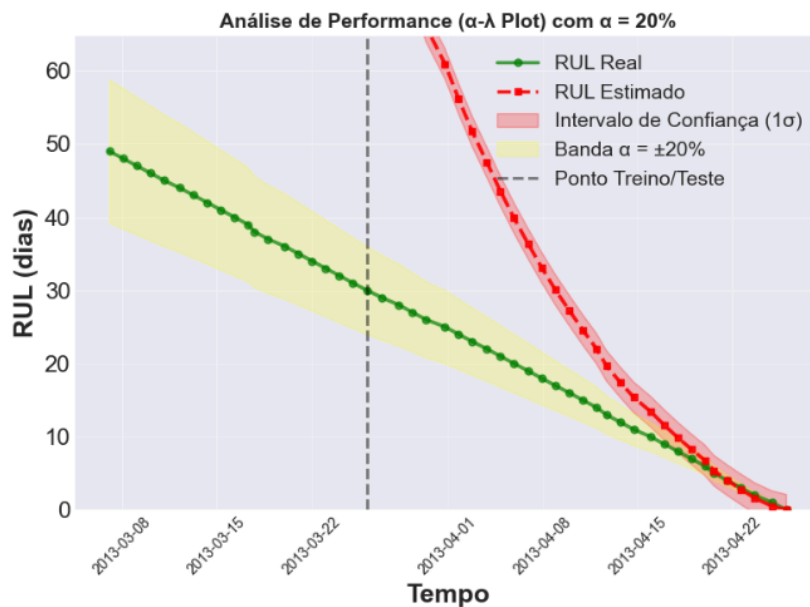
$$P(\alpha^*(t)) = P(r^*(t) - \lambda r(t) < r(t) < r^*(t) + \lambda r^*(t) | \theta(t)) \quad (5)$$

em que:

- a) $r^*(t)$ - estimativa de RUL no instante t ;
- b) $r(t)$ - valor verdadeiro da RUL no instante t ;
- c) λ - parâmetro que define largura do intervalo de confiança;
- d) $\Theta(t)$ - representa os parâmetros estimados do modelo em t ;
- e) $P(\alpha^*(t))$ é a probabilidade de que a predição esteja dentro dos limites.

Em aplicações práticas de manutenção preditiva, um valor típico de $\lambda = 0,2$ (ou 20%) é frequentemente adotado como compromisso entre precisão e viabilidade operacional. Esse limite significa que uma predição é considerada aceitável se o RUL estimado estiver dentro de $\pm 20\%$ do RUL verdadeiro. A Figura 26 ilustra o gráfico α - λ e a crescente precisão do modelo conforme mais dados são utilizados na estimativa.

Figura 26 - Gráfico α - λ



Fonte: Elaboração própria (2025) utilizando Matplotlib.

5 CONCLUSÃO

Este trabalho cumpriu o objetivo de sistematizar e aplicar boas práticas para o tratamento, transformação e análise de séries temporais de vibração mecânica em rolamentos de alta rotação de aerogeradores, utilizando o conjunto de dados público *Wind Turbine High-Speed Bearing Prognosis Data* da MathWorks.

A metodologia desenvolvida demonstrou que indicadores como RMS, curtose e Curtose Espectral apresentam comportamento monotônico ao longo do tempo, característica fundamental para aplicações de prognóstico. A análise de monotonicidade permitiu identificar que características com valores superiores a 0,3 são adequadas para modelagem de degradação e RUL. A técnica de PCA foi empregada com sucesso para fusão de características e redução de dimensionalidade, permitindo a construção de um indicador de saúde consolidado que captura a maior parte de variações dos dados. O modelo de degradação exponencial ajustado aos dados mostrou-se capaz de estimar a RUL em tempo real, com a métrica α - λ demonstrando probabilidade crescente de acerto conforme mais dados de operação são incorporados ao modelo.

Contudo, algumas limitações devem ser reconhecidas. O conjunto de dados utilizado apresenta restrições quanto à quantidade de amostras (de 50 dias), utilização de um único sensor de vibração, e ausência de variáveis operacionais complementares como velocidade do vento, carga nas pás, potência gerada e corrente. Essas limitações restringem a generalização dos resultados para outros aerogeradores e condições operacionais distintas.

5.1 Trabalhos futuros

Para trabalhos futuros, sugere-se expandir a metodologia em três frentes principais: integrar sensores de vibração distribuídos nos diferentes eixos e mancais da caixa de transmissão, combinados com dados SCADA de velocidade do vento e potência, estender o período de coleta para meses, ao invés de apenas 6 segundos diariamente, abrangendo diversos regimes operacionais para maior robustez nas tendências de degradação e RUL. E investigar técnicas de IA como redes neurais convolucionais e modelos híbridos, que capturam dependências temporais e espectrais mais sofisticadas que os indicadores lineares deste estudo.

REFERÊNCIAS

ALMUTAIRI, K. M.; SINHA, J. K. **Experimental vibration data in fault diagnosis: a machine learning approach to robust classification of rotor and bearing defects in rotating machines.** *Machines*, Basel, v. 11, n. 10, p. 943, 2023. DOI: <https://doi.org/10.3390/machines11100943>.

BADIHI, H. et al. **A comprehensive review on signal-based and model-based condition monitoring of wind turbines: fault diagnosis and lifetime prognosis.** *Proceedings of the IEEE*, v. 110, n. 6, p. 754-803, 2022. DOI: 10.1109/JPROC.2022.3171691.

BAGRI, I. et al. **Vibration Signal Analysis for Intelligent Rotating Machinery Diagnosis and Prognosis: A Comprehensive Systematic Literature Review.** *Vibration*, v. 7, p. 1013-1062, 2024. DOI: 10.3390/vibration7040054.

BUDISETYAWAN, D. et al. **Wind Turbine Reliability Forecast: A Technical Review on the Research Milestone and Assessment of the Energy Cost Using Monte Carlo Simulation.** *Engineered Science*, v. 35, p. 1502, 2025. DOI: 10.30919/es1502.

CAESARENDRA, W.; TJAHHJOWIDODO, T. **A Review of Feature Extraction Methods in Vibration-Based Condition Monitoring and Its Application for Degradation Trend Estimation of Low-Speed Slew Bearing.** *Machines*, v. 5, n. 4, p. 1-28, 2017. DOI: 10.3390/machines5040021.

CASTELLANI, F. et al. **Diagnosis of faulty wind turbine bearings using tower vibration measurements.** *Energies*, v. 13, n. 6, p. 1474, 2020.

CHATTERJEE, J.; DETHLEFS, N. **Scientometric review of artificial intelligence for operations & maintenance of wind turbines: the past, present and future.** *Renewable and Sustainable Energy Reviews*, v. 144, p. 111051, 2021.

EFTEKHARNEJAD, B.; CARRASCO, M. R.; CHARNLEY, B.; MBA, D. **The application of spectral kurtosis on Acoustic Emission and vibrations from a defective bearing.** *Mechanical Systems and Signal Processing*, v. 25, p. 266-284, 2011. DOI: 10.1016/j.ymssp.2010.06.010.

EMPRESA DE PESQUISA ENERGÉTICA (EPE). **Geração eólica e fotovoltaica: dados de entrada para modelos energéticos - metodologias e premissas.** *Nota Técnica EPE/DEE/011/2021-R3*. Rio de Janeiro: EPE, set. 2024. Disponível em: https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-836/NT%20EPE-DEE-011-2021-R3_Dados%20de%20entrada%20para%20modelos.pdf. Acesso em: 7 nov. 2025.

ESCALER, X.; MEBARKI, T. **Full-scale wind turbine vibration signature analysis.** *Machines*, v. 6, n. 4, p. 63, 2018. DOI: <https://doi.org/10.3390/machines6040063>.

GLOBAL WIND ENERGY COUNCIL (GWEC). **Global Wind Report 2024.** Brussels: GWEC, 2024. Disponível em:

<https://www.gwec.net/hubfs/Website-2023/documents/GWEC-2024.pdf>. Acesso em: 23 nov. 2025.

INTERNATIONAL ELECTROTECHNICAL COMMISSION (IEC). **IEC 61400-1: Wind turbines — Part 1: Design requirements**. Geneva: IEC, 2019.

INTERNATIONAL RENEWABLE ENERGY AGENCY (IRENA). **Renewable Energy Technologies: Cost Analysis - Wind Power**. Abu Dhabi: IRENA, 2012. (Renewable Energy Cost Analysis Series, v. 1, issue 5/5). Disponível em: <https://www.irena.org/publications/2013/Jan/Renewable-Power-Generation-Costs-in-2012-An-Overview>. Acesso em: 28 out. 2025.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO). **ISO 13372: Condition monitoring and diagnostics of machines — Vocabulary**. Geneva: ISO, 2012.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO). **ISO 13373-1: Condition monitoring and diagnostics of machines — Vibration condition monitoring — Part 1: General procedures**. Geneva: ISO, 2016.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO). **ISO 20816-3: Mechanical vibration — Measurement and evaluation of machine vibration — Part 3: Industrial machines**. Geneva: ISO, 2019.

KESTEL, K. et al. **Condition monitoring of wind turbine drivetrains: State-of-the-art technologies, recent trends, and future outlook**. *Wind Energy Science Discussions* (preprint), 2025. DOI: <https://doi.org/10.5194/wes-2025-168>.

LI, Y. et al. **Collaborative monitoring of wind turbine performance based on probabilistic power curve comparison**. *Renewable Energy*, v. 231, p. 120919, 2024.

LUONG, P.; WANG, W. **An evolving fuzzy classifier for induction motor health condition monitoring**. *Intelligent Control and Automation*, v. 10, p. 129-141, 2019. DOI: 10.4236/ica.2019.104009.

MATHWORKS. **Wind Turbine High-Speed Bearing Prognosis**. MATLAB & Simulink. Disponível em: <https://www.mathworks.com/help/predmaint/ug/wind-turbine-high-speed-bearing-prognosis.html>. Acesso em: 5 maio 2025.

MATHWORKS. **WindTurbineHighSpeedBearingPrognosis-Data**. Disponível em: <https://github.com/mathworks/WindTurbineHighSpeedBearingPrognosis-Data>. Acesso em: 5 maio 2025.

NUNES, P.; SANTOS, J.; ROCHA, E. **Challenges in predictive maintenance - A review**. *CIRP Journal of Manufacturing Science and Technology*, v. 40, p. 53-67, 2023. DOI: 10.1016/j.cirpj.2022.11.004.

ORSTED. **What is the carbon footprint of offshore wind?** [S. I.], 2022. Disponível em:

<https://us.orsted.com/wind-projects/seven-facts-about-offshore-wind/carbonfootprint>.

Acesso em: 7 nov. 2025.

PFATFEL, S.; FAULSTICH, S.; ROHRIG, K. **Performance and reliability of wind turbines: a review.** *Energies*, v. 10, n. 1904, p. 1-27, 2017.

RAO, S. S. **Mechanical Vibrations.** 6. ed. Boston: Pearson, 2017.

REZAMAND, M. et al. **Critical wind turbine components prognostics: a comprehensive review.** *IEEE Transactions on Instrumentation and Measurement*, v. 69, n. 12, p. 9306-9322, 2020. DOI: <https://doi.org/10.1109/TIM.2020.3030165>.

SAIDI, L.; BEN ALI, J.; BENBOUZID, M. **The use of SESK as a trend parameter for localized bearing fault diagnosis in induction machines.** *ISA Transactions*, v. 63, p. 436-449, 2016. DOI: 10.1016/j.isatra.2016.03.015.

SAÏDI, A.; ALI, M. **The use of spectral kurtosis as a trend parameter for bearing faults diagnosis.** *Mechanical Systems and Signal Processing*, v. 72-73, p. 316-329, 2016. DOI: 10.1016/j.ymssp.2015.09.014.

SAXENA, A. et al. **Metrics for evaluating performance of prognostic techniques.** In: *INTERNATIONAL CONFERENCE ON PROGNOSTICS AND HEALTH MANAGEMENT (PHM)*, 2010, Portland. Proceedings. [S. I.]: IEEE, 2010.

SHENG, S. **Wind turbine gearbox condition monitoring round robin study - vibration analysis.** Technical Report NREL/TP-5000-54530. Golden, CO: National Renewable Energy Laboratory (NREL), 2012. Disponível em: <https://www.nrel.gov/>. Acesso em: 14 nov. 2023.

SHENG, S. **Report on Wind Turbine Subsystem Reliability - A Survey of Various Databases.** Technical Report NREL/PR-5000-59111. Golden, CO: National Renewable Energy Laboratory (NREL), 2013. Disponível em: <https://www.nrel.gov/>. Acesso em: 7 nov. 2025.

SILVA, L. M.; ABREU-HARBICH, L. V. **Metodologia simplificada para avaliação do potencial de energia eólica em centros urbanos.** *PARC Pesquisa em Arquitetura e Construção*, Campinas, v. 8, n. 1, p. 46-58, mar. 2017. DOI: 10.20396/parc.v8i1.8648501.

SRIKANTH, P.; SEKHAR, A. S. **Wind turbine drive train dynamic characterization using vibration and torque signals.** *Mechanism and Machine Theory*, v. 98, p. 2-20, 2016. DOI: 10.1016/j.mechmachtheory.2015.11.013.

STRÖMBERGSSON, D. et al. **Bearing monitoring in the wind turbine drivetrain: A comparative study of the FFT and wavelet transforms.** *Wind Energy*, v. 23, n. 6, p. 1381-1393, 2020. DOI: <https://doi.org/10.1002/we.2491>.

TCHAKOUA, P. et al. Wind Turbine Condition Monitoring: **State-of-the-Art Review, New Trends, and Future Challenges**. *Energies*, v. 7, n. 4, p. 2595-2630, 2014. DOI: 10.3390/en7042595.

XIAO, F. et al. **Condition monitoring and vibration analysis of wind turbine**. *Structural Control and Health Monitoring*, v. 27, n. 11, p. e2557, 2020. DOI: 10.1002/stc.2557.

WOJTASZEK, H.; BOROWSKI, P. F.; HANDSCHKE, M.; MICIUŁA, I.; STECYK, A.; BIELAWA, A.; OŹDYK, S.; KOWALCZYK, A.; CZEPEŁO, F. **Wind Energy in Transition: Development, Socio-Economic Impacts, and Policy Challenges in Europe**. *Energies*, v. 18, n. 11, p. 2811, 2025. DOI:10.3390/en18112811

WANG, L.; LIANG, M.; ZHANG, Q. **A bearing prognosis framework based on deep wavelet extreme learning machine and particle filter**. *CIRP Journal of Manufacturing Science and Technology*, v. 39, p. 1-12, 2022. DOI: 10.1016/j.cirpj.2022.11.004.

ZHANG, B.; ZHANG, L.; XU, J. **Degradation feature selection for remaining useful life prediction of rolling element bearings**. *Quality and Reliability Engineering International*, v. 32, n. 2, p. 547–554, 2016. DOI: 10.1002/qre.1771.

ZIEGLER, M. et al. **Virtual sensing of wind turbine hub loads and drivetrain fatigue damage**. *Forschung im Ingenieurwesen*, v. 87, n. 1, p. 1-12, 2023. DOI: 10.1007/s10010-023-00627-0.

ZUO, H.; BI, K.; HAO, H. **A state-of-the-art review on the vibration mitigation of wind turbines**. *Engineering Structures*, v. 252, p. 113-497, 2022. DOI: 10.1016/j.engstruct.2021.113497.