

CATEGORIA 3

O&M



Identificação de falha de refrigeração em aerogeradores utilizando aprendizado de máquina

Nathianne Andrade¹, Letícia Xavier¹, Giovanni Aguiar¹, Brendo Usandizaga¹, Rennan Oliveira²

1 Delfos Energy, 2 V2i Energia S.A.

nathianne.andrade@delfos.energy, leticia.xavier@delfos.energy, giovanni.aguiar@delfos.energy,
brendo.usandizaga@delfos.energy, rennan.oliveira@v2ienergia.com

RESUMO

Este trabalho apresenta um estudo de caso e a metodologia empregada para reduzir o impacto energético das paradas de máquina causadas por alarmes de sobreaquecimento dos componentes mais frequentes em um parque eólico específico. Os resultados foram obtidos através da comparação de dados de paradas de máquinas entre dois períodos de alto vento em anos consecutivos. A aplicação da metodologia proposta resultou em uma redução de 33% no impacto energético das paradas de máquinas devido ao sobreaquecimento em estudo.

Palavras-chaves:

Manutenção Preditiva; Aerogeradores; Causa-raiz; Sistema de Refrigeração

ABSTRACT

This paper presents a case study and the methodology employed to reduce the energy impact of machine downtimes caused by overheating alarms of the most frequent components in a specific wind farm. The results were obtained through the comparison of machine downtime data between two consecutive high-wind periods. The application of the proposed methodology resulted in a reduction of 33% in the energy impact of the machine downtimes due to overheating under study.

Keywords:

Predictive Maintenance; Wind Turbine; Root Cause; Cooling System

1. INTRODUÇÃO

Alarmes de sobreaquecimento ocorrendo na nacele são um dos modos de falha mais comuns em turbinas eólicas. Embora existam sistemas de arrefecimento nos componentes principais da nacele (*gearbox*, gerador, conversor, etc), devido a complexidade das condições de operação das turbinas eólicas torna-se difícil calcular e determinar com precisão a ventilação e transferência de calor dos componentes principais na fase de projeto. Desse modo, o projeto do sistema de arrefecimento pode não atender a demanda real, resultando em alarmes de sobreaquecimento ocorrendo com frequência (Jiang *et al.*, 2015).

Para que esses alarmes sejam reduzidos, faz-se necessário um plano de manutenção que garanta o bom funcionamento de todos os equipamentos, causando a menor indisponibilidade possível com manutenções previamente agendadas. Portanto, é importante que os componentes sejam constantemente monitorados de modo que as intervenções ocorram antes da falha, resultando em um aumento da produtividade e redução dos equipamentos defeituosos (Subtil, 2020).

Dentre os custos gerados por um plano de manutenção que não tem foco em atuar antes da falha (manutenção reativa) estão o acréscimo do risco de quebra de componente e a redução da produção, visto que a intervenção ocorre após a parada da máquina, aumentando a indisponibilidade. Então, para o melhor funcionamento do parque, é preferível que haja um plano de manutenção preditiva (Subtil, 2020).

O presente trabalho tem como objetivo relatar um caso de estudo e a metodologia utilizada a fim de reduzir o impacto energético de paradas de máquina devido a alarmes de sobreaquecimento de componentes mais frequentes para o parque eólico que foi objeto de estudo.

2. FUNDAMENTAÇÃO TEÓRICA

É frequente observar, em parques eólicos, a elaboração de planos de manutenção que se concentram nos sintomas das falhas, em vez de abordarem suas causas raízes. Esta abordagem se justifica pela obtenção de resultados imediatos e pela priorização de esforços em prazos mais curtos. No entanto, a falta de análises de causas raízes e a ausência de retroalimentação dos planos de manutenção a partir dessas análises conferem um caráter reativo, e não preventivo. Tal situação leva à tolerância a falhas recorrentes que provocam interrupções na operação dos parques eólicos, resultando em prejuízos consideráveis à produção. Ademais, a carência de um plano de longo prazo para abordar essas falhas perpetua esses problemas.

2.1. Análise de causa raiz

A análise de causa raiz é um método que tem por princípio a identificação da causa original de um problema e a razão da sua ocorrência, visando a sua prevenção e melhora contínua do processo analisado. A partir desse método é possível identificar o erro inicial e procurar a solução mais adequada para a sua correção.

O método consiste no uso de ferramentas, abordagens e técnicas para o estudo de não conformidades a serem corrigidas por meio da melhoria dos processos. Das ferramentas de análise de causa raiz mais utilizadas tem-se o Diagrama de Ishikawa e o Diagrama de Pareto (Oliveira *et al.*, 2022).

2.2. Diagrama de Ishikawa

O diagrama de Ishikawa, também conhecido como diagrama de causa e efeito ou espinha de peixe, é uma ferramenta amplamente utilizada quando é preciso investigar a causa de um problema. O diagrama se assemelha a uma espinha de peixe com a cabeça representando o efeito a ser analisado e as espinhas representando as causas e subcausas.

A ferramenta está relacionada a seis categorias principais, conhecidas como os “6 Ms” da cadeia produtiva, sendo elas: mão de obra, máquina, material, método, meio ambiente e medida. Esses elementos representam as diferentes áreas que podem influenciar um processo e causar problemas quando não estão funcionando como esperado.

No diagrama de Ishikawa as categorias dos “6 Ms” são representadas como as espinhas principais, a partir das quais são traçadas linhas que representam as possíveis causas que podem estar relacionadas com o problema em questão. Essa ferramenta ajuda a visualizar e organizar informações

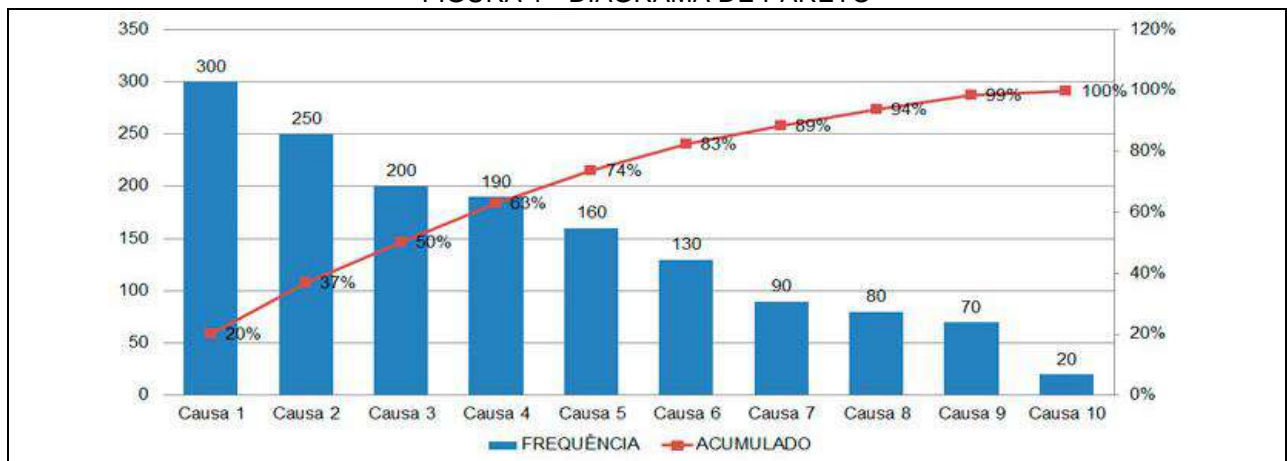
relacionadas ao problema, facilitando a identificação das potenciais causas raízes e orientando para encontrar soluções adequadas (Inácio *et al.*, 2023).

2.3. Diagrama de Pareto

Introduzido pelo economista Vilfredo Pareto, o diagrama de Pareto é uma ferramenta gráfica de análise amplamente utilizada na gestão de qualidade que auxilia na identificação e priorização dos fatores ou causas de início para a maior parte dos problemas em determinado cenário. A ferramenta parte do princípio que a maioria dos efeitos é resultado de um número relativamente pequeno de causas. Então, para a priorização das ações corretivas ou de melhoria que apresentem maior impacto na resolução dos problemas é necessário identificar as causas principais.

Para a construção de um diagrama de Pareto deve-se seguir os seguintes passos: coleta de dados, classificação dos dados, contagem das ocorrências, ordenação dos dados e por fim a construção do gráfico. Na análise dos resultados é possível identificar as “causas resistentes”, ou seja, as poucas categorias responsáveis pela maior parte dos problemas (Inácio *et al.*, 2023).

FIGURA 1 - DIAGRAMA DE PARETO



FONTE: Soares (2024).

2.4. Predições de falhas utilizando redes neurais

Uma Rede Neural Artificial (RNA) é um sistema de dados complexo que utiliza computação paralela para imitar a aprendizagem biológica das redes neurais humanas. Existem diversas arquiteturas de RNAs, mas a maioria possui: uma camada de entrada para dados (variáveis de entrada); uma ou mais camadas intermediárias onde algoritmos de *Backpropagation* ajustam os pesos das funções de ativação iterativamente para minimizar erros de predição; e uma camada de saída que fornece a resposta (variável de saída).

Na predição de falhas, esses modelos se destacam por sua capacidade de lidar com problemas não-lineares complexos sem a necessidade de conhecimento especializado profundo (Zhang, 2018). Durante o treinamento, várias estratégias garantem que o modelo funcione bem com novos dados não vistos anteriormente, um processo conhecido como validação, que é crucial para evitar o *overfitting*. Após a validação, a RNA é considerada confiável se o erro entre os valores reais e preditos, medido pelo Erro Quadrático Médio (EQM), for aceitável. A fase de teste subsequente avalia a qualidade do modelo. Fatores como a qualidade e diversidade dos dados de entrada e o período de treinamento influenciam a precisão do modelo. Um modelo bem calibrado pode identificar comportamentos normais da variável monitorada e detectar desvios além dos limites operacionais, permitindo ações preventivas e/ou corretivas antes de falhas funcionais.

Em indústrias com muitos ativos, a automação inteligente e responsiva é essencial para monitorar todos os componentes críticos dos aerogeradores. Modelos de aprendizado de máquina baseados em RNAs são fundamentais para a Operação e Manutenção (O&M), proporcionando benefícios financeiros significativos. A redução dos períodos de inatividade devido a falhas nos componentes de arrefecimento pode oferecer uma vantagem competitiva significativa para o setor.

3. MÉTODO DO ESTUDO

3.1. Caso de estudo

O presente estudo de caso refere-se ao parque eólico Mangue Seco (Guamaré - RN), composto por 39 aerogeradores Enercon E82 de 2,0 MW, em operação no nordeste do Brasil há 13 anos. Foi utilizado dados operacionais do período de ventos fortes entre 1º de setembro de 2022 e 31 de dezembro de 2022 como referência do estudo e o período entre 1º de setembro de 2023 e 31 de dezembro de 2023 para fins de comparação e obtenção dos resultados.

Atualmente, o parque é operado pela V2i Energia S.A. (V2i), empresa que atua no mercado de energia renovável com uma perspectiva global, especializada no desenvolvimento, implementação e gestão de ativos no setor elétrico, abrangendo projetos de transmissão e geração de energia elétrica. A V2i monitora o parque eólico por meio da Plataforma de monitoramento da Delfos, uma ferramenta especializada em monitoramento e previsão de falhas em ativos de energia renovável. A manutenção do parque é realizada pela Wobben Windpower. Este estudo de caso foi conduzido em conjunto pelas equipes técnicas das empresas V2i, Delfos e Wobben.

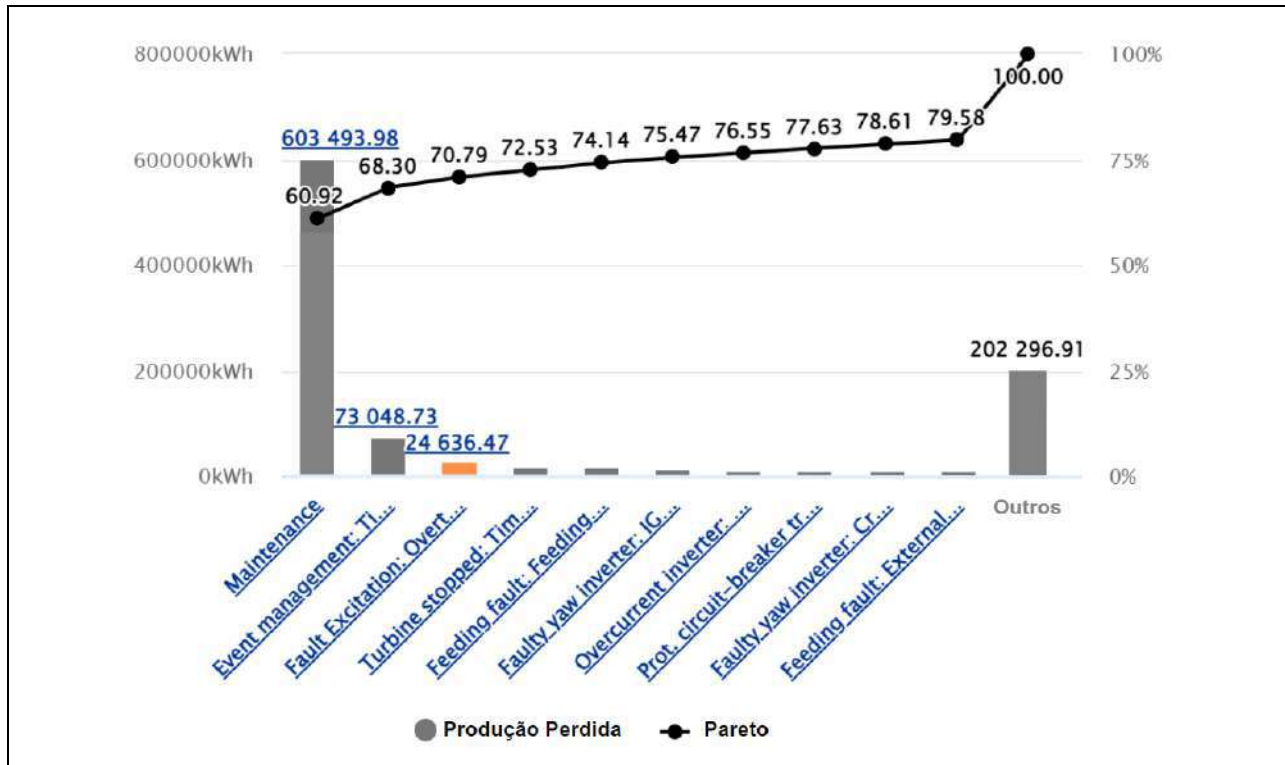
3.2. Definição do escopo da análise de causa raiz

O complexo estudado apresentava paradas recorrentes, cujas causas raízes ainda não haviam sido identificadas nem abordadas nos planos de manutenção, os quais se concentravam no tratamento dos sintomas dessas causas.

Com o objetivo de determinar quais falhas requeriam maior atenção, todas as paradas ocorridas no período de referência foram organizadas em um gráfico de Pareto, classificado por tipo de falha de acordo com a energia frustrada durante as paradas, disponível na ferramenta de monitoramento da empresa Delfos, conforme Figura 2.

Observa-se que, em primeiro lugar, estão as 171 paradas classificadas como "Maintenance", as quais estão relacionadas com as horas planejadas e executadas no plano de manutenção, visto que o alarme só é enviado quando a equipe inicia a atividade. Desse modo, o alarme não representa um problema com uma causa raiz específica, mas sim um sintoma de paradas com causas diversas. Em segundo lugar, encontram-se as 69 paradas categorizadas como "Event Management: timeout receivebuffer", o alarme ocorre devido a perda de comunicação com o aerogerador, a qual por ocorrer por diversas razões, porém, na maioria das situações, ocorre durante a manutenção de outra máquina se as mesmas estiverem ligadas em série. Portanto, essa falha corresponde a um conjunto diversificado de tipos de paradas. Dessa maneira, antes de iniciar uma análise de causa raiz, seria necessário reclassificar essas paradas em tipos específicos. Devido à complexidade dessa tarefa, essas falhas foram excluídas do escopo deste estudo, sendo recomendadas para investigações futuras. Conseqüentemente, o tipo de falha selecionado para a análise de causa raiz foi "Failure Excitation: Overtemperature Heatsink", que ocorreu 136 vezes durante o período de referência.

FIGURA 2 - ANÁLISE DE PARETO DO IMPACTO ENERGÉTICO DE PARADAS DE 2022



FONTE: Os Autores (2024) adaptado de Plataforma de Monitoramento Delfos (2024).

3.3. Falha pelo alarme "Failure Excitation: Overtemperature Heatsink"

O alarme "Failure Excitation: Overtemperature Heatsink" refere-se a um mau funcionamento no gabinete do reostato de excitação, ilustrado na Figura 3. Este gabinete fornece a corrente necessária ao rotor do gerador para a geração do campo magnético (campo de excitação) posicionado na parte traseira da nacelle.

FIGURA 3 - GABINETE DO REOSTATO DE EXCITAÇÃO ABERTO



FONTE: Relatório Técnico 80.10 V2i Energia (2024).

Durante a condução deste estudo, foi descoberto que a causa raiz mais comum desse alarme está associada a uma falha no componente de arrefecimento, um ventilador de fluxo cruzado, ilustrado na Figura 4. O ventilador é localizado dentro do gabinete do reostato de excitação, sendo acionado quando a temperatura do *heatsink* ultrapassa 60°C. O padrão operacional dessa temperatura para os aerogeradores do caso de estudo é:

- Padrão saudável: A temperatura ideal de operação do *heatsink* é em torno de 45°C.
- Limite crítico: O aerogerador é programado para parar quando a temperatura do *heatsink* atinge 80°C a fim de evitar danos.

FIGURA 4 - VENTILADOR DE FLUXO CRUZADO SOBRESSALENTE



FONTE: Relatório Técnico 80.10 V2i Energia (2024).

O controle dos aerogeradores do parque eólico Mangue Seco permite que o alarme "Failure Excitation: Overtemperature Heatsink" cause paradas das máquinas, seguidas por uma retomada automática à operação, até 10 vezes consecutivas. Após esse número de eventos, o aerogerador deixa de reiniciar automaticamente, exigindo uma intervenção manual remota. Após essa intervenção remota, a máquina pode novamente repetir 10 eventos de falha antes que seja necessária a intervenção da equipe local. Quando a retomada automática está habilitada, os alarmes duram em média 2 minutos, contudo, o tempo total de retorno à operação da máquina é em média 10 minutos por ocorrência. O impacto operacional destes alarmes é maior quando intervenções manuais remotas ou locais são necessárias, podendo levar várias horas para que a operação seja retomada.

3.4. Diagrama de Ishikawa aplicado

A metodologia utilizada para a análise de causa raiz foi o diagrama de Ishikawa. Para a aplicação desta metodologia, foram reunidos três grupos de especialistas técnicos: especialistas da empresa de monitoramento de ativos de energia renovável Delfos, especialistas da empresa empreendedora V2i e especialistas da fornecedora de serviços de O&M Wobben. O efeito considerado para o diagrama foi a alta frequência de paradas devido ao alarme "Failure Excitation: Overtemperature Heatsink", conforme ilustrado na Figura 5.

FIGURA 5 - DIAGRAMA DE ISHIKAWA APLICADO AO CASO DE ESTUDO



FONTE: Os Autores (2024).

Baseando-se nos "6M's", conforme ilustrado na Figura 5, as possíveis causas raízes identificadas foram:

- Mau dimensionamento
- Falta de peças de reposição
- Horários limitados de atuação da Equipe de Manutenção
- Alta salinidade
- Temperatura ambiente elevada
- Falha no ventilador de fluxo cruzado
- Ausência de ferramenta de monitoramento da temperatura do *heatsink*
- Intervenções locais após 20 paradas de máquina
- Intervenção não baseada na probabilidade da máquina parar em breve

As duas primeiras causas não foram incluídas no plano de ação, pois não havia evidências de problemas relacionados à falta de peças de reposição ou ao dimensionamento inadequado do componente. As causas referentes aos horários limitados de atuação da Equipe de Manutenção, alta salinidade e temperatura ambiente elevada também foram desconsideradas, uma vez que estas não eram gerenciáveis pelos times de especialistas que conduziram o estudo e seriam responsáveis pelo plano de ação.

O plano de ação focou-se, portanto, nas quatro últimas causas mencionadas. Dado que a falha do ventilador de fluxo cruzado era o reparo mais comum realizado em casos de parada de máquina devido ao alarme em questão, decidiu-se desenvolver uma ferramenta dedicada ao monitoramento desse componente. Ainda, tornou-se necessário readequar o plano de manutenção inicial. Essa abordagem era baseada na atuação em aerogeradores que já haviam parado por um número estipulado de vezes e que eram indicados pela ferramenta de monitoramento. A nova abordagem deve ser preventiva e estar alinhada com a nova ferramenta de monitoramento proposta no plano de ação.

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

O plano de ação consistiu em atuar nas causas raízes relacionadas e apresentadas na etapa da metodologia: implementação de uma ferramenta de monitoramento preventiva e de um plano de manutenção preventivo.

4.1. Ferramenta de monitoramento

O monitoramento deve ser um sistema que acompanha de forma contínua a temperatura do *heatsink* dos aerogeradores. Sua função principal deve garantir que a operação dos aerogeradores permaneça dentro de limites seguros, evitando falhas ou paradas inesperadas. Em resumo, a ferramenta de monitoramento deve ser capaz de:

- Monitorar constantemente a temperatura do *heatsink*.
- Gerar alertas preditivos antes que a temperatura atinja níveis críticos.
- Classificar a severidade dos alertas para priorizar quais aerogeradores necessitam de intervenção imediata.

Foi desenvolvido uma ferramenta utilizando redes neurais para prever a temperatura esperada do *heatsink* dadas as condições operacionais do aerogerador. As condições utilizadas como dado (10-minutais) de entrada para treinamento e monitoramento da rede neural foram: produção do aerogerador, temperatura da nacelle, temperatura ambiente.

Alertas automáticos foram gerados quando a diferença entre a temperatura do *heatsink* medida e predita excedia um limite estatístico. Essa diferença é denominada erro, e o limite estatístico, *threshold*. O cálculo do *threshold* representa a incerteza da predição da rede neural artificial, sendo determinado a partir de um percentil pré-estabelecido da distribuição do erro, obtido na fase de teste do modelo.

Para estabelecer o critério de geração de alarmes preditivos, utilizou-se a mediana horária do erro de predição acima do *threshold*. Quando havia mais de 6 pontos acima do *threshold* nos últimos sete dias, o alerta preditivo era criado. Dessa forma, a lista de alertas automáticos identifica os aerogeradores em risco de sofrer paradas devido ao alarme "Failure Excitation: Overtemperature Heatsink". A priorização dos aerogeradores dentro do grupo de risco foi realizada comparando-se a quantidade de pontos horários acima do *threshold*.

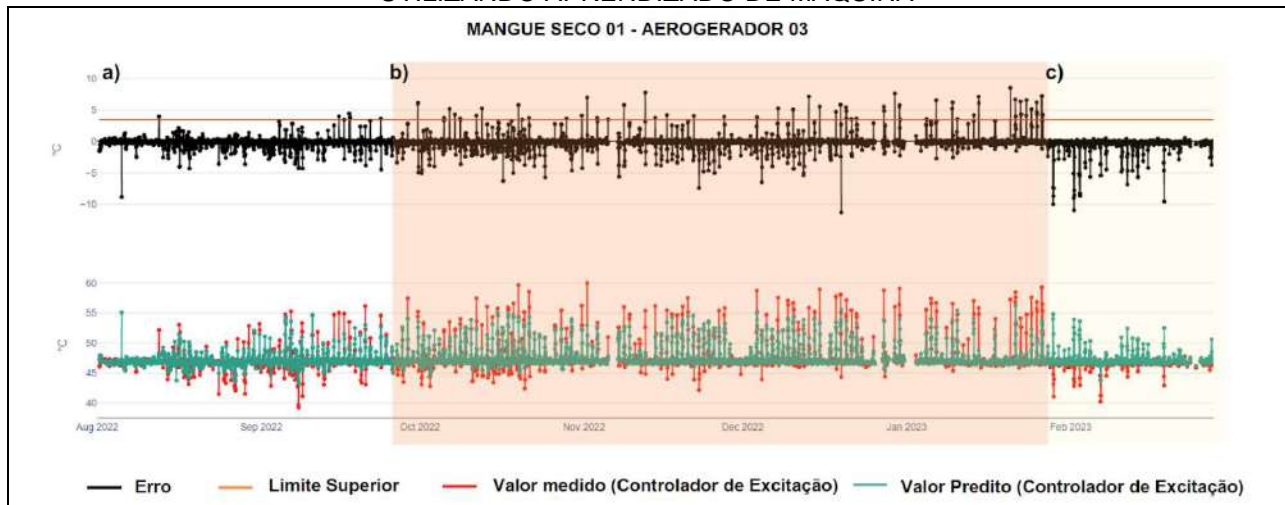
A ferramenta foi implementada pela Delfos e disponibilizada na Plataforma de monitoramento do parque eólico de Mangue Seco. A visualização da ferramenta pode ser vista na Figura 6, onde é possível observar o monitoramento de um aerogerador durante três fases: antes (a) e durante o mau funcionamento do ventilador (b) e após o reparo (c).

4.2. Plano de manutenção preventivo

O plano de manutenção preventivo difere do plano de manutenção do período de referência devido ao seu caráter não reativo: a tomada de decisão de inspeção e troca do componente ventilador de fluxo cruzado do reostato passou a ser baseada nos alertas da nova ferramenta de monitoramento e não na contagem de ocorrências sucessivas de parada de máquinas devido ao alarme "Failure Excitation: Overtemperature Heatsink".

A ferramenta de monitoramento do padrão de temperatura passou a ser utilizada semanalmente pelos times da Delfos e da V2i para definir o grupo de aerogeradores que estavam em risco de sofrer paradas relacionadas ao alarme "Failure Excitation: Overtemperature Heatsink", com base no padrão operacional da temperatura do *heatsink*. A priorização dos esforços de intervenção dentre os

FIGURA 6 - MONITORAMENTO DA TEMPERATURA DO HEATSINK UTILIZANDO APRENDIZADO DE MÁQUINA



LEGENDA: Os valores da temperatura prevista estão em verde. Os valores da temperatura medida estão em vermelho. A diferença entre os valores medidos e previstos, chamado de erro, estão representados em preto. O *threshold* está representado em laranja no gráfico superior.

FONTE: Os Autores (2024) adaptado de Plataforma de Monitoramento Delfos (2024).

aerogeradores do grupo de risco passou a ser realizada diariamente pelo time da V2i, com base na ferramenta de monitoramento de tempo de operação acima de 65°C.

De posse de tais alertas e da priorização, a equipe V2i aciona a equipe da Wobben diariamente, a fim de alinhar quais aerogeradores precisavam da intervenção preventiva no ventilador de fluxo cruzado. Devido ao caráter preventivo das intervenções, estas poderiam acontecer em momentos de ventos baixos, uma vez que esta atividade estaria sendo realizada antes mesmo das paradas causadas pelo alarme “Failure Excitation: Overtemperature Heatsink”. Essa característica também contribui para diminuir o impacto energético das paradas de manutenção.

4.3. Avaliação do plano de ação

O plano de ação detalhado foi aplicado no ano de 2023 e os resultados foram obtidos a partir da comparação entre os períodos de altos ventos de 2022 (período de referência, pré-plano de ação) e de 2023 (período de avaliação, pós plano de ação). As métricas utilizadas para comparação entre os dois períodos foram:

- Duração e impacto energético das paradas causadas pelo alarme “Failure Excitation: Overtemperature Heatsink”
- Duração e impacto energético das paradas para manutenção

Os resultados comparativos foram obtidos por meio da ferramenta de monitoramento da Delfos, já implementada para o complexo eólico em questão desde setembro de 2022. No Quadro 1, são apresentados os resultados comparativos entre o período de referência e o período de avaliação após a implementação das melhorias no plano de manutenção para falhas de refrigeração no gabinete do reostato. Em 2022, o total de horas de parada foi de 40,82 horas, resultando em 24.636,47 kWh de energia não gerada. Em 2023, esses valores diminuíram para 16,07 horas de parada e 16.352,92 kWh de energia não gerada, indicando uma redução significativa.

QUADRO 1 - RESULTADOS COMPARATIVOS DE PARADAS POR
“FAILURE EXCITATION: OVERTEMPERATURE HEATSINK”

	2022 - Período de Referência	2023 - Período de Avaliação	Diferença Absoluta	Diferença relativa
Duração das paradas (h)	40,82	16,17	24,65	-60,39%
Impacto energético das paradas (kWh)	24.636,47	16.352,92	8.283,55	-33,62%

FONTE: Os Autores (2024).

Além disso, as métricas de impacto das manutenções também apresentaram uma redução de cerca de 11% na duração das manutenções, como pode ser observado no Quadro 2. Embora seja esperado que o plano de ação tenha contribuído para os resultados observados nas paradas por manutenção, não se pode afirmar que todas as reduções nas métricas de impacto das manutenções se devem exclusivamente ao plano de ação explorado neste estudo.

QUADRO 2 - RESULTADOS COMPARATIVOS DE PARADAS POR MANUTENÇÃO

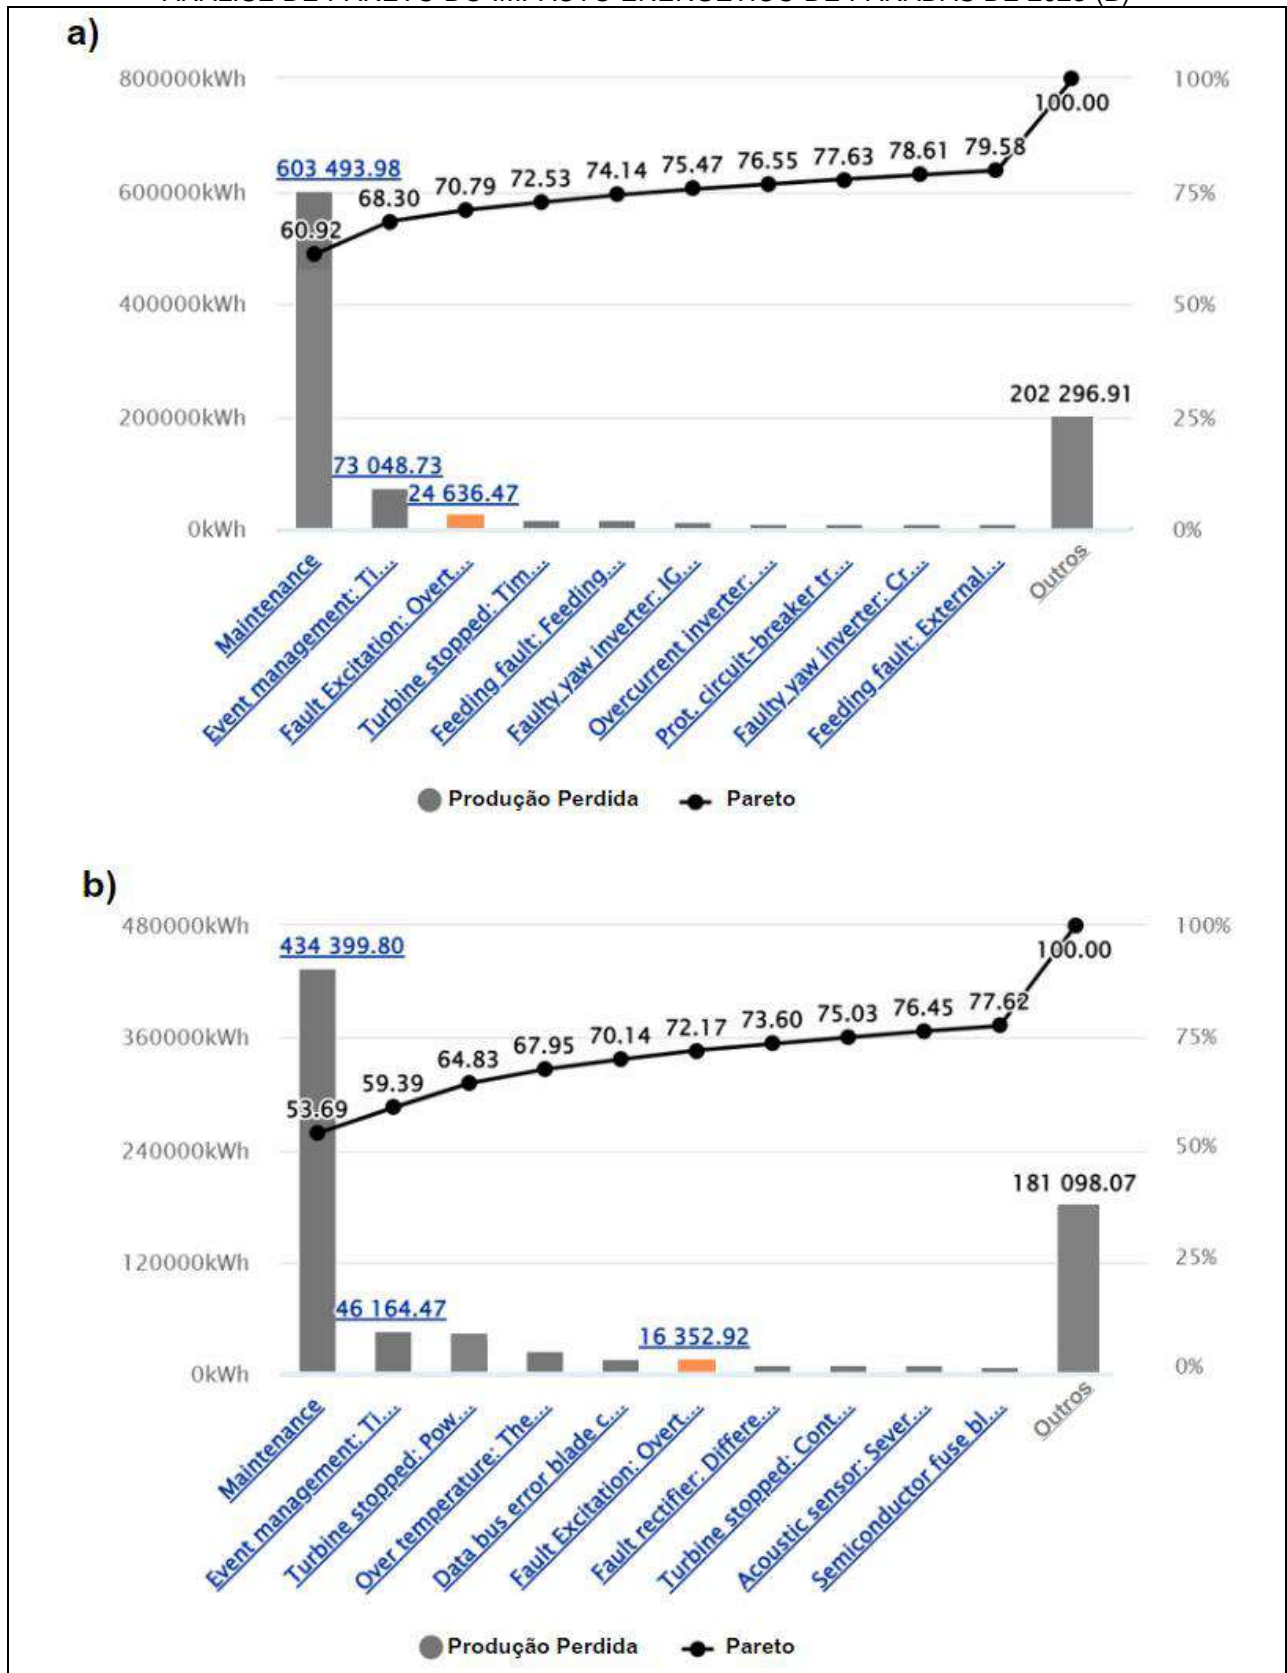
	2022 - Período de Referência	2023 - Período de Avaliação	Diferença Absoluta	Diferença relativa
Duração das paradas (h)	725,19	644,67	80,52	-11,10%
Impacto energético das paradas (kWh)	603.493,98	434.399,80	169.094,18	-28,02%

FONTE: Os Autores (2024).

A análise dos diagramas de Pareto para os anos de 2022 (Figura 7a) e 2023 (Figura 7b) revela uma mudança substancial no impacto do alarme "Fault Excitation: Overtemperature Heatsink". De acordo com a Figura 7 e o Quadro 3, essa falha era a terceira maior causa de paradas em 2022, representando 3,14% de toda perda energética. Após a implementação do plano de manutenção preventiva, essa falha passou a ser a sexta maior causa de paradas em 2023, representando apenas 2,03% de toda a perda energética.

A execução do plano de ação implementado permitiu reduções significativas nas métricas relacionadas ao impacto das paradas causadas pelo alarme "Failure Excitation: Overtemperature Heatsink", atingindo até 60,39% de redução na duração dos paradas relacionadas e 33,62% no impacto energético destes. O efeito do plano de ação também pode ser observado quando comparamos o Pareto de impacto energético das paradas de máquina: enquanto que as paradas pelo o alarme eram responsáveis por 3,14% de toda a energia frustrada no período de referência; no período de avaliação, essa contribuição caiu em 1,11 pontos percentuais.

FIGURA 7 - ANÁLISE DE PARETO DO IMPACTO ENERGÉTICO DE PARADAS DE 2022 (A) E ANÁLISE DE PARETO DO IMPACTO ENERGÉTICO DE PARADAS DE 2023 (B)



FONTE: Os Autores (2024) adaptado de Plataforma de Monitoramento Delfos (2024).

QUADRO 3 - CONTRIBUIÇÃO DO ALARME “FAILURE EXCITATION: OVERTEMPERATURE HEATSINK” PARA O TOTAL DE ENERGIA FRUSTRADA

	2022 - Período de Referência	2023 - Período de Avaliação	Diferença em p.p.
Contribuição (%)	3,14	2,03	-1,11

FONTE: Os Autores (2024).

5. CONCLUSÕES E RECOMENDAÇÕES

Alarmes de sobreaquecimento em componentes na nacele de turbinas eólicas representam uma das causas mais comuns de paradas de máquinas. A mitigação desses alarmes pode ser alcançada através de planos de manutenção preventiva, resultando em menores períodos de indisponibilidade e permitindo a otimização dos momentos de reparo preventivo, alinhados com as janelas de baixo recurso eólico. O complexo em estudo apresentava paradas recorrentes, cujas causas raízes não haviam sido identificadas nem abordadas em planos de manutenção anteriores. A partir da análise das paradas de máquina no período de referência, a falha decorrente do alarme "Failure Excitation: Overtemperature Heatsink" foi selecionada por ser uma das mais frequentes. Após a investigação, foram identificados os seguintes fatores como possíveis causas raízes: falha do ventilador de fluxo cruzado; ausência de ferramenta de monitoramento especializada; e intervenções locais e remotas não preditivas.

Para abordar os problemas evidenciados pela análise de causa raiz, foi desenvolvida uma ferramenta baseada em redes neurais para prever a temperatura esperada do *heatsink* (dissipador de calor) dadas as condições operacionais, com envio de alertas automáticos quando a diferença entre a temperatura medida e a predita excedia um limite estatístico. Ademais, o plano de manutenção foi revisado, passando a incluir intervenções baseadas no monitoramento preventivo.

A aplicação da ferramenta e do novo plano de manutenção na safra de vento subsequente obteve resultados significativos. A inspeção e troca do componente ventilador passaram a ser baseadas nos alertas da nova ferramenta de monitoramento, resultando na diminuição da duração das manutenções e das paradas relacionadas em 11% e 60%, respectivamente. Com base nos resultados, o monitoramento mais especializado e a reformulação do plano de manutenção trouxeram ganhos energéticos expressivos, reduzindo em 34% o impacto energético da falha monitorada pelo sistema desenvolvido e diminuindo a sua contribuição percentual para o total de energia frustradas em 1,11 pontos percentuais. Por fim, ressalta-se que a metodologia explorada neste trabalho pode ser aplicada para aprimorar os planos de manutenção de outras falhas do parque eólico em estudo ou mesmo em outros parques eólicos.

REFERÊNCIAS

OLIVEIRA, M. de A. S.; NOLETO, L. M.; FERREIRA, B. F. Análise de causa raiz aplicada em uma subestação termoeétrica. *In*: CONGRESSO INTERNACIONAL DE ENGENHARIA MECÂNICA E INDUSTRIAL, 22, 2022, São Paulo. **INOVAÇÃO TECNOLÓGICA: Os novos rumos da Engenharia Mecânica e Industrial**. 2022.

INÁCIO, L. C. dos R. *et al.* Ferramentas básicas da qualidade: folha de verificação, estratificação, fluxograma, diagrama de Ishikawa, diagrama de Pareto, matriz GUT e 5W2H. **Revista de Gestão e Secretariado**, São Paulo, v. 14, n. 10, p. 17413–17427, 2023.

JIANG, R. *et al.* **Fault mode, effects and criticality analysis for overheating fault of wind turbines gearbox and generator**. *In*: International Conference on Renewable Power Generation (RPG 2015), 2015, Beijing, China. **Anais...** 2015.

SUBTIL, F. **Monitorização e Análise de Desempenho da Manutenção de Parques Eólicos**. 2020. Tese (Mestrado em Engenharia Eletrotécnica e de Computadores) - Universidade do Porto, Faculdade de Engenharia, Portugal, 2020.

SOARES, V. **Na Prática: Diagrama de Pareto: o que é, como usar**. Disponível em: <https://www.napratica.org.br/diagrama-de-pareto/>. Acesso em: 24 jun. 2024.

ZHANG, Z. Automatic Fault Prediction of Wind Turbine Main Bearing Based on SCADA Data and Artificial Neural Network. **Open Journal of Applied Sciences**, [S.L.], v. 08, n. 06, p. 211-225, 2018.

Análise de vibrações *flapwise* em pás de aerogeradores

Nikolas Lukin¹, Raquel Jahara Lobosco²

¹Petrobras, CENPES, ²UFRJ, Departamento de Engenharia Mecânica

nikolas.lukin@petrobras.com.br, raquelobosco@poli.ufrj.br

RESUMO

Atualmente, o Brasil está passando por uma transição energética, com o crescimento significativo da energia eólica. Nesse contexto, os aerogeradores têm se tornado cada vez maiores e mais potentes, exigindo uma abordagem sofisticada no controle de vibrações para evitar falhas operacionais. Devido ao tamanho dos aerogeradores modernos, realizar testes em laboratórios ou túneis de vento para prever os efeitos do escoamento nas vibrações das pás representa um desafio significativo e, dessa forma, a simulação numérica surge como uma alternativa viável. Este trabalho propõe a modelagem da pá de um aerogerador pelo modelo de viga de Euler-Bernoulli, utilizando metodologias analíticas e numéricas, fundamentadas na dinâmica de sistemas elásticos de múltiplos corpos. Inicialmente, com o objetivo de validar o método e estabelecer uma malha adequada para essa análise, foi realizada uma comparação da resposta estática e da análise modal do modelo numérico proposto com a solução analítica usando uma geometria simplificada. Em uma segunda fase, a análise da resposta dinâmica dos deslocamentos da pá durante sua operação foi conduzida por meio de simulações numéricas sob condições de fluxo turbulento de vento, tendo como referência a turbina de 10MW da DTU (LR10-MW RWT). Esta pesquisa identificou um cenário operacional adverso onde a frequência natural de vibração da pá se aproximou da frequência de excitação causada pela redução da sua rigidez, potencialmente levando à uma falha catastrófica do equipamento, o qual foi explorado na simulação. Neste cenário, as amplitudes de vibração aumentam consideravelmente e, conseqüentemente, a fadiga e a colisão da pá com a torre tornam-se críticas. Assim, este estudo contribui para a análise da confiabilidade das turbinas eólicas e para a previsibilidade operacional, fornecendo valiosos parâmetros para o contínuo avanço eficiente da energia eólica.

Palavras-chaves: Energia eólica; Modelo numérico; Vibrações

ABSTRACT

Currently, Brazil is going through an energy transition, with significant growth in wind energy. In this context, wind turbines have become increasingly larger and more powerful, requiring a sophisticated approach to vibration control to avoid operational failures. Due to the size of modern wind turbines, carrying out tests in laboratories or wind tunnels to predict the effects of flow on blade vibrations represents a significant challenge and, therefore, numerical simulation emerges as a feasible alternative. This work proposes the modeling of a wind turbine blade using Euler-Bernoulli beam model, considering analytical and numerical methodologies, based on the dynamics of elastic systems of multiple bodies. Initially, with the aim of validating the method and establishing an adequate mesh for this analysis, a comparison of the static response and modal analysis of the proposed numerical model was carried out with the analytical solution using a simplified geometry. In a second phase, the analysis of the dynamic response of blade displacements during its operation was conducted through numerical simulations under conditions of turbulent wind flow, using DTU's 10MW turbine (LR10-MW RWT) as a reference. This research identified an adverse operational scenario where the natural vibration frequency of the blade approached the excitation frequency caused by the reduction in its stiffness, potentially leading to a catastrophic failure of the equipment, which was explored in the simulation. In this scenario, vibration amplitudes increase considerably and, consequently, fatigue and collision of the blade with the tower become critical. Thus, this study contributes to the analysis of wind turbine reliability and operational predictability, providing valuable parameters for the continuous efficient advancement of wind energy.

Keywords: Wind energy; Numerical model; Vibrations

1. INTRODUÇÃO

O padrão de consumo do século passado não é mais viável e o mundo demanda pelo desenvolvimento sustentável. Neste âmbito, a Organização das Nações Unidas (ONU) elaborou 17 objetivos como parte do compromisso global da agenda 2030. Entre esses objetivos, destacam-se o desenvolvimento de energias limpas, medidas de combate às mudanças climáticas e a promoção da inovação na indústria e infraestrutura [1]. Uma abordagem eficaz para alcançar esses é através da implementação da energia eólica. Baseada em uma fonte renovável, a energia eólica não emite carbono fóssil durante sua operação. Além disso, a expansão da energia eólica impulsiona o desenvolvimento tecnológico, fomentando a criação de novas soluções e avanços no setor energético renovável em conformidade com os objetivos do desenvolvimento sustentável.

A extração da energia eólica se dá através da conversão da energia cinética do vento em energia elétrica utilizando aerogeradores, que são equipamentos capazes de fazer a captação, transformação e transmissão dessa energia. Na maioria dos aerogeradores, a primeira etapa desse processo de conversão de energia ocorre nas pás, onde o seu perfil aerodinâmico promove a transferência do movimento do vento, gerando forças de reação em sua superfície e impulsionando a rotação das pás em conjunto com o rotor. Essa rotação, por sua vez, induzirá tensões no gerador correspondente [2]. Desde a sua concepção, os aerogeradores têm se tornado cada vez maiores para aproveitar melhor a energia do vento e obter ganhos de escala. Atualmente, existem aerogeradores com pás com mais de 100m de comprimento (Figura 1) [3].




Figura 1 - Evolução dos aerogeradores ao longo do tempo

Entretanto, à medida que os aerogeradores crescem em tamanho, os desafios tecnológicos também se intensificam. Isso se deve, em parte, ao fato de que eles não podem mais ser considerados simples corpos rígidos imersos em um campo uniforme de vento, devendo ter incorporados os efeitos aero-elásticos no seu projeto [4]. Conseqüentemente, estas máquinas estão sujeitas a vibrações durante sua operação que em nada contribuem para a geração de energia, mas prejudicam a sua durabilidade devido a esforços excessivos e fadiga [5].

As pás dos aerogeradores possuem basicamente 3 modos relevantes de vibração: "torcional" (rotação em torno do seu eixo longitudinal), "edgewise" (no plano de rotação) e "flapwise" (fora do plano de torção). Normalmente, a vibração *flapwise* está associada ao menor momento de inércia da pá (conseqüentemente à menor rigidez flexural), à menor frequência natural e aos maiores deslocamentos, onde além da ocorrência da fadiga, a pá está sujeita à colisão com a torre do aerogerador [6]. Muitas falhas observadas em campo são diretamente decorrentes deste movimento (Figura 2).




Figura 2 - Colisão da pá com a torre devido ao movimento flapwise (Adaptado de [6] e [7])

O estudo das vibrações nas pás surgiu inicialmente no desenvolvimento de helicópteros [8] e foi logo estendido para os aerogeradores. Este trabalho está focado na modelagem do modo de vibração *flapwise* nas pás eólicas de grande comprimento. Devido ao tamanho das pás dificilmente será possível fazer testes em laboratório ou em túneis de vento para prever os efeitos do vento sobre as vibrações da estrutura. Neste caso, a simulação numérica torna-se, portanto, uma alternativa viável. Cabe notar que, atualmente, as simulações numéricas são utilizadas para o projeto e certificação dos aerogeradores, mas a sua utilização não considera a variação das propriedades dos materiais, os quais terão de suportar uma operação contínua por pelo menos 20 anos em ambientes agressivos (Figura 3) [8]. Este trabalho explora esta lacuna na literatura.




Figura 3 - Exemplo de dano na pá provocado na sua operação

2. ESTADO DA ARTE/ FUNDAMENTAÇÃO TEÓRICA

Na última década, muitas análises numéricas foram desenvolvidas para caracterizar a vibração de pás de aerogeradores [10]. No entanto, a abordagem que oferece a melhor relação precisão / custo computacional para a análise estrutural é a dinâmica de multi-corpos elásticos [11], base dos softwares *Bladed* e *OpenFAST*, os quais são utilizados no projeto e certificação de aerogeradores. Seguindo esta metodologia, este trabalho utilizou o modelo de viga de Euler-Bernoulli para modelar a dinâmica das pás eólicas. Segundo este modelo, a curvatura de uma viga decorre dos momentos transversais a ela aplicadas, desconsiderando os deslocamentos decorrentes do cisalhamento. Esta hipótese se mostra aderente à realidade quando a viga é esbelta, ou seja, quando a razão entre o seu comprimento e

espessura é maior que 20 e para a análise de vibrações em baixa frequência como é o caso dos aerogeradores [12]. Para tornar este modelo mais realista, são incluídos no modelo os efeitos centrífugos e do peso próprio na sua rigidez, os quais variam respectivamente em função da rotação e do azimute, definido como o ângulo entre a pá e a linha vertical. A equação constitutiva (Eq. 1) é formulada com base na orientação dos eixos prevista pela IEC 61400.

$$EI_y(z) \frac{\partial^4 u}{\partial z^4} + 2 \frac{\partial EI_y(z)}{\partial z} \frac{\partial^3 u}{\partial z^3} + \left[mg(L-z)\cos(\theta) - 0.5m\omega^2(L^2 - z^2) + \frac{\partial^2 EI_y}{\partial z^2} \right] \frac{\partial^2 u}{\partial z^2} + [m\omega^2 z - mg\cos(\theta)] \frac{\partial u}{\partial z} + m \frac{\partial^2 u}{\partial t^2} + b \frac{\partial u}{\partial t} = q(z) \quad (1)$$

em que θ é o ângulo de azimute e as condições de contorno do problema são o engastamento da raiz e a ausência de esforços na ponta da pá,

$$u(0) = \frac{\partial u(0)}{\partial z} = \frac{\partial^2 u(L)}{\partial z^2} = \frac{\partial^3 u(L)}{\partial z^3} = 0 \quad (2)$$

A Equação 1 pode ser resolvida analiticamente em uma condição muito específica, considerando uma geometria uniforme, sem rotação e posicionada em um azimute de 90° . Os deslocamentos, neste caso, são calculados por,

$$u(z) = \frac{1}{EI} \left(\frac{(Q_0 c_h)}{24} z^4 + \frac{(Q_0 c_h)L}{6} z^3 + \frac{(Q_0 c_h)L^2}{4} z^2 \right) \quad (3)$$

Ademais, neste modelo, os modos e frequências naturais também podem ser obtidos analiticamente,

$$u(z) = \text{sen}(k_n z) - \text{senh}(k_n z) - \left(\frac{\text{sen}(k_n L) + \text{senh}(k_n L)}{\text{cos}(k_n L) + \text{cosh}(k_n L)} \right) (\text{cos}(k_n z) + \text{cosh}(k_n z)) \quad (4)$$

$$f_n = \frac{k_n^2}{2\pi} \sqrt{\frac{EI}{m}}, \text{ com } k_n = \begin{cases} n = 1, k_1 = 1.875 \\ n = 2, k_2 = 4.694 \\ n \geq 3, k_n \cong \left(n - \frac{1}{2}\right) \pi \end{cases} \quad (5)$$

Para o caso geral, a Equação 1 pode ser reorganizada em função dos seus termos relacionados à uma derivada espacial ou temporal do deslocamento,

$$Au_{,zzzz} + Bu_{,zzz} + Cu_{,zz} + Du_{,z} + m\ddot{u} + b\dot{u} = q \quad (6)$$

A qual pode ser discretizada utilizando o método de diferenças finitas e as equações resultantes podem ser organizadas na forma de um sistema dinâmico,

$$[M]\{\ddot{u}\} + [B]\{\dot{u}\} + [K]\{u\} = q \quad (7)$$

Os autovalores (ω_n^2) e os autovetores (X_i) da equação característica (8) são respectivamente as frequências naturais e os modos de vibração da pá, os quais são obtidos por,

$$\omega_n^2 [M]X_i = [K]X_i \quad (8)$$

Os carregamentos aerodinâmicos transversais $q(z)$ variam ao longo da pá, em função da velocidade relativa do vento e da geometria da pá e, em especial, ao perfil do aerofólio o qual determina o seu arrasto e sustentação em diferentes ângulos de ataque φ . Esta relação é descrita pelas curvas polares. Dos carregamentos gerados (arrasto e sustentação), as vibrações *flapwise* são afetadas pelas componentes normais à linha da corda e podem ser determinados pelo triângulo de velocidades no aerofólio (Figura 4).

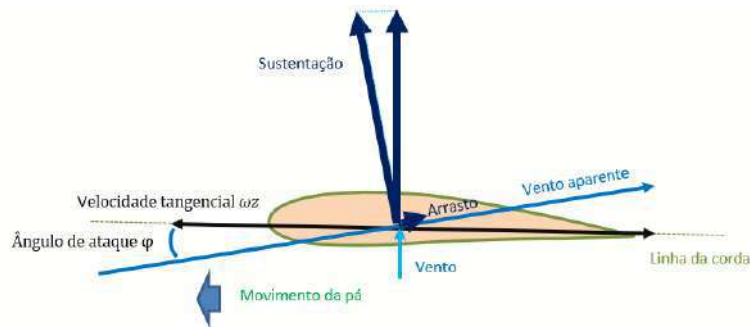


Figura 4 - Triângulo de velocidades no aerofólio

$$q(z) = \frac{1}{2} \rho_{ar} \cdot corda(z) \cdot (U_w^2 + (\omega z)^2) (C_L(\varphi) \cos(\varphi) + C_D(\varphi) \sin(\varphi)) \quad (9)$$

em que $\varphi = \arctg\left(\frac{U_w}{\omega z}\right)$ é o ângulo de ataque ou o ângulo de incidência aparente do vento na pá. O vento aqui é modelado considerando o perfil exponencial conforme a IEC 61400-1. Além do aumento da intensidade do vento com a altura, que na prática funciona como uma fonte excitadora na pá com frequência igual da rotação, adiciona-se uma componente aleatória com desvio-padrão da classe IA definido na mesma norma,

$$U_w = V_{hub} \left(\frac{h}{h_{hub}}\right)^\alpha + \Phi^{-1}(\delta) \quad (10)$$

em que $\Phi^{-1}(\delta)$ é a função densidade de probabilidade acumulada de uma distribuição normal $\mathcal{N}(0, \sigma)$ e δ é uma variável aleatória com $0 \leq \delta \leq 1$ com a turbulência atuando como um ruído de processo no modelo. Em uma primeira abordagem por questões de simplicidade, não se consideraram os efeitos do ângulo de *tilt* e de conicidade nos carregamentos da pá, uma vez que eles são relativamente pequenos.

A relação entre a velocidade do vento no hub (U_w) e a rotação da pá (ω) é descrita pela curva de acionamento do aerogerador, aqui ilustrada na Figura 5. Até atingir a rotação nominal, o aerogerador tende a operar em um TSR (*Tip Speed Ratio*) ótimo, característico de cada equipamento.



Figura 5 - Curva de acionamento do aerogerador

Os deslocamentos do sistema dinâmico são integrados diretamente no tempo usando o método de Runge-Kutta de 4ª ordem. Considera-se a condição inicial com deslocamentos transversais nulos e azimute zero, a qual apesar de ser estável, eventualmente cria efeitos transitórios no início da simulação. Para contornar este fato, serão desconsiderados os primeiros 30s da simulação. O incremento de tempo usado é determinado pelas propriedades do material (E, ρ_{mat}) e do passo da malha h ,

$$k = 0.9h \sqrt{\frac{\rho_{mat}}{E}} \quad (11)$$

Ainda que a equação de Euler forneça meios para se calcular os deslocamentos de uma pá, por questões práticas, geralmente estes não são monitorados nos aerogeradores. Para se acompanhar a dinâmica da pá, normalmente utilizam-se células de carga para medir os carregamentos normalmente na sua raiz [9] (Figura 6), as quais medem indiretamente a curvatura da pá ($\frac{\partial^2 u}{\partial z^2}$) no ponto onde são instaladas. Neste processo, a curvatura da pá é calculada, registrada e analisada utilizando técnicas de processamento de sinais, incluindo recortes, filtros e a sua conversão para o domínio da frequência. A seção a seguir detalha o método utilizado nesta análise.




Figura 6 - Células de carga instaladas na raiz da pá

3. MÉTODO DO ESTUDO

Para analisar as vibrações *flapwise* da pá de um aerogerador de grande comprimento um algoritmo em linguagem Python foi desenvolvido. As etapas deste algoritmo são: (1) a definição dos principais parâmetros e condições iniciais, (2) definição da matriz de massa, rigidez e amortecimento, (3) integração numérica no domínio do tempo usando representação em espaço de estados e algoritmo RK4, (4) cálculo das frequências naturais da pá e registro da curvatura da raiz da pá, (5) processamento do sinal da curvatura e (6) apresentação gráfica dos resultados. Resumidamente estas etapas estão mostradas na Figura 7. A abordagem proposta permitirá uma compreensão abrangente e precisa da dinâmica da pá, tendo controle dos principais seus parâmetros e possibilitando a análise das suas vibrações, assim como o efeito das variáveis de projeto na resposta dinâmica do sistema.

Na análise foram considerados 3 modelos. O modelo 1 refere-se à uma pá uniforme, constituindo uma viga tipo cantiléver, que é utilizada para validar o método numérico comparando-o com a solução analítica. Por outro lado, os outros dois modelos consideram a geometria, a rigidez, a densidade linear e o amortecimento variáveis ao longo do eixo longitudinal da pá. Os parâmetros do modelo 2 foram baseados na turbina de 10MW da DTU (LR10-MW RWT) [3] [13], enquanto o modelo 3 consiste em uma condição com a rigidez degradada, ou seja, fora da especificação do modelo anterior, devido, por exemplo, ao desgaste, fissuras, delaminações, danos provocados por raios e colisões com aves, à fadiga e a degradação por corrosão do material constitutivo das pás [15]. Em todos os casos, a rigidez ao longo do eixo longitudinal da pá é modelada pelo modelo exponencial. A diferença entre estes parâmetros está ilustrada na Figura 8. Nestes modelos, as curvas polares assumidas foram baseadas no perfil NACA0012 e estão mostradas na Figura 9. Os demais parâmetros comuns estão resumidos na Tabela 1.

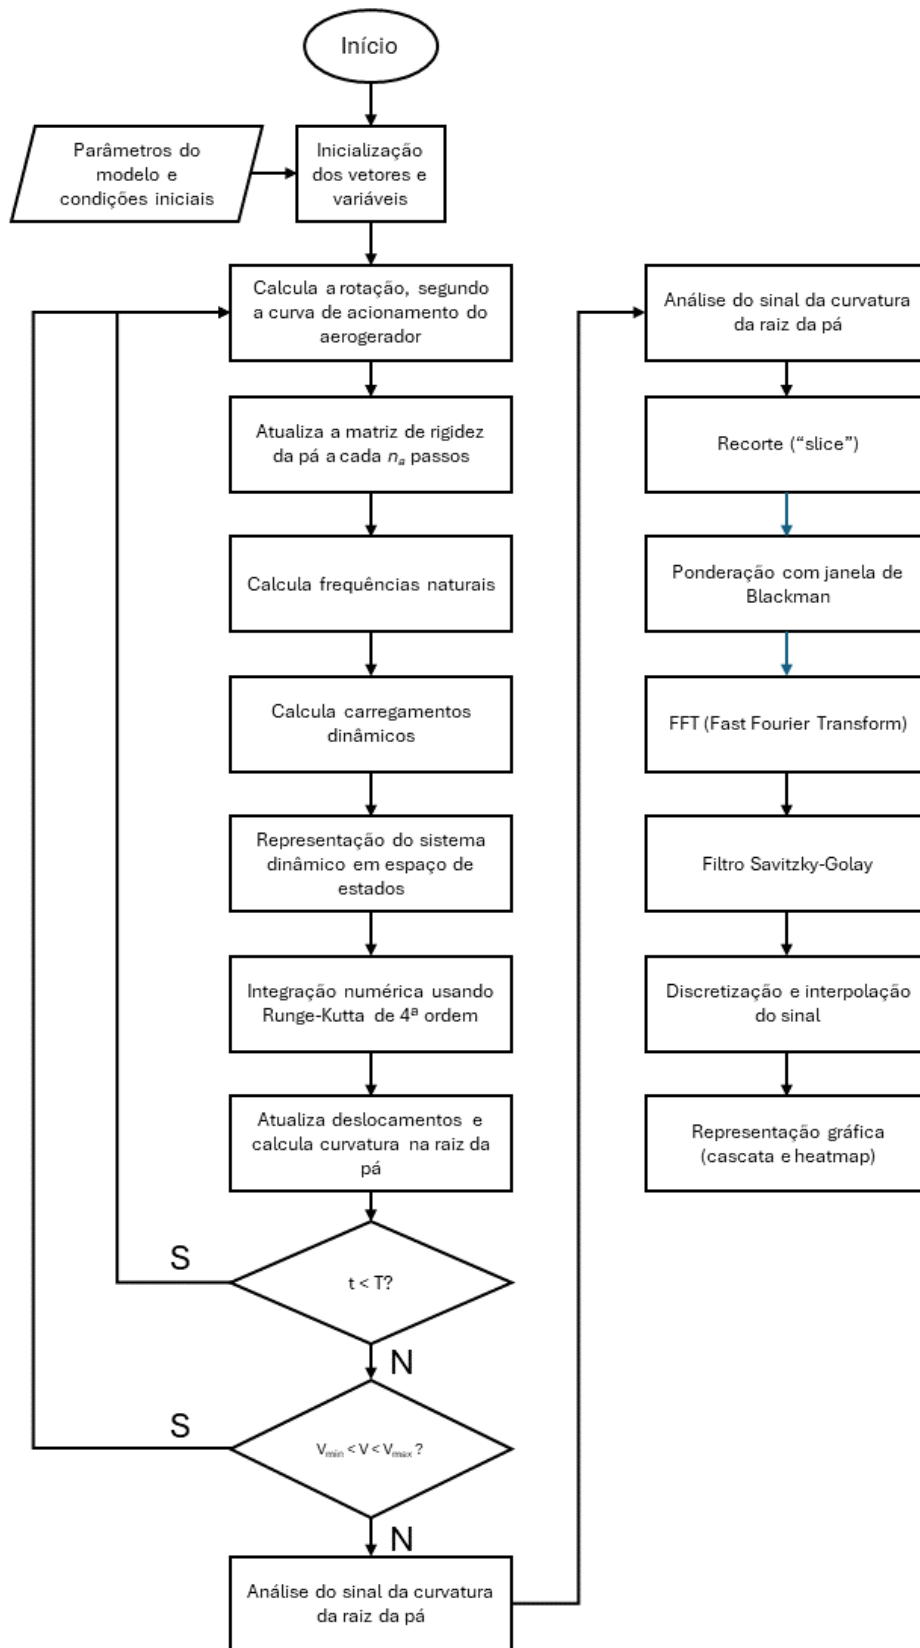


Figura 7 - Fluxograma do algoritmo

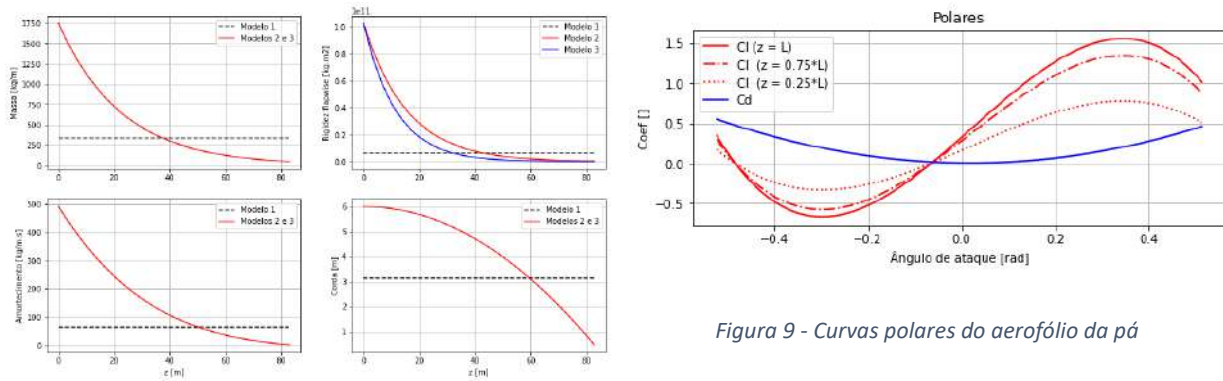


Figura 8 - Parâmetros dos modelos de geometria fixa (pontilhado) e variável (linha cheia)

Figura 9 - Curvas polares do aerofólio da pá

Tabela 1 - Parâmetros comuns dos 3 modelos

Classe	Parâmetro	Valor	Unidade	Descrição
Material: compósito	E	40	GPa	Módulo de Young
	ρ_{mat}	1500	kg/m ³	Densidade do material
	g	9,81	m/s ²	Gravidade
Vento: classe IA (IEC 61400)	ρ_{ar}	1,225	kg/m ³	Densidade do ar
	L	86,37	m	Comprimento da pá
	α	0,2	-	Coeficiente cisalhamento
Geometria e Controle: baseado no aerogerador DTU 10MW [13]	h_{hub}	150	m	Altura do hub
	σ	6,9	m/s	Desvio-padrão da velocidade do vento
	TSR	7,5	-	Tip Speed Ratio
	V_{cut-in}	3	m/s	Cut-in speed
	ω	9.5	rpm	Rotação da pá

Na análise dinâmica as simulações numéricas são realizadas com 120s de duração. No entanto, este sinal é filtrado para descartar os primeiros 30s e eliminar efeitos transitórios (*burn-in*). O recorte é então convertido para o domínio da frequência via FFT (*Fast Fourier Transform*), o qual é ponderado com uma janela de Blackman e suavizado utilizando-se um filtro Savitsky-Goulay.

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Inicialmente, foi analisado o modelo 1 para a validação do método pela sua comparação com a solução analítica. Para tanto, o perfil da viga foi calculado considerando um carregamento constante e uniforme ao longo do seu comprimento e os seus modos e frequências naturais, a partir dos autovetores e autovalores da matriz de rigidez respectivamente. Os resultados para uma discretização da pá em $n = 50$ nós estão mostrados nas Figura 10 (perfil da viga), Figura 11 (modos de vibração) e na Tabela 2 (frequências naturais). Observa-se uma boa aderência dos métodos analítico e numérico proposto.

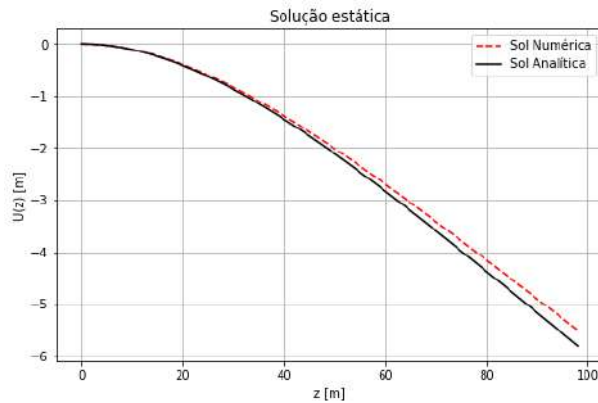


Figura 10 - Comparação da deflexão da pá gerada pelos modelos analítico e numérico de geometria fixa com $q = 1000N/m^2$

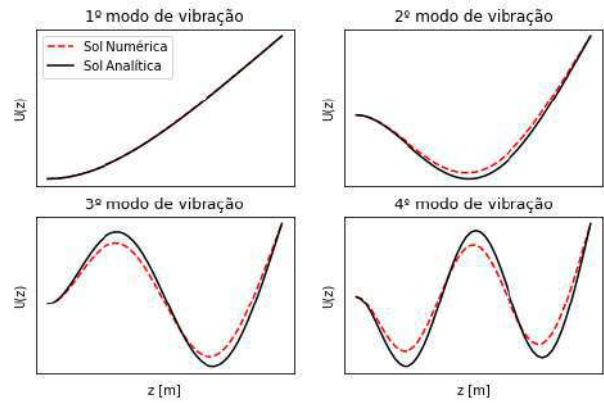


Figura 11 - Comparação dos modos de vibração gerados pelos modelos analítico e numérico de geometria fixa

Tabela 2 - Comparação das frequências naturais de vibração gerados pelos modelos analítico e numérico de geometria fixa

Modo de vibração	Modelo numérico (Hz)	Solução analítica (Hz)	Erro (%)
1	0,26	0,25	4,0
2	1,61	1,55	3,9
3	4,49	4,33	3,7
4	8,77	8,48	3,4

Além da análise modal, o processo de validação comparou a deflexão estática da ponta da pá pelo modelo 1, de geometria e propriedades mecânicas uniformes, com um modelo equivalente em elementos finitos (MEF) no software Abaqus. Nesta análise foram considerados um carregamento transversal uniforme de $Q_0 = 1000 N/m^2$ com a pá em diferentes rotações e azimutes (Figura 12), incluindo os carregamentos do peso próprio e da rotação. A pá simulada em MEF foi discretizada em 500 elementos de casca S4R. Os resultados para uma malha de $n = 50$ nós estão resumidos na Tabela 3.




Figura 12 - Modelo em elementos finitos usado para validação do modelo numérico

Tabela 3 - Comparação da deflexão estática entre os modelos numérico 1 e de elementos finitos para um carregamento uniforme $Q = 1000\text{N/m}^2$ e $n = 50$.

Simulação			Deflexão da ponta da pá		
#	θ (°)	ω (rad/s)	Numérico	MEF	Erro (%)
1	90	0,0	5,505	5,951	-7,5
2	0	0,0	5,86	6,364	-7,9
3	180	0,0	5,19	5,589	-7,1
4	90	1,0	3,766	3,957	-4,8
5	0	1,0	3,93	4,136	-5,0
6	180	1,0	3,615	3,793	-4,7

É possível perceber uma boa convergência entre os resultados dos modelos analítico, numérico e de elementos finitos. Uma vez que a matriz de rigidez obtida pelo método proposto foi validada, os modelos numéricos 2 e 3 foram analisados, os quais são integrados no tempo conforme o algoritmo proposto. A análise é realizada varrendo-se um range de velocidades do vento no hub de 1 à 12m/s, faixa na qual é notável considerar que a pá encontra-se totalmente atacada na posição de produção de potência, ou seja, com a linha da corda paralela ao eixo de rotação e com vento incidindo perpendicularmente à superfície da pá. A partir de 12m/s o controle de pitch começa a atuar embandeirando as pás para não sobrecarregar o aerogerador e, nesta velocidade, são esperados os valores extremos de carregamento e deflexões. Para fins de simplificação, a rotação do hub se mantém constante em cada velocidade média do vento. O momento resultante na raiz e a resposta da curvatura na raiz da pá, assim como a deflexão da ponta da pá em função da excitação do vento estão ilustradas na Figura 13 para uma pá discretizada em $n = 32$ nós.




Figura 13 - Efeito do vento (acima) e o sinal do empuxo, momento e curvatura da raiz da pá decorrentes no modelo 2

O sinal gerado pela leitura da curvatura é tratado e analisado via FFT. A Figura 14a mostra a representação em cascata 3D para a resposta vibracional do modelo 2 em diferentes velocidades do vento, enquanto a Figura 154b é uma representação planificada do gráfico anterior na forma de “heatmap”. Neste modelo, são observados quatro picos associados às vibrações livres ou naturais do sistema e às vibrações forçadas decorrentes da excitação provocadas pela turbulência do vento e pela rotação da pá

respectivamente. Essa interpretação está fundamentada na teoria das equações diferenciais, segundo a qual a sua solução é a soma das suas soluções homogênea e particular do sistema mecânico representado. Observa-se ainda que a as frequências naturais *flapwise* da pá apresentam variação ao longo da sua posição azimutal, a qual atribui-se à variação da sua tensão média e, conseqüentemente, da sua rigidez por conta do efeito do seu próprio peso.

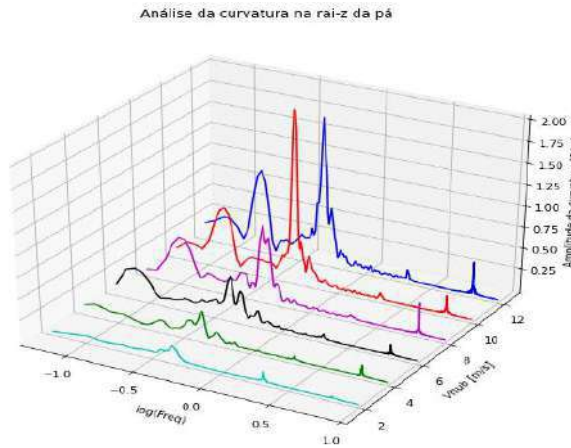


Figura 14a – FFT da curvatura da raiz da pá em diferentes velocidades do vento

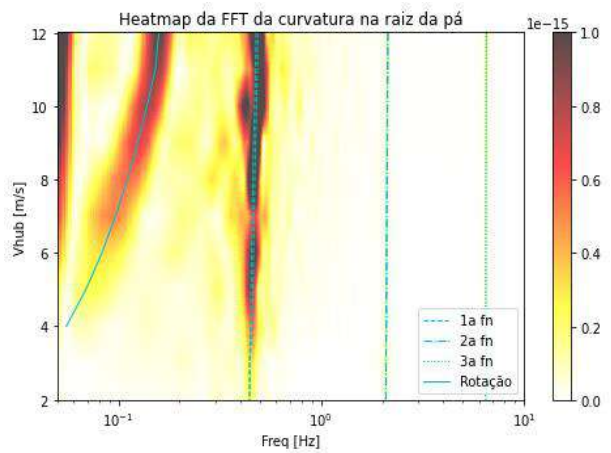


Figura 154b - Heatmap do sinal processado por FFT da curvatura da raiz da pá

A mesma análise é repetida no modelo 3. Observa-se que nesta condição, a rigidez da estrutura é menor e, a frequência de rotação da pá está mais próxima a primeira frequência natural da pá. Conseqüentemente, as amplitudes de vibração foram maiores o que implica em maiores tensões que o material terá de suportar e, conseqüentemente, levará à maiores deflexões na ponta da pá e fadiga, uma vez que o modo fundamental de vibração é dominante. Os resultados são mostrados nas Figura 165a e Figura 175b. Um resumo comparando os principais resultados obtidos na análise dos modelos com a referência é apresentado na Tabela 4.

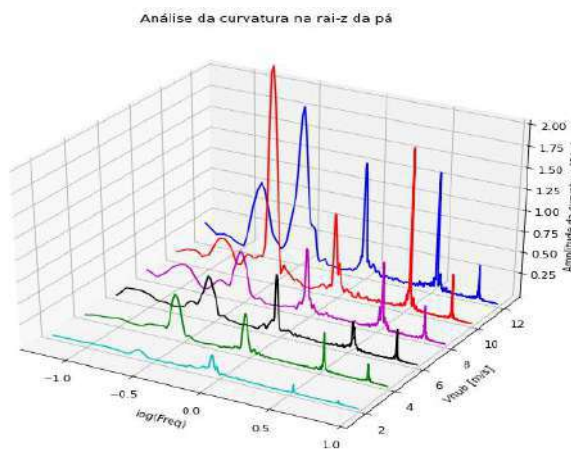


Figura 165a - FFT da curvatura da raiz da pá do modelo 3 em diferentes velocidades do vento

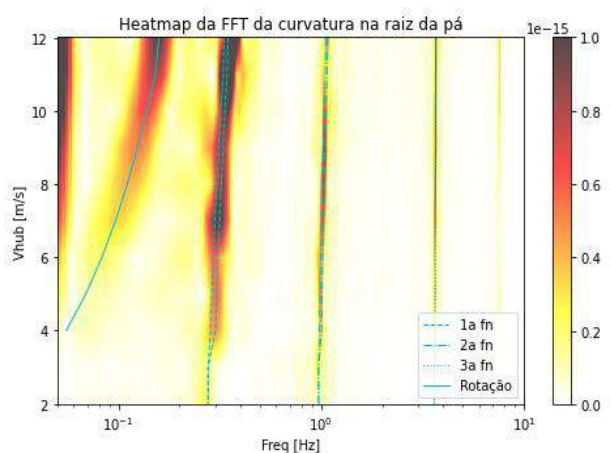


Figura 175b - Heatmap do sinal processado por FFT da curvatura da raiz da pá do modelo 3

Tabela 4 - Principais parâmetros dos modelos 2 e 3 obtidos por simulação e comparação com a referência

Parâmetro	Unidade	Referência	Modelo 2	Modelo 3
Momento máximo na raiz da pá	kNm	$(-2,5 \text{ à } -4,4)10^4$	$-2,3 \cdot 10^4$	$-2,2 \cdot 10^4$
Deflexão máxima da ponta da pá	m	12,4	13,7	29,9
Primeira freq. Natural	Hz	0,52	0,48	0,27
Segunda freq. Natural	Hz	1,61	2,12	0,93
Terceira freq. Natural	Hz	3,40	6,52	3,52

Os resultados obtidos pelo modelo 2 são aderentes aos valores equivalentes do aerogerador de 10MW da DTU encontrados na literatura. As diferenças encontradas com relação à referência podem ter diversas causas, mas são atribuídas principalmente ao modelo adotado e à comparação com valores extremos obtidos pelos DLCs (*Design Load Cases*). Uma abordagem mais adequada seria a comparação com os valores médios, usando exatamente o mesmo vento em ambos os casos. Observa-se ainda que a pá é sensível à perda de rigidez, com as simulações mostrando os efeitos da aproximação da frequência de rotação da pá com a sua primeira frequência natural na operação de uma pá fora da especificação de projeto. Além dos processos de fabricação que são inerentemente imprecisos, é preciso considerar a variação da rigidez da pá ao longo da sua vida útil decorrentes da sua operação.

5. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

Este trabalho apresentou um método de modelagem e análise da vibração *flapwise* de uma pá eólica de grande comprimento. O método foi validado com base na comparação da resposta do modelo 1 (geometria uniforme) com os modelos analítico e de elementos finitos em diversas condições, o qual obteve uma boa convergência dos resultados. O algoritmo desenvolvido foi então aplicado para simular a resposta dinâmica de pás com propriedades radiais variáveis, baseadas na turbina de referência de 10MW da DTU. Na comparação com o aerogerador de referência, o modelo apresentou resultados aderentes. As diferenças encontradas serão objeto de estudos na continuidade deste trabalho.

Nas simulações realizadas, verificou-se que o vento, em conjunto com a rotação da pá, atua como uma fonte de excitação *flapwise*, induzindo a sua vibração nas frequências da rotação e naturais, ambas identificadas com técnicas de análise de sinais. Entretanto, é crucial observar que, embora os modelos numéricos sejam amplamente utilizados para o projeto e certificação de turbinas eólicas, eles não consideram as variações das propriedades dos materiais da pá, os quais podem sofrer alterações devido à operação contínua em ambientes severos ao longo dos anos. Isso pode ocorrer devido às degradações inerentes à própria operação ou de uma fabricação fora da especificação. Normalmente as frequências associadas à rotação são menores que as frequências naturais *flapwise*, mesmo considerando a variação destas frequências com o azimute e com a rotação, mas esta pesquisa mostrou que a diminuição da rigidez pode levar a uma situação catastrófica do equipamento quando essas frequências se aproximam, resultando no aumento das vibrações e da colisão da pá com a torre. Desta forma é fundamental incorporar uma prática de inspecionar a sua rigidez ao longo do seu tempo de operação e considerar a sua variação nas simulações de cargas e controle (DLC) para um projeto mais seguro.

REFERÊNCIAS

- [1] ONU, “Objetivos de Desenvolvimento Sustentável no Brasil,” 23 março 2024. [Online]. Available: <https://brasil.un.org/pt-br/sdgs>.
- [2] C. J. F. Júnior, Modeling wind turbine blades by geometrically-exact beam and shell elements: a comparative approach, São Paulo, Brazil: Diss. de mestr., Escola Politécnica, University of São Paulo, 2017.
- [3] E. Gaertner, “Definition of the IEA 15-Megawatt Offshore Reference Wind,” 2020. [Online]. Available: <https://www.nrel.gov/docs/fy20osti/75698.pdf>.
- [4] M. H. Hansen, “Aeroelastic instability problems for wind turbines,” *Wind Energy* 10.6, p. 551–577, 2007.
- [5] N. Navadeh, “Finite Element Analysis of Wind Turbine Blade Vibrations,” *Vibration* 4.2, p. 310–322, 2021.
- [6] S. Zhang, “Investigation of a UWB Wind Turbine Blade Deflection Sensing System With a Tip Antenna Inside a Blade,” *IEEE Sensors Journal* 16, p. 7892–7902, 2016.
- [7] X. & L. C. & T. J. Chen, “Structural integrity of wind turbines impacted by tropical cyclones: A case study from China,” *Journal of Physics Conference Series*. 753, 2016.
- [8] F. A. Coleman RP, “Theory of self-excited mechanical oscillations of helicopter rotors with hinged blades,” National Advisory Committee for Aeronautics (NACA), 1957.
- [9] IEC, International Standard IEC 61400-1, Geneva: International Electrotechnical Commission (IEC), 2005.
- [10] G. e. a. Larsen, “Modal Analysis of Wind Turbine Blades,” Risø National Laboratory, Roskilde, Denmark, 2002.
- [11] S. AA., Dynamics of Multibody Systems 4th ed., Cambridge University Press, 2013.
- [12] D. T. X. S. Xianying Zhang, “Differences between Euler-Bernoulli and Timoshenko beam formulations for calculating the effects of moving loads on a periodically supported beam,” *Journal of Sound and Vibration Vol. 481*, 2020.
- [13] SmartFibre, “SmartBlade Loads Monitoring System,” 2024. [Online]. Available: www.smartfibres.com/products/smartblade. [Acesso em 18 maio 2024].
- [14] C. Bak, R. Bitsche e A. e. a. Yde, “Light Rotor: The 10-MW reference wind turbine,” *Proceedings of EWEA 2012 - European Wind Energy Conference & Exhibition*. European Wind Energy Association (EWEA), 2012.
- [15] W. Wang, Y. Xue, C. He e Y. Zhao, “Defect Types and Mechanism of Wind Turbine Blades.” Scholarly Community Encyclopedia, [Online]. Available: <https://encyclopedia.pub/entry/27751>. [Acesso em 7 julho 2024].

Detecção de anomalias em rolamentos de aerogeradores baseada em modelos não supervisionados

Samuel Bezerra da Gama Neto¹, Gustavo de Novaes Pires Leite², Rodrigo Cesar Lira da Silva², Frederico Duarte de Menezes², Alexandre Carlos Araujo da Costa³, Olga de Castro Vilela³, Leonardo José de Petribú Brennand³, Rodrigo Henrique de Lima Farias³, Giovanni Moura de Holanda⁴, Fabrício Cristófani⁴, Edgar Lessa Venancio⁵, Isabela Niedo Marchiori⁵, Jefferson Silva Barbosa⁵

¹Universidade Federal de Pernambuco (UFPE), Brasil

²Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco (IFPE), Brasil

³Centro de Energias Renováveis da UFPE (CER-UFPE), Brasil

⁴Fundação para Inovações Tecnológicas (FITec), Brasil

⁵CPFL Renováveis, Brasil

* Autor para correspondência

samuel.gneto@ufpe.br, gustavonovaes@recife.ifpe.edu.br, rodrigo.lira@paulista.ifpe.edu.br, fredericomenezes@recife.ifpe.edu.br, alexandre.acosta@ufpe.br, olga.vilela@ufpe.br, leonardo.brennand@ufpe.br, rodrigo.hlfarias@ufpe.br, gholanda@fitec.org.br, fabriciocristofani@fitec.org.br, edgar.venancio@cpfl.com.br, imarchiori@cpfl.com.br, jefferson.barbosa@cpfl.com.br

RESUMO

O planejamento da manutenção de parques eólicos é uma tarefa complexa, uma vez que os aerogeradores estão expostos a condições ambientais adversas que podem acelerar o desgaste dos componentes e que dificultam a identificação prévia de falhas. Além disso, a falta de um plano de manutenção adequado pode comprometer a confiabilidade dos aerogeradores, reduzindo a eficiência e diminuindo a margem de lucro dos parques eólicos. Neste contexto, uma estrutura para detecção de anomalias de rolamentos foi aplicada aos dados de vibração de três parques eólicos localizados no Nordeste do Brasil. Foram utilizados dois procedimentos para a rotulação dos dados e extração de atributos em diferentes domínios para o treinamento de doze modelos não supervisionados. Para detecção final da anomalia, uma estratégia de comitês de modelos baseada na votação majoritária foi adotada. A validação da metodologia foi realizada para o caso de ocorrência de falha no rolamento do eixo de alta velocidade do *gearbox* de quatro aerogeradores. Os resultados demonstraram que o método proposto conseguiu identificar corretamente anomalias em dois dos aerogeradores analisados. Os dados foram obtidos no âmbito de um projeto de P&D Aneel, chamado de CPFL.APE, e que está sendo desenvolvido por um consórcio entre UFPE, IFPE, FITEC e CPFL.

Palavras-chaves: Detecção de anomalias; Aerogeradores; Rolamentos; Aprendizagem não supervisionada

ABSTRACT

Maintenance planning for wind farms is a complex task, as wind turbines are exposed to adverse environmental conditions that can accelerate component wear and make it difficult to identify early faults. Additionally, the lack of an adequate maintenance plan can compromise the reliability of the wind turbines, reducing efficiency and decreasing the profit margins of the wind farms. In this context, a framework for bearing anomaly detection was applied to vibration data from three wind farms located in the Brazilian Northeast. Two procedures were used for data labeling, and feature extraction was performed in different domains for the training of twelve unsupervised models. For final anomaly detection, a majority voting-based combination strategy was adopted. The methodology was validated for the case of high-speed shaft bearing failure in the gearboxes of four wind turbines. The results demonstrated that the proposed method correctly identified anomalies in two of the analyzed wind turbines. The data were obtained under an Aneel R&D project called CPFL.APE, that is being developed by a consortium between UFPE, IFPE, FITEC and CPFL.

Keywords: Anomaly detection; Wind turbines; Bearings; Unsupervised learning

1. INTRODUÇÃO

Aerogeradores (AEGs) são dispositivos rotativos cuja geração de energia elétrica está diretamente ligada à disponibilidade e à velocidade do vento. Estes equipamentos são constituídos de sete principais componentes: pás, *hub*, torre, nacele, rolamento principal, *gearbox* e gerador (Olabi *et al.*, 2021). Segundo Santelo *et al.* (2022), um dos principais contribuintes para o tempo de inatividade dos AEGs é o *gearbox*, devido ao seu tamanho e complexidade. As falhas nesse componente são causadas principalmente pela quebra dos dentes das engrenagens e pelo desgaste dos rolamentos.

Em AEGs, os rolamentos podem ser afetados por cargas excessivas devido à dinâmica do fluxo de vento e às condições ambientais, resultando em vários modos de falha, como deformação plástica, fadiga e corrosão (Liu; Zhang, 2020). Neste contexto, visando contornar esses problemas diferentes técnicas para a detecção, diagnóstico e prognóstico de falhas em rolamentos foram publicadas na literatura, como a análise de vibração e modelos de aprendizagem de máquina supervisionada, que necessitam de especialistas ou da intervenção humana.

Nesse sentido, este estudo propõe o uso de modelos não supervisionados para detecção de anomalias de rolamentos utilizando dados de vibração de AEGs de 2,1 MW de três parques eólicos localizados no Nordeste do Brasil, que são oriundos de um projeto de P&D ANEEL, chamado de CPFL.APE, e que está sendo desenvolvido por um consórcio entre UFPE, IFPE, FITEC e CPFL. Modelos de detecção de anomalias são capazes de detectar pontos de dados que se desviam do padrão normal, cujas principais vantagens são: (i) detecção de *outliers*; (ii) habilidade de ajustar e adaptar para diferentes aplicações (Omar *et al.*, 2013; Boukerche *et al.*, 2020).

Portanto, os principais objetivos deste estudo são:

- i) Identificar os eventos de falhas dos rolamentos dos AEGs disponibilizados pelos parques eólicos;

- ii) Extrair atributos nos domínios do tempo, frequência, teoria da informação e mecânico dos dados brutos de vibração;
- iii) Aplicar modelos não supervisionados para detecção de anomalias;
- iv) Utilizar um comitê de modelos para detecção de anomalias em AEGs.

Este trabalho está organizado da seguinte forma: a Seção 2 apresenta estudos relacionados à detecção de anomalias, a Seção 3 detalha a metodologia adotada, a Seção 4 fornece resultados e discussão. Por fim, a Seção 5 apresenta as conclusões e direções de pesquisas futuras.

2. ESTADO DA ARTE

No contexto da detecção de anomalias, diversas técnicas têm sido aplicadas a AEGs. Um exemplo é o estudo de Lin *et al.* (2020), no qual o modelo de floresta de isolamento (do inglês, *Isolation Forest*) foi utilizado para remover pontos extremos do sistema supervisório. Em seguida, uma rede neural de aprendizagem profunda foi empregada para prever a potência dos AEGs. Os resultados mostraram que o erro quadrático médio foi de 0,114 para os modelos treinados com os dados brutos e de 0,003 para os modelos treinados com os dados filtrados.

Para detecção de falhas em AEGs, Trizoglou *et al.* (2021) implementaram uma estrutura baseada na detecção de anomalias, seleção de atributos e treinamento de modelos com o comportamento livre de falhas. Para a detecção de anomalias foi adotada a floresta de isolamento. Os modelos utilizados para a detecção de falhas foram o *Extreme Gradient Boost* (XGBoost) e a rede neural de memória de curto e longo prazo (LSTM).

Chen *et al.* (2021) propuseram o uso de uma LSTM combinada com um *autoencoder* para detecção de anomalias. Nessa abordagem, o modelo foi treinado com dados do sistema supervisório referentes a períodos livres de falhas. De modo que as previsões de condições anômalas resultassem em um erro de reconstrução maior do que o observado para condições normais. Uma abordagem semelhante foi aplicada por Xiang *et al.* (2022), que implementaram uma técnica de detecção de anomalias em séries temporais combinando uma rede neural convolucional, uma rede neural bidirecional *Gated Recurrent Unit* (GRU) e um mecanismo de atenção.

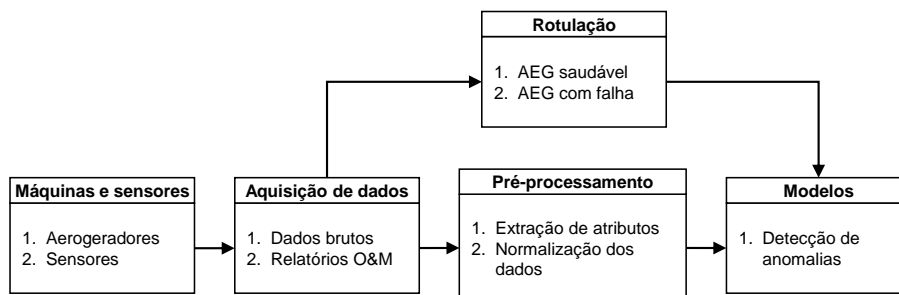
Para classificação dos dados, Leite *et al.* (2023) aplicaram uma metodologia buscando a detecção de anomalias para o rolamento da extremidade sem acionamento do gerador de AEGs utilizando dados de vibração de doze aerogeradores. A metodologia analisou individualmente onze modelos e combinou uma estratégia 5x2 de validação cruzada para garantir a melhor generalização dos modelos. Os resultados alcançaram uma acurácia 96,3% na detecção de falhas.

Munguba *et al.* (2024) utilizaram um comitê de técnicas de detecção de anomalias na sua proposta. Eles empregaram essas técnicas nos rolamentos principais, no rolamento do eixo de alta velocidade da caixa de engrenagens, e nos rolamentos da extremidade com e sem acionamento do gerador. As saídas das combinações foram comparadas pelos valores dos rótulos obtidos através da análise de vibração, alcançando os melhores resultados da métrica de área sob a curva (AUC) de 98% para o caso do rolamento principal.

3. MÉTODO DO ESTUDO

A metodologia aplicada neste estudo, cujo objetivo é avaliar a detecção de anomalias de rolamentos de AEGs, pode ser resumida por meio do diagrama apresentado na Figura 1, no qual se têm os seguintes passos principais: (i) aquisição de dados; (ii) pré-processamento; (iii) rotulação; (iv) desenvolvimento de modelos de detecção de anomalias.

Figura 1 – Metodologia para detecção de anomalias aplicada a dados de vibração do CMS de AEGs.



Fonte: Autores, 2024.

3.1 AQUISIÇÃO DOS DADOS

De acordo com a Figura 1, o primeiro passo da metodologia consiste no acesso aos dados brutos dos acelerômetros no banco de dados do *Condition Monitoring System* (CMS). Além disso, os relatórios de operação e manutenção (O&M) foram utilizados para identificação de manutenções, substituição de componentes e registros de falhas em AEGs, incluindo os modos e as datas em que essas falhas foram observadas, para auxiliar no processo de rotulagem dos dados.

Os dados fornecidos pelo CMS dos parques eólicos analisados são divididos em:

- i) Dados brutos de vibração: representa a série temporal de aceleração, medida em g , com uma taxa de frequência, fs , e período de coleta, T . Para o sistema CMS analisado, $fs = 20.000 \text{ Hz}$ e $T = 20s$, o que totaliza 400.000 amostras por acelerômetro e por coleta;
- ii) Dados de tendência: esses são dados coletados e extraídos automaticamente pelo CMS determinados pelo RMS (*root mean square*) do sinal de vibração.

3.2 PRÉ-PROCESSAMENTO

Com respeito ao segundo passo no diagrama da Figura 1 (pré-processamento), duas etapas foram empregadas: extração de atributos e normalização dos dados. Deve-se ressaltar que os dados de vibração de componentes mecânicos de carga variável como aqueles componentes presentes nos AEGs são complexos, altamente voláteis e imprevisíveis, principalmente devido a rajadas de vento, mudanças de direção e cisalhamento da velocidade do vento, que produzem assimetrias no rotor (Feng *et al.*, 2015). Para capturar as diferentes dinâmicas das formas de onda da vibração em um ambiente tão complexo, foram extraídos atributos de domínios distintos (domínios do tempo, frequência, teoria da informação e

mecânico) (Caesarendra; Tjahjowidodo, 2017). Tais características são definidas de forma a fornecer informações suficientes aos modelos de aprendizado de máquina para lhes permitir a separação de estados saudáveis dos estados defeituosos dos AEGs. Os atributos extraídos do sinal de vibração utilizados para o treinamento dos modelos foram:

- i) Domínio do tempo: raiz quadrada média, variância, curtose, pico a pico, simetria e fator de crista;
- ii) Domínio da frequência: frequência média, frequência central, frequência RMS e frequência de desvio padrão;
- iii) Domínio da teoria da informação: entropia, divergência Jensen-Shannon, complexidade estatística da permutação, do *power spectrum* e da *wavelet* da função de massa de probabilidade;
- iv) Domínio mecânico: harmônicos e *sidebands* da frequência de *Ball Pass Frequency Outer* (BPFO), *Ball Pass Frequency Inner* (BPFI) e *Ball Spin Frequency* (BSF), e velocidade do eixo.

A segunda etapa do pré-processamento, antes do treinamento dos modelos de detecção de anomalias, consistiu na normalização do conjunto de dados. A normalização é um procedimento para evitar que ocorra influência no desempenho dos modelos de aprendizagem de máquina pela diferença de variabilidade entre os atributos do conjunto de dados (Singh; Singh, 2020). No caso específico, foi aplicada a normalização (Z-score) em relação à média μ e ao desvio padrão σ , conforme a Eq. 1, para cada amostra x_n de cada atributo i do conjunto de dados.

$$x_{i,n}^* = \frac{x_{i,n} - \mu_i}{\sigma_i} \quad (1)$$

3.3 ROTULAÇÃO

O terceiro passo da metodologia, que ocorre simultaneamente ao passo 2, envolve o procedimento de rotulação dos dados. Esse procedimento inclui a classificação dos AEGs em dois grupos, saudáveis e com falhas, com o objetivo de auxiliar na avaliação da performance dos modelos. Nesta etapa, foram utilizadas duas abordagens distintas: registro de falhas e limites de vibração conforme norma.

A rotulação com base no registro de falhas consistiu na análise das informações registradas por componente (rolamento principal, *gearbox* e gerador), concentrando-se principalmente em problemas relacionados a engrenagens e rolamentos.

Na abordagem baseada nos limites de vibração conforme norma, foram examinados os alarmes de falhas obtidos pelos dados de tendência do CMS. Nesse caso, considera-se como alarme de falha qualquer valor de vibração acima de uma das duas zonas de vibrações determinadas pela norma ISO 20816-21, conforme a Tabela 1.

De acordo com a norma ISO 20816-21, a Zona B representa valores de vibrações nas quais os

componentes do AEG podem operar por um longo período. Por sua vez, a Zona C representa valores não adequados para a operação por um longo período. Com esses valores de vibrações é recomendado realizar investigação da razão do aumento da vibração. Por fim, a Zona D é a mais perigosa para a máquina; segundo a norma vigente, esses valores de vibrações vão certamente danificar o AEG e seus componentes.

Tabela 1 – Limites das zonas de vibrações conforme a ISO 20816-21.

Componente do AEG	Medição em aceleração (m/s ²)		Medição em velocidade (mm/s)	
	Zona B/C	Zona C/D	Zona B/C	Zona C/D
Nacele e torre	0,1 Hz a 10 Hz		0,1 Hz a 10 Hz	
	0,3	0,5	60	100
Rotor	0,1 Hz a 10 Hz		0,1 Hz a 1000 Hz	
	0,3	0,5	2,0	3,2
Gearbox	0,1 Hz a 10 Hz		0,1 Hz a 1000 Hz	
	0,3	0,5	2,0	5,6
	0,1 Hz a 10 Hz			
	7,5	12		
Gerador	10 Hz a 5000 Hz		10 Hz a 1000 Hz	
	10	16	6	10

Fonte: Adaptado da ISO 20816-21.

Deste modo, os AEGs que registraram o maior número de alarmes na zona crítica de vibração foram classificados com falha. Para cada AEG com falha, foram selecionados dois aerogeradores vizinhos saudáveis, desde que não apresentassem um número significativo de alarmes que os classificasse também com falha.

3.4 DESCRIÇÃO DOS MODELOS

No tocante ao quarto passo no diagrama da Figura 1 (desenvolvimento de modelos de detecção de anomalias), foram implementados, doze modelos de aprendizado não supervisionado para detecção de anomalias e consequentes falhas nos aerogeradores: *Angle-base Outlier Detection*, *Clustering-Based Local Outlier*, *Connectivity-Based Local Outlier*, *Isolation Forest*, *Histogram-based Outlier Detection*, *K-Nearest Neighbors Detector*, *Local Outlier Factor*, *One-class SVM detector*, *Principal Component Analysis*, *Minimum Covariance Determinant*, and *Stochastic Outlier Selection*.

Os modelos de detecção de anomalias são algoritmos utilizados para identificar padrões no conjunto de dados que não correspondem ao comportamento normal, ou seja, para detectar pontos de dados que são considerados como *outliers* (Agrawal; Agrawal, 2015). Nesse sentido, os modelos foram implementados utilizando a biblioteca PyCaret (Ali, 2020), uma ferramenta *low-code* em Python que reúne diversos modelos de aprendizado de máquina para uso em diferentes aplicações, como aprendizado

supervisionado (classificação e regressão), aprendizado não supervisionado (*clustering* e detecção de anomalias) e séries temporais (previsão).

Para a detecção final da anomalia, adotou-se um comitê de modelos baseados em votação. Cada modelo foi treinado separadamente e suas previsões foram combinadas para determinar a decisão final. A estratégia de combinação adotada foi a votação majoritária, na qual um ponto no conjunto de dados foi considerado anômalo somente quando pelo menos metade dos modelos do comitê, ou seja, 6, indicassem anomalias.

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Nesta seção, são apresentados os resultados da metodologia proposta para detecção de anomalias em rolamentos de AEGs. Inicialmente, serão detalhados os resultados da seleção dos AEGs categorizados como saudáveis e com falha, obtidos por meio do procedimento de rotulação, juntamente com os atributos extraídos durante o pré-processamento. Em seguida, serão apresentados os resultados da combinação dos modelos de detecção para cada AEG.

Os resultados foram obtidos pela aplicação da metodologia a uma base de dados extraída de três parques eólicos situados no Brasil, todos com AEGs do mesmo fabricante e com capacidade de 2,1 MW.

4.1 PRÉ-PROCESSAMENTO E ROTULAÇÃO


Como mencionado, os passos seguintes após a aquisição dos dados foram o pré-processamento e a rotulação dos AEGs. Para a rotulação dos dados, foram considerados os registros de falhas e os alarmes baseados nos limites de vibração de cada componente, conforme a norma ISO 20816-21.

A Figura 2 apresenta um exemplo da determinação dos alarmes pela aplicação dos limites de vibração para o sensor do rolamento do eixo de alta velocidade do *gearbox*, considerando as Zonas B/C e C/D. Assim, os aerogeradores identificados com falhas foram aqueles que apresentaram o maior número de alarmes na soma das duas zonas. Lembrado que, para cada AEG com falha, foram selecionados dois vizinhos espacialmente mais próximos, desde que estes não apresentassem um número significativo de alarmes. Para a rotulação, devido à disponibilidade dos dados, foram utilizados os dados de tendência entre os períodos de setembro de 2022 a junho de 2023.

A Tabela 2 apresenta os resultados da identificação dos AEGs com falhas, juntamente com suas descrições, e dos AEGs saudáveis. Nesta etapa, foram selecionados 22 aerogeradores dos três parques eólicos, dos quais 8 apresentavam falhas e 14 estavam em condições saudáveis.

Na etapa de pré-processamento, foram extraídos atributos dos sinais de vibração de cada sensor em diferentes domínios para a detecção de anomalia: tempo, frequência, teoria da informação e mecânico. Contudo, os dados brutos de vibração foram disponibilizados apenas em amostras espaçadas entre os períodos de 01-2022 a 12-2023, devido à grande quantidade de informações geradas pelos sensores e o número de AEGs. A aplicação da extração de atributos resultou no conjunto de dados com 9.180 instâncias e 1.081 colunas.

Figura 2 – Aplicação dos limites de vibração para obtenção dos alarmes de falha. (a) AEG saudável; (b) AEG com falha.



Fonte: Autores, 2024.

Tabela 2 – Resultado do procedimento de rotulação.


Parque	AEG	Falha/Descrição	Fonte	AEG saudáveis
A	5	Rolamento NDE do gerador		9, 10
	14	Rolamento do planetário		12, 15
B	8	Rolamento LSS do <i>gearbox</i> Rolamento IMS do <i>gearbox</i>	Dados de tendência	9, 10
	22	Rolamento HSS do <i>gearbox</i> Rolamento NDE do gerador		21, 23
C	9	Deslocamento das engrenagens planetárias da <i>gearbox</i>	Log de alarmes	10, 12
	13	Rolamento LSS do <i>gearbox</i> Rolamento IMS do <i>gearbox</i> Rolamento HSS do <i>gearbox</i>	Dados de tendência	2, 4
	14	Danos na pista dos rolamentos HSS da <i>gearbox</i> e trinca encontrada no alojamento do rolamento IMS	Log de alarmes	2, 4
	26	Rolamento HSS do <i>gearbox</i>	Dados de tendência	24, 27

Fonte: Autores, 2024.

Neste estudo, os dados do sensor radial do rolamento do eixo de alta velocidade do *gearbox* foram utilizados para detectar situações anômalas que poderiam indicar falhas, visto que quatro AEGs

listados na Tabela 2 compartilharam o mesmo problema. Os dados originais foram filtrados para selecionar apenas instâncias com velocidades iguais ou superiores a 1.800 rpm, considerando assim apenas o conjunto de dados dos instantes em que os AEGs estavam em funcionamento. A Figura 3 apresenta o histograma da velocidade de rotação para os dois conjuntos de dados.

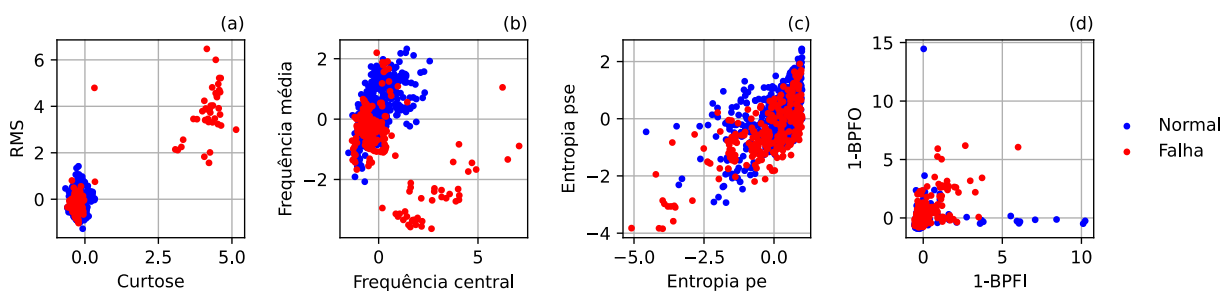
Figura 3 – Histograma da velocidade de rotação em rpm. (a) Conjunto de dados original; (b) Conjunto de dados filtrado.



Fonte: Autores, 2024.

Para o treinamento dos modelos, o conjunto de dados filtrado foi normalizado pelo método Z-score. A aplicação das operações anteriores gerou uma base de dados resultante de 752 instâncias e 206 colunas. A Figura 4 mostra o gráfico de dispersão de alguns atributos extraídos em diferentes domínios, usados na detecção de anomalias.

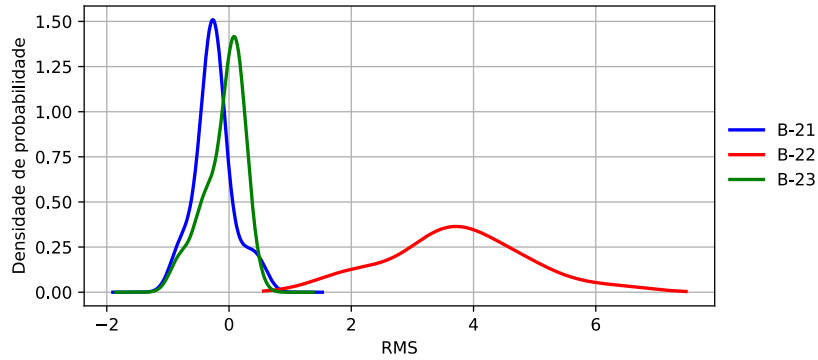
Figura 4 – Gráfico de dispersão. (a) Tempo; (b) Frequência; (c) Teoria da informação; (d) Mecânico.



Fonte: Autores, 2024.

A Figura 5 mostra a comparação da densidade de probabilidade do atributo RMS dos AEGs B-21, B-22 e B-23 pela estimativa de densidade kernel. Observa-se que os AEGs saudáveis, B-21 e B-23, exibem densidades de probabilidade similares e compactas. Em contraste, o AEG B-22 apresenta valores mais dispersos.

Figura 5 – Densidade de probabilidade do atributo RMS.




Fonte: Autores, 2024.

4.2 DETECÇÃO DE ANOMALIAS

A seguir é apresentado o estudo de caso da aplicação da metodologia nos dados brutos de vibração obtidos do CMS. Para a operação de detecção de anomalia foram utilizados doze modelos de aprendizagem não supervisionada implementadas pela biblioteca PyCaret, com os hiperparâmetros padrões indicados na biblioteca.

Para aumentar o desempenho na detecção de anomalias e reduzir a incidência de falsos alarmes, adotou-se uma estratégia de combinação das saídas dos modelos por meio de votação majoritária. Assim, o alarme é acionado apenas se mais de seis modelos classificarem o ponto como anômalo. A Figura 6 apresenta os AEGs considerados com falha da Tabela 2 que apresentaram alarmes de anomalias.

Figura 6 – Alarmes de anomalias para os aerogeradores com falha.



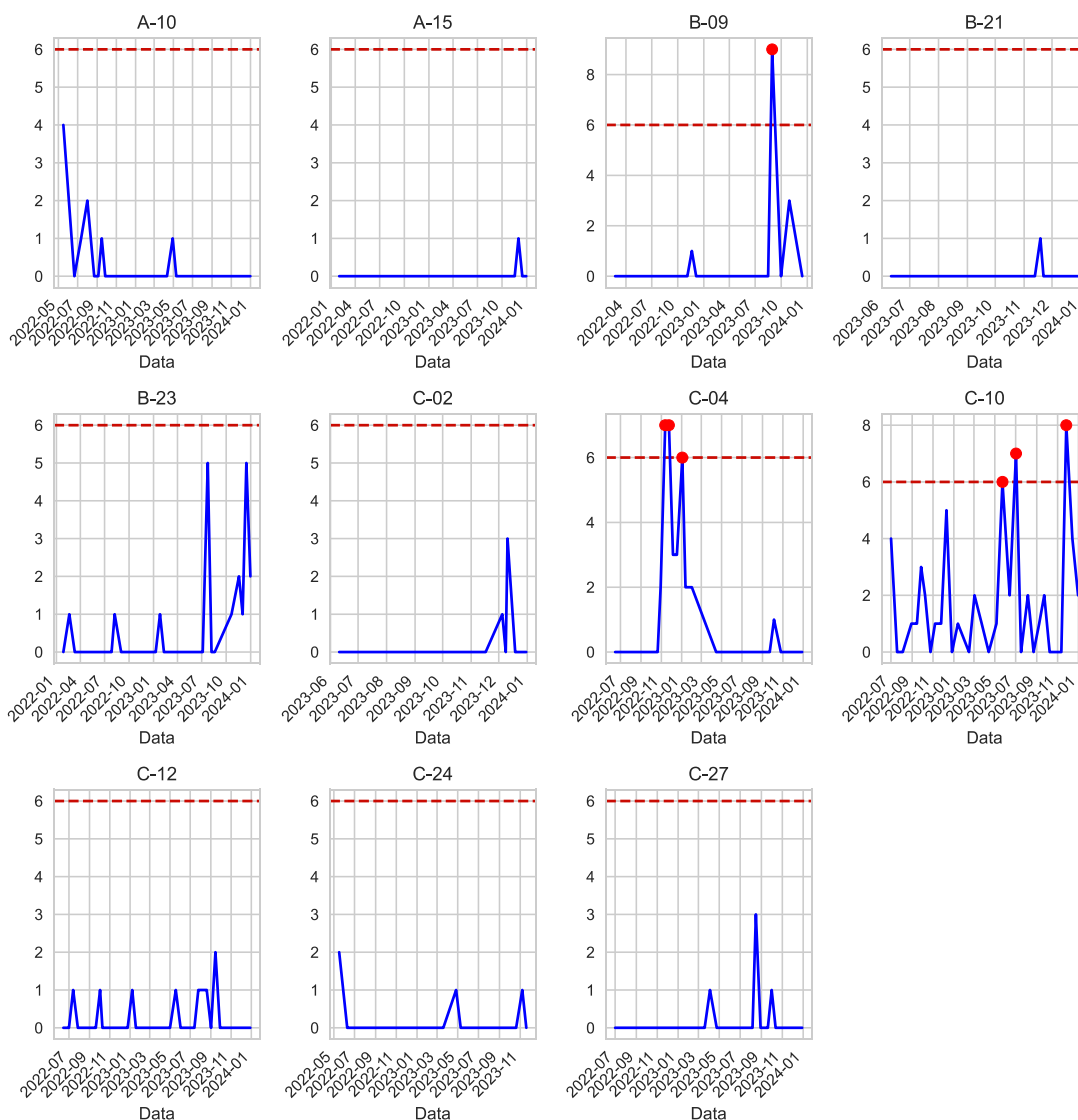
Fonte: Autores, 2024.

Para falhas relacionadas ao rolamento do eixo de alta velocidade do *gearbox*, conforme mostrado na Tabela 2, apenas os AEGs B-22, C-13, C-14 e C-26 apresentaram esse tipo de falha em algum momento. No entanto, pela Figura 6, observa-se que os AEGs A-14, B-8, B-22 e C-14 foram os que tiveram anomalias indicadas por seis ou mais modelos em seus dados. Conforme listado na Tabela 2, nos AEGs A-14 e B-8 foram identificadas falhas relacionadas a outros componentes do *gearbox*. Desse modo, o resultado da Figura 2 levanta a hipótese de haver atravessamento de frequências entre as vibrações dos componentes, resultando na detecção de anomalias pelo sensor considerado. Por outro lado, os AEGs B-22 e C-14 apresentaram alarmes durante o período de rotulação de falha do rolamento HSS do *gearbox*.

Além disso, para os mesmos AEGs foram identificadas anomalias fora dos limites dos dados de tendência analisados, logo não há como confirmar se houve alarmes para esses AEGs ou se estes podem ser considerados falsos positivos.

Para validação da metodologia, a Figura 7 apresenta o resultado da detecção de anomalias para os AEGs considerados saudáveis da Tabela 2.

Figura 7 – Alarmes de anomalias para os aerogeradores saudáveis.



Fonte: Autores, 2024.

De acordo com a Figura 7, somente os AEGs B-9, C-4 e C-10 apresentaram indicações de anomalias. Contudo, os alarmes dos AEGs B-9 e C-10 ocorreram fora do período de análise dos dados de tendência. Para o AEG C-4, no entanto, são necessárias mais investigações sobre a classificação como saudável estabelecida na Tabela 2.

Para os demais AEGs classificados como saudáveis que apresentaram pelo menos uma indicação de anomalia, conforme mostrado na Figura 7, podem ser feitas as seguintes análises:

- i) Devido à parametrização, alguns modelos podem identificar eventos de anomalias para as condições normais de operação, resultando em falsos positivos que não necessariamente indicam problemas reais;
- ii) A variabilidade nas condições ambientais e operacionais pode ter influenciado na indicação de eventos de anomalias;
- iii) Especificamente para os AEGs A-15, B-21, B-23, C-2 e C-27, foram identificadas anomalias após o período de análise dos dados de tendência;

5. CONCLUSÕES

Neste estudo foi aplicado uma abordagem para detecção de anomalias para o rolamento do eixo de alta velocidade do *gearbox* de AEGs, utilizando dados de três parques eólicos em operação no Nordeste do Brasil.

Na aplicação do método, foram utilizados dados de vibração entre os anos de 2022 e 2023 de 22 AEGs, para o treinamento de 12 modelos de detecção de anomalias. O alarme de detecção final foi considerado pela técnica de combinação majoritária. Acerca dos resultados da metodologia aplicada, as principais considerações são:

- i) Os métodos de detecção de anomalias conseguiram reconhecer variações do comportamento padrão nos AEGs B-22 e C-14, os quais estão registrando dados de falhas no rolamento HSS do *gearbox*;
- ii) Foram registradas anomalias em aerogeradores considerados como saudáveis ou com falhas registradas em outros componentes. Essa observação pode estar correlacionada com os hiperparâmetros específicos dos modelos utilizados para análise, que foram aplicados conforme configuração padrão, ou então à possibilidade real de que os AEGs estejam exibindo um comportamento anômalo.

Em síntese, os limites de vibração estabelecidos por norma são indicativos da possibilidade de falha nos componentes dos AEGs. No entanto, os modelos de aprendizado de máquina para detecção de anomalias representam uma alternativa para identificar padrões de falhas, permitindo que estas sejam identificadas antes mesmo de alcançarem níveis severos de vibração.

Dessa forma, os próximos passos em relação à metodologia para trabalhos futuros são:

- i) Expansão da base de dados, agregando mais amostras e ocorrências de falhas dos AEGs, de modo que ajudem a distinguir entre anomalias reais e variações normais no funcionamento dos AEGs;
- ii) Aplicação de técnica de otimização dos hiperparâmetros individuais de cada modelo, para diminuir falsos positivos e aumentar a detecção de casos de anomalias;
- iii) Expandir a abordagem de detecção de anomalias para outros componentes do *drivetrain* dos AEGs;

- iv) Adotar outras abordagens da combinação dos modelos para detecção de anomalias.

6. AGRADECIMENTOS

Os autores reconhecem o financiamento e apoio das empresas do grupo CPFL Energia, sob supervisão da ANEEL - Agência Nacional de Energia Elétrica, número do projeto P&D PD-00063-3090.

REFERÊNCIAS

AGRAWAL, S.; AGRAWAL, J. Survey on anomaly detection using data mining techniques. **Procedia Computer Science**, v. 60, p. 708-713, 2015.

ALI, M. PyCaret: An open source, low-code machine learning library in Python. **PyCaret version**, v. 2, 2020.

BOUKERCHE, A., ZHENG, L.; ALFANDI, O. Outlier detection: Methods, models, and classification. **ACM Computing Surveys (CSUR)**, v. 53, n. 3, p. 1-37, 2020.

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. 21, 2017.

CHEN, H. *et al.* Anomaly detection and critical SCADA parameters identification for wind turbines based on LSTM-AE neural network. **Renewable Energy**, v. 172, p. 829-840, 2021.

FENG, Z.; CHEN, X.; LIANG, M. Iterative generalized synchrosqueezing transform for fault diagnosis of wind turbine planetary gearbox under nonstationary conditions. **Mechanical Systems and Signal Processing**, v. 52, p. 360-375, 2015.

ISO 20816-1. Mechanical Vibration—Measurement and Evaluation of Machine Vibration—Part 1: General Guidelines; **ISO**: Geneva, Switzerland, 2016.

LEITE, G. N. P. *et al.* A robust fleet-based anomaly detection framework applied to wind turbine vibration data. **Engineering Applications of Artificial Intelligence**, 2023. v. 126.

LIN, Z.; LIU, X.; COLLU, M. Wind power prediction based on high-frequency SCADA data along with isolation forest and deep learning neural networks. **International Journal of Electrical Power & Energy Systems**, v. 118, p. 105835, 2020.

LIU, Z.; ZHANG, L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings. **Measurement**, v. 149, p. 107002, 2020.

MUNGUBA, C. F. L. *et al.* Ensemble learning framework for fleet-based anomaly detection using wind turbine drivetrain components vibration data. **Engineering Applications of Artificial Intelligence**, 2024. v. 133.

OLABI, A. G. *et al.* A review on failure modes of wind turbine components. **Energies**, v. 14, n. 17, p. 5241, 2021.

OMAR, S.; NGADI, A.; JEBUR, H. H. Machine learning techniques for anomaly detection: an overview. **International Journal of Computer Applications**, v. 79, n. 2, 2013.

SANTELO, T. N.; OLIVEIRA, C. M. R.; MACIEL, C. D.; MONTEIRO, J. R. B. A. Wind turbine failures review and trends. **Journal of Control, Automation and Electrical Systems**, p. 1-17, 2022.

SINGH, D.; SINGH, B. Investigating the impact of data normalization on classification performance. **Applied Soft Computing**, v. 97, p. 105524, 2020.

TRIZOGLU, P.; LIU, X.; LIN, Z. Fault detection by an ensemble framework of Extreme Gradient Boosting (XGBoost) in the operation of offshore wind turbines. **Renewable Energy**, v. 179, p. 945-962, 2021.

XIANG, L.; YANG, X.; HU, A.; SU, H.; WANG, P. Condition monitoring and anomaly detection of wind turbine based on cascaded and bidirectional deep learning networks. **Applied Energy**, v. 305, p. 117925, 2022.

ENERGIA EÓLICA: ANÁLISE DE DESEMPENHO DE AEROGERADORES INSTALADOS NO NORDESTE DO BRASIL FRENTE A DISTÚRBIOS NA REDE DE CONEXÃO

Dr. Eloi Rufato Junior¹, Bruno Alisson Rodrigues², Édi Carlos Pedroso³, João Gabriel Silochi⁴

UTFPr - Universidade Tecnológica Federal do Paraná, Departamento Acadêmico de Engenharia Elétrica
e COPEL - Departamento de Energia Eólica, UTFPr - Universidade Tecnológica Federal do Paraná,
Departamento Acadêmico de Engenharia Elétrica, UTFPr - Universidade Tecnológica Federal do Paraná,
Departamento Acadêmico de Engenharia Elétrica, UTFPr - Universidade Tecnológica Federal do Paraná,
Departamento Acadêmico de Engenharia Elétrica

elrufato@utfpr.edu.br, brunoalisson@alunos.utfpr.edu.br, edi.carlos.rbs@gmail.com,
joaogabrielsilochi@alunos.utfpr.edu.br

RESUMO

A maior necessidade de energia elétrica, traz consigo a constante busca por potenciais fontes para a geração de energia elétrica. O sistema elétrico interligado brasileiro está em expansão, com a mudança da matriz energética sobretudo por meio de fontes renováveis, de característica intermitente, tipicamente acopladas à rede com uso de equipamentos de eletrônica de potência. Estes aproveitamentos energéticos têm características que causam propagação de fenômenos eletromagnéticos na extensão da rede onde se conectam. Diante disto, este trabalho visa avaliar a suportabilidade de aerogeradores a afundamentos de tensão, devido à ocorrência de curtos-circuitos na rede básica de transmissão, bem como realizar o estudo das distorções harmônicas causadas pela geração de energia eólica ao sistema. Para o desenvolvimento desta análise é feito um estudo de caso em um complexo eólico localizado no nordeste do Brasil. A modelagem do sistema é realizada utilizando os softwares ATPDraw e HarmZs, por meio de modelos equivalentes do complexo eólico. As simulações de afundamento de tensão realizadas demonstraram a existência de pontos de permissão de desconexão das máquinas do parque eólico, conforme diretrizes vigentes, na primeira e segunda vizinhança. Os resultados das simulações de distorção harmônica apontam que o desempenho do parque eólico estudado já apresenta taxa de distorção harmônica individual adequada e também que a instalação de um banco de capacitores futuro deverá reduzir a taxa de distorção harmônica para a maioria das frequências.

Palavras-chaves:

Energias Renováveis; Sustentabilidade; Energia Eólica; Qualidade de Energia Elétrica; Harmônicos; Suportabilidade a Afundamentos.

ABSTRACT

An increase of demand for electric energy results in a search for potential generation sources. The SIN (Brazilian interconnected electrical system) is expanding with the growth of its energy matrix mainly through renewable sources, as solar and wind generation. Those kind of sources configure an intermittent nature of generation and are typically linked to the grid using power electronics equipments. Also, they have intrinsic features that cause electromagnetic propagation phenomena in the extension of the grid

where they are connected. Considering that scenario, the aim of this work is to evaluate wind turbines hold out in voltage sags situations, due to the occurrence of transmission grid short circuits. Plus, this work searches, as well, to carry out the study of the harmonic distortions caused by the wind generation to the Brazilian electric system. To develop this analysis, a case study is performed in a wind power plant located in the northeast of Brazil. Whole system is modeled using the ATPDraw and HarmZs softwares by equivalent models of the wind power plant. Voltage sag simulations applied showed up an existence of permission points for disconnecting the wind generators units in the first and second closer buses (closer substations), according to current Brazilian guidelines. As results, harmonic distortion simulations indicate that the performance of the wind power plant studied already presents an adequate individual harmonic distortion rate. Also, a future capacitor bank installation should reduce the harmonic distortion rate for a larger range of frequencies.

Keywords:

Renewable Energies; Sustainability; Wind Energy; Electrical Power Quality; Harmonics; Low Voltage Ride-Through;

1. INTRODUÇÃO

A evolução de processos agrícolas e industriais, bem como o crescente avanço tecnológico de dispositivos eletrônicos, associado ao facilitado acesso da população a estes produtos, traz consigo uma maior necessidade do consumo de energia elétrica no mundo. A partir dessa necessidade, tem-se adotado alternativas de fontes de energia já estabelecidas, assim como se tem buscado alternativas sustentáveis, como o exemplo da geração de energia elétrica comercialmente por meio de fontes primárias eólicas.

A geração de energia elétrica por meio de usinas eólicas tem se apresentado como uma excelente com grande crescimento nos últimos anos, na qual conforme ANEEL (2023), em maio de 2023 alcançou 13,34% da matriz energética.

Entretanto, existem desafios envolvidos na conexão dessas fontes ao SIN (Sistema Interligado Nacional), pois geralmente se concentram distantes dos grandes centros de carga, aumentando perdas no sistema, incompatibilidade entre geração e demanda, respectivamente quedas de tensão e desvios de frequência (ACKERMANN, 2005). Outra característica é a intermitência dessas fontes, com consequências adicionais decorrentes da dificuldade de despacho destas.

2. ESTADO DA ARTE/ FUNDAMENTAÇÃO TEÓRICA

Faz-se embasamento da teoria técnica de geração de energia eólica, com compreensão de todos os componentes e sistemas, além do ambiente regulatório vigente no Brasil. O estudo de a fundamentos de tensão é elaborado utilizando a ferramenta computacional ATPDraw (Alternative Transient Program). A simulação para verificação dos harmônicos gerados pelo parque eólico no PAC é realizada por meio do software HarmZs do CEPEL. O estudo de caso aborda uma subestação PAC localizada na região do nordeste do Brasil, que conta ao todo com 149 aerogeradores totalizando aproximadamente 312,9 MW de potência instalada, com circuitos alimentadores de 34,5 kV, distribuídos em entre três transformadores elevadores para 230 kV.

2.1 Cenário da Energia Eólica

Em 2021, a indústria eólica mundial teve o seu segundo melhor ano, com quase 94 GW de capacidade instalada, com uma previsão de alcançar a marca de 110 GW de novas instalações até 2026 (GWEC, 2022, p. 9 - 11). Conforme o Gráfico 1 pode-se observar a evolução da capacidade mundial instalada no decorrer dos últimos 22 anos.




Gráfico 1 - Desenvolvimento histórico de instalações de geração eólica.
Fonte: GWEC (2022).

No Brasil em 2021 a capacidade instalada de geração eólica atingiu a marca de 20 GW, correspondendo aproximadamente a 70% de toda capacidade eólica da América Latina, sendo a segunda maior fonte de geração de energia do país (GWEC, 2022, p. 127).

Em 2021 foi possível realizar o marco regulatório para o setor offshore, devido a publicação do Decreto 10.946/2022, dispondo da transferência de recursos físicos, bem como a utilização de recursos naturais para a geração de energia elétrica em usinas offshore. A EPE prevê que a capacidade eólica offshore instalada no mar atinja 16 GW até 2050 com uma redução de CAPEX de 20%, onde CAPEX é a sigla do termo, em inglês, Capital Expenditure, que significa “despesas de capitais”, é destinado aos bens intangíveis da empresa, sendo assim, corresponde a parcela dos recursos da empresa que será destinada a bens de capital (GWEC, 2022, p. 127 - 128).

2.2 Aeroogeradores

Os principais componentes da turbina eólica são ilustrados na Figura 1.




Figura 1 - Componentes de um Aeroerador.
Fonte: CEPEL (2014).

2.3 Tipo D - Turbina eólica de velocidade variável completa e gerador síncrono de ímãs permanentes (PMSG) ou gerador síncrono de rotor bobinado (WRSG)

A configuração do Tipo D trás um gerador síncrono acoplado a um conversor de frequência de potência integral, podendo ser gerador multipolos que dispensam a utilização da caixa de engrenagens (SÖDER; ACKERMANN, 2005, p. 59). O rotor do gerador pode ser de ímãs permanentes ou de rotor bobinado (MANWELL et al., 2002, p.235). O conversor de frequência compensa a potência reativa, efetua a conexão com a rede elétrica e permite a variação livre da velocidade da turbina. A Figura 2 ilustra as características dessa configuração.



Figura 2 - Turbina eólica de velocidade variável completa com conversor de frequência em escala real
TIPO D

Fonte: Adaptado de Söder e Ackermann (2005).

2.4 Conversores de frequência

As turbinas eólicas de velocidade variável geram tensão e frequência variável, por esta característica, não são conectadas diretamente à rede, sendo assim a aplicação de conversores é necessária para a operação desses sistemas e sua conexão com a rede. Destacam-se os seguintes tipos: sistemas de inversores comutados em rede e sistemas de inversores auto comutados (ENERGIE, 2001, p.10).

Inversores comutados em rede são baseados em tiristores convencionais, por meio de chaveamento comutado, possuindo um custo menor, baixas perdas e a necessidade de conexão com a rede para a sua operação, possui como principal ponto negativo o consumo de energia reativa e produção de grandes harmônicos (SÖDER; ACKERMANN, 2005, p. 73). Conforme Energie (2001, p.10) os inversores à base de tiristores produzem harmônicos inteiros de 5^a, 7^a, 11^a, 13^a ordem, sendo essencial a utilização de filtros.

Inversores auto comutados são baseados em GTO (tiristores comutáveis de desligamento de porta), com frequência de comutação de 1kHz e transistores bipolares de porta isolados (IGBT) de frequência de comutação de 2 a 20kHz (SÖDER; ACKERMANN, 2005, p.60-61). Conforme Energie (2001, p.11), esses inversores são modulados por largura de pulso (PWM) com a utilização mais frequente de IGBTs, tem como principal vantagem o controle de potência ativa e reativa, bem como o fornecimento de reativo pelo inversor PWM. De acordo com Söder e Ackermann, (2005, p.106) esse modelo tem como principal vantagem o controle da potência ativa e reativa. Entretanto, traz consigo a desvantagem de produzir correntes harmônicas da ordem de kHz, sendo essencial a utilização de filtros para a redução desses harmônicos de altas frequências.

No que se refere aos autos comutados pode-se destacar o conversor back-to-back, um dos mais utilizados nos aerogeradores de velocidade variável e objeto do estudo do presente trabalho, sendo bidirecional com dois conversores VSC (Voltage Source Converter), modulados por largura de pulso (PWM). Seu principal elemento é o transistor de porta isolada IGBT, atuando como chave. A presença de um capacitor em seu elo CC interno permite a compensação de reativos tanto da rede quanto do gerador sem que cada lado afete o outro. A Figura 3 apresenta os detalhes da estrutura desse conversor.




Figura 3 - Estrutura do Conversor de Frequência back-to-back
Fonte: Adaptado de Söder e Ackermann (2005).

2.5 Problemas à qualidade de energia causados por sistemas eólicos conectados à rede

A conexão de sistemas de energia eólica à rede afeta a qualidade da senoide de tensão elétrica, devido às características dos equipamentos e do local da instalação (SÖDER; ACKERMANN, 2005, p. 79). Para isso, procura-se injetar menos correntes harmônicas na rede ou criação de caminhos de baixa impedância para que essas correntes não provoquem distorções de tensão.

2.6 Harmônicos em sistemas de geração eólica

A razão de distorção harmônica total de corrente ou tensão é um índice utilizado para avaliar o fator de qualidade de tensão e corrente em um sistema de potência em regime permanente (FISCH, 2021, p. 43).

Por motivos econômicos, os transformadores operam próximo da região de saturação da curva de magnetização; desta forma, na condição em que o equipamento está com carga baixa e sobretensão, acaba levando a sobre-excitação do transformador, fazendo com que opere na região de saturação da curva de magnetização (MACHADO, 2017, p.47). Como consequência, apresenta uma corrente de excitação rica em harmônicos de terceira e quinta ordem (ARRILLAGA; BRADLEY, 1985 p.98).

O estudo (LIU; LARA; SILVA, 2022) promoveu o estudo de percepção da Distorção Harmônica frente à variação dos parâmetros da rede interna da CGE, na qual identificou que a distorção harmônica

calculada pelo método do Lugar Geométrico varia em função do nível de curto circuito do PAC, sistemas mais fortes, com maior nível de curto circuito, são menos suscetíveis às distorções harmônicas.

A análise de como as correntes harmônicas emitidas por diferentes turbinas se comportam na rede interna coletora da CGE é evidenciada no artigo (YANG; BOLLEN; LARSSON, 2014), na qual demonstra que as correntes inter-harmônicas revelam uma distribuição angular uniforme em torno da origem do plano complexo, enquanto que as correntes harmônicas apresentam uma distribuição angular não uniforme centralizada em um ponto distinto da origem no plano complexo o que acaba influenciando no efeito de agregação ou cancelamento destas correntes. A Norma Europeia IEC 61000-2-2 define o termo inter-harmônicas como sendo quaisquer frequências múltiplas não inteiras da frequência fundamental.

2.7 Qualidade de Energia

As principais diretrizes dos requisitos necessários às instalações integrantes do Sistema Elétrico de Potência, sob o aspecto técnico da qualidade de energia elétrica é regida sob dois documentos principais, o PRODIST, redigido pela Aneel, e os Procedimentos de Rede, redigidos pelo ONS.

2.7.1 Fenômenos associados à qualidade de energia elétrica, normatizados no PRODIST (ANEEL)

No PRODIST a qualidade da energia elétrica é subdividida em qualidade do produto e qualidade do serviço, com a qualidade do produto definida como a conformidade da senoide de tensão entregue e com a qualidade do serviço definida como continuidade do fornecimento de energia elétrica (ANEEL, 2022). No Brasil, por determinação da Aneel, devem ser cumpridos os requisitos de qualidade de energia elétrica contidos no módulo 8 do PRODIST, com aplicabilidade para consumidores, centrais geradoras, distribuidoras, agentes importadores e exportadores de energia elétrica, transmissoras detentoras de DITs e o ONS.

São definidos no PRODIST fenômenos de regime permanente e de regime transitório com indicadores a serem monitorados referentes à qualidade do produto. Tem-se como fenômenos de regime permanente a variação de tensão, fator de potência, harmônicos de tensão, desequilíbrio de tensão, flutuação de tensão e variação de frequência (ANEEL, 2022). O fenômeno de regime transitório para avaliação da QEE é a variação de tensão de curta duração.

2.7.2 Distorções harmônicas

As distorções harmônicas são fenômenos associados a deformações da onda de tensão, que deve ser uma senoide pura e com frequência fundamental situada dentro da faixa de 59,9 a 60,1 Hz em condições normais (ANEEL, 2022).

A informação de distorções harmônicas da onda de tensão é obtida por meio de 1008 (mil e oito) registros válidos por mês civil, obtidos sucessivamente com intervalos de 10 minutos entre eles, totalizando 7 dias de medição. Recomenda-se a obtenção de registros adicionais também consecutivos caso seja necessário a realização de expurgo devido a interrupção no fornecimento de tensão ou ocorrência de VTCD, (ANEEL, 2022). O Quadro 2. Apresenta os valores máximos permissíveis de distorção harmônicas.

Quadro 2- Limites permitidos de distorção harmônica.

Indicador	Vn < 2,3 kV	2,3 kV ≤ Vn < 69 kV	69 kV ≤ Vn < 230 kV	Indicador
DTT95%	10,00%	8,00%	5,00%	DTT95%
DTTp95%	2,50%	2,00%	1,00%	DTTp95%
DTTi95%	7,50%	6,00%	4,00%	DTTi95%
DTT395%	6,50%	5,00%	3,00%	DTT395%

Fonte: Adaptado de ANEEL (2022)

Além disso, se a medição for feita por meio de TP - transformadores de potencial, com conexão do tipo V, os limites para DTT3 95% são reduzidos à metade do valor declarado no Quadro 2 (ANEEL, 2022). No PRODIST não há menção de valores permissíveis específicos para limites de distorção harmônica para tensões nominais iguais ou superiores a 230 kV, portanto os Procedimentos de Rede são a referência deste fator de QEE no Brasil.

2.8 Fenômenos associados à qualidade de energia normatizados nos Procedimentos de Rede (ONS)

No submódulo 2.9 dos Procedimentos de rede se tem os requisitos mínimos a serem atendidos por instalações que contenham elementos com características não lineares ou especiais prejudiciais, à QEE na Rede Básica, na qual não se faz distinção entre qualidade de produto e qualidade de serviço como acontece no PRODIST, agrupando todos os fenômenos no conjunto qualidade de energia elétrica.

2.8.1 Distorção harmônica

A distorção harmônica de tensão é avaliada com relação a limites individuais e globais (ONS, 2022). Ambos são avaliados diretamente por meio de campanhas de medição aplicadas ao PAC quando a conexão é exclusiva. Quando há mais de uma instalação os limites globais são avaliados da mesma forma e os limites individuais são verificados a partir de cálculos em conjunto com a medição aplicada ao PAC. A partir dos indicadores de distorção harmônica obtidos anteriormente se calcula o indicador DTHTS95% primeiro se obtendo o valor que foi superado em 5% dos registros obtidos em período de 1 dia (24 horas), considerando o valor integralizado em intervalos de 10 minutos e depois de obtidos esses valores, utiliza-se o maior valor obtido em base diária ao longo de 7 (sete) dias consecutivos. O valor usado para cada período de cálculo deve ser o maior valor obtido entre as três fases (ONS, 2023). Os limites são apresentados no Quadro 3 e no Quadro 4.

Quadro 3- Limites globais para os indicadores DTHI e DTHTS95%

DTHI de ordem harmônica h	Vn < 69 kV		69 kV = Vn	
	Ímpar	Par	Ímpar	Par
2 = h = 7	5,00%	2,00%	2,00%	1,00%
8 = h = 14	3,00%	1,00%	1,50%	0,50%
15 = h = 25	2,00%	1,00%	1,00%	0,50%
26 = h	1,00%	1,00%	0,50%	0,50%
DTHTS95%	6,00%		3,00%	

Fonte: Adaptado de ONS (2021)

Quadro 4- Limites individuais para os indicadores DTHI e DTHTS95%

DTHI de ordem harmônica h	Vn < 69 kV		69 kV = Vn	
	Ímpar	Par	Ímpar	Par
2 = h = 25	1,50%	0,60%	0,60%	0,30%
26 = h	0,70%	0,60%	0,40%	0,30%
DTHTS95%	3,00%		1,50%	

Fonte: Adaptado de ONS (2021)

3. MÉTODO DO ESTUDO

3.1 Modelos de Estudo para Qualidade de Energia Elétrica

O objetivo dos estudos de QEE no sistema de potência é avaliar o impacto operacional de novas instalações no Ponto de Acoplamento Comum PAC. Os estudos são conduzidos para avaliar a integração de novas instalações, interação entre instalações já existentes ou uma combinação de ambas. Quando conduzidos de maneira adequada possibilitam identificar já nas etapas de projeto as características das conexões futuras e quando realizados com a instalação em operação permitem caracterizar os fenômenos, permitindo racionalização da condição operativa da instalação.

3.1.1 Afundamentos de tensão

No Brasil o ONS determina as condições mínimas que o parque eólico deve satisfazer para possibilitar a sua conexão ao SIN, por meio dos seus Procedimentos de Rede no submódulo 2.1, que estabelece os principais requisitos técnicos para a conexão do parque gerador com a rede básica.

Durante a ocorrência de curto-circuito no SIN, por se tratar de uma rede forte, que possui uma potência de curto-circuito muito mais alta quando comparado com o parque eólico, ocorre o afundamento da tensão até que haja a desconexão do ponto com a falha, por meio da atuação da proteção (disjuntor). De modo a garantir a confiabilidade do sistema elétrico de potência é exigido pelo ONS que caso haja variações de tensão no ponto de conexão, durante a ocorrência de curtos-circuitos na rede, a unidade geradora deve operar sem a desconexão de suas máquinas, para garantir o restabelecimento de tensão do sistema, conforme a Figura 4.




Figura 4 - Tensão nos terminais aerogeradores ou inversores da central geradora.
Fonte: (ONS, 2023)

Para realizar a verificação dos níveis de afundamento de tensão que podem ser sentidas no ponto de conexão, foi realizado a simulação de faltas em todas as linhas que compõem duas vizinhanças, para LT's superiores a 100 km, ou o número de vizinhanças que possuam no mínimo 100 km de LT entre o ponto estudado e os equivalentes da rede, conforme previsto nos procedimentos de rede do ONS submódulo 2.3. Foi considerado faltas trifásicas, bifásicas e fase-terra, todas sólidas, com duração para atuação da proteção de 100 ms, para pontos do sistema em 500 kV, e 150 ms segundos, para pontos do sistema em 230 kV, conforme valores estabelecidos pelos procedimentos de rede submódulo 2.6. Com base nesses parâmetros foi modelado o sistema e seus equivalentes no software ATPDraw, de modo a identificar eventuais pontos de sensibilidade em que se pode realizar a desconexão das máquinas.

3.1.2 Modelagem de turbina eólica

As configurações de conexão dos geradores em complexos eólicos disponíveis variam de acordo com as características elétricas, pois cada tipo possui um sistema de proteção individual, que pode ser vantajoso ao sistema, pois em caso de falhas no sistema, apenas de 5 a 15% das turbinas são desligadas da rede, resultando em uma menor perda de geração (MULJADI; GEVORGIAN, 2011). Entretanto, tais simulações exigem uma maior análise do modelo estudado e das suas configurações elétricas básicas.

Tendo em vista, que um complexo eólico compreende a instalação de diversos aerogeradores e suas redes coletoras associadas, onde na ocorrência de falta no sistema, a corrente de curto-circuito total desse complexo é a soma das contribuições individuais de cada gerador, o que torna a análise muito complexa (MULJADI; GEVORGIAN, 2011).

No que diz respeito a turbinas eólicas do Tipo 4 (PMSG), presentes na central geradora analisada, mesmo o sistema operando na frequência de 60 Hz, devido ao fato do gerador estar conectado diretamente ao conversor, operando de forma isolada do sistema, devido às velocidades variáveis aos quais está submetido, seus enrolamentos estão operando com frequências variáveis. Desta forma, conforme Muljadi e Gevorgian (2011) a contribuição de potência de curto-circuito é limitada pela sua corrente nominal, ou pouco acima disso, geralmente projetados com uma margem de 10% acima da sua capacidade nominal durante as faltas.

Devido ao fato de tais parâmetros serem controlados pelo conversor, conforme Muljadi e Gevorgian (2011) pode-se realizar a representação das turbinas eólicas por uma fonte de corrente trifásica constante durante um curto-circuito, respeitando os limites de proteção do conversor da máquina. Esse tipo de simplificação torna possível a modelagem do complexo eólico como um todo e otimização de recursos de processamento de simulação. Os dados dos geradores síncronos que são utilizados no sistema de geração eólico estudado e os respectivos dados de curto-circuito são apresentados no Quadro 5.

Quadro 5- Dados de curto circuito de cada aerogerador

Equipamento	Tensão (kV)	I _{max Seq.+} (A _{rms})/unid.	FP CC (curto)	FP pré falta	VP1	VP2
47 Aerogeradores x 2,1 MW	34,5	50,76	0,1	1,00	0,50	0,85
50 Aerogeradores x 2,1 MW	34,5	50,76	0,1	1,00	0,50	0,85
52 Aerogeradores x 2,1 MW	34,5	50,76	0,1	1,00	0,50	0,85

Fonte: Autoria própria (2023)

3.1.3 Modelagem de gerador síncrono

O modelo do gerador síncrono vem da análise do diagrama fasorial das tensões, na qual para uma determinada V_t em seus terminais é necessária uma E_a tensão interna, que possui quedas de tensão

causadas pela reação de armadura X_r , reatância de dispersão X_{ir} , representadas em conjunto por X_s , denominada de reatância síncrona, e a resistência de armadura R_a (STEVENSON, 1986).

Em estudos de curto-circuito conforme Kindermann (1997) é possível realizar a representação do gerador síncrono apenas por uma fonte de tensão alternada em série com sua reatância síncrona subtransitória. Esta modelagem é mais conservadora pois a ausência da resistência de armadura resulta em valores de corrente de curto-circuito mais elevados do que aconteceria caso fosse considerada.

3.1.4 Modelagem da rede coletora

As redes de distribuição interna, que realizam a conexão das instalações das centrais de geração eólica com as subestações coletoras, são alimentadas no nível de tensão de 34,5 kV. A modelagem desse sistema foi realizada por parâmetros concentrados no modelo PI (π), em % na base de 100 MVA. No Quadro 6 são apresentados os dados dos cabos de conexão das redes coletoras do parque eólico.9.

Quadro 6 - Parâmetros dos cabos das redes coletoras

Tipo do cabo	R1 (Ω /km)	X1 (Ω /km)	C1 (μ F/km)	R0 (Ω /km)	X0 (Ω /km)	C0 (μ F/km)
CAIRO	0,1425	0,3875	0,0116	0,3207	2,0340	0,0043
150 mm2	0,2647	0,1500	0,1846	1,6862	0,0890	0,1846

Fonte: Autoria própria (2023)

3.1.5 Modelagem das linhas de transmissão

A modelagem das linhas de transmissão do sistema, foi realizada conforme orientações das diretrizes para elaboração de projetos básicos da transmissão (ONS, 2013), bem como, atendendo aos procedimentos de rede 2.3 (ONS, 2022), que orientam a representação da linha de transmissão por parâmetros distribuídos.

Os dados das linhas de transmissão do sistema de potência conectado ao sistema de geração eólico estão base de potência de 100 MVA, obtidos pelos dados do ONS no software ANAFAS.

3.1.6 Modelagem dos transformadores

Um transformador pode ser modelado com base em sua resistência dos enrolamentos, reatância de indutiva X_s , que representa a queda de tensão causada no secundário pelas diferenças dos fluxos que enlaçam os enrolamentos. Entretanto, para a maioria das simulações realizadas em sistemas de potência, conforme Stevenson (1986) e Kindermann (1997), pode-se efetuar uma simplificação no modelo, ignorando assim a corrente de magnetização, tendo em vista que ela é muito inferior à corrente da carga.

3.2 Dados do sistema de potência

Os parâmetros dos transformadores que compõem o sistema interligado nacional, bem como dos transformadores equivalentes, gerados pelo cálculo do equivalente do sistema interligado no software ANAFAS, que são fornecidos pelos dados técnicos do ONS.

3.3 Harmônicos em regime permanente

O ONS afirma que ainda há limitações nos modelos de fluxos de harmônicos e é recomendado nos Procedimentos de Rede, em seu Submódulo 2.3, a adoção do método do lugar geométrico (LG) para a avaliação de desempenho com relação à distorção harmônica. O estudo é conduzido de forma a se obter valores de distorção harmônica de tensão a partir das correntes harmônicas geradas por equipamentos não lineares presentes no sistema. A forma geral é equacionada pela Lei de Ohm, onde se obtém uma tensão a partir da divisão de uma corrente por duas admitâncias em paralelo. Opta-se esta representação pela facilidade de estudo de diferentes configurações da rede externa. O modelo é representado conforme a Figura 5.




Figura 5 - Circuito equivalente de Norton para simulação de distorção harmônica.

Fonte: Autoria própria (2023)

Adota-se um circuito por frequência harmônica conforme a Figura 5, com Y_{ih} representando a Rede Interna completa. Para cada frequência harmônica é gerada uma nuvem de pontos da Rede Externa Y_{bh} , composta pelas admitâncias equivalentes da rede externa na sua configuração completa e em todas as suas configurações de contingência $n-1$, para a harmônica em questão e para as inter-harmônicas de $h-1$ a $h+1$ no método LG anular ou para as inter-harmônicas de $h-0,5$ a $h+0,5$ com passo $0,1$ h no método do LG poligonal. Com a nuvem Y_{bh} disponível, calcula-se a distância mínima entre sua envoltória e Y_{ih} .

A fonte de corrente harmônica da Figura 5 é a agregação em paralelo das correntes individuais dos equipamentos não lineares. Considera-se para tal somente as magnitudes máximas (pior caso) agregadas, conforme a IEC 61000-3-6. As magnitudes das correntes harmônicas de cada equipamento devem ser obtidas via medição, com ressalva que adicionalmente, acoplamentos via inversores devem ter a medição certificada conforme a IEC 61400-21.

3.4 Modelagem de resistência em função da frequência

É exigido que se faça correção dos valores de resistência em função da frequência para os elementos das redes sob estudo de distorção harmônica a serem aceitos para integração de instalações ao SIN (ONS, 2018). Internamente ao software HarmZ é fornecido um único modelo de correção das resistências, preparado para ser utilizado diretamente sobre os dados da rede modelada em frequência fundamental conforme dados de entrada para estudos de fluxo de potência utilizando o software Anarede. No manual do software HarmZ constam parâmetros de correção de resistência em função da frequência a serem utilizados caso não se tenha um estudo próprio caracterizando os efeitos de alteração da resistência em função da frequência.

4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

O presente capítulo apresenta os resultados e discussões das simulações de afundamentos de tensão realizadas no software ATPDraw e de harmônicos em regime permanente no software HarmZs. Os estudos de afundamento de tensão modelados em softwares de simulação, devem buscar o máximo a melhor representação dos fenômenos envolvidos no processo analisado, para que seja possível apresentar resultados de mesma natureza e com valores muito próximos ao esperado fisicamente. Em contrapartida há um conteúdo bem detalhado de dados que foram atendidos, para que o estudo de distorção harmônica seja aprovado pelo ONS.

4.1 Resultados da simulação de harmônicos em regime permanente

Foi realizado um estudo limitado a respeito da distorção harmônica, considerando apenas um parque integrante de um complexo de geração eólica. A Rede Interna e as fontes harmônicas não correspondem a totalidade do empreendimento, porém a Rede Externa é representativa da característica de distorção de tensão em função das correntes geradas nos elementos não lineares presentes.

No parque eólico estudado não ocorre violação dos limites de distorção harmônica individual de ordem 2 a 50 estipulados no Quadro 3 e 4. As distorções globais contidas no Quadro 3 não foram consideradas pois seria necessário um estudo completo do complexo de geração eólica.

A presença futura do banco de capacitores na barra de 34,5 kV da subestação cria um caminho de impedância menor para as frequências mais altas, característica esperada da resposta em frequência dos capacitores. Além disso, não há efeito de ressonância que se acentua com a inserção do banco. Uma impedância resultante das redes Interna e Externa mais baixa provoca menos distorção de tensão para correntes de distorção iguais. A Figura 6 mostra a resposta em frequência vista do PAC conforme o modelo da Figura 5.

O resultado da Figura 6 foi obtido com a ferramenta auxiliar do HarmZ de resposta em frequência. Na Tabela 1 constam os resultados dos cálculos para os harmônicos com corrente diferente de zero que comprovam a Figura 6 e os mesmos cálculos para o caso do banco de capacitores futuro ligado ao sistema. É apresentado também a diferença de distorção harmônica individual entre os dois casos, onde ocorre o aumento para ordens de 2 a 8 devido ao deslocamento da frequência de ressonância. Para

ordens harmônicas maiores ocorre redução devido a redução da impedância na maior parte do espectro de frequência. Além disso, a distorção harmônica total não viola os limites estabelecidos e se reduz com a inserção do banco de capacitores devido à redução de impedância, conforme apresentado na Tabela 2.

h	Sem banco de capacitores			Com banco de capacitores			Redução da DHI (%)
	I Norton (pu)	Ymin (pu)	DHI Máx (%)	I Norton (pu)	Ymin (pu)	DHI Máx (%)	
2	0,000008	41,155648	0,00002	0,000009	40,719815	0,000023	-0,000003
3	0,000008	27,462161	0,000031	0,000011	26,709472	0,000039	-0,000008
4	0,000005	20,312193	0,000026	0,000008	19,051643	0,000044	-0,000018
5	0,000098	15,858502	0,00062	0,000221	13,543342	0,001632	-0,001012
7	0,00006	10,480503	0,000568	0,00059	24,989356	0,002362	-0,001794
8	0,000044	8,674222	0,000502	0,000101	12,752978	0,00079	-0,000288
9	0,000015	7,189962	0,000205	0,000018	9,702447	0,000186	0,000019
10	0,000038	5,926028	0,000642	0,000031	7,816501	0,000391	0,000251
11	0,000022	4,81617	0,000464	0,000013	6,376336	0,000204	0,00026
13	0,000008	2,88613	0,00027	0,000003	4,112777	0,000067	0,000203
14	0,000008	2,004034	0,000399	0,000002	3,140611	0,000074	0,000325
15	0,000021	1,144287	0,001826	0,000005	2,218291	0,000228	0,001598
16	0,000007	0,299134	0,002313	0,000001	1,314965	0,000108	0,002205
17	0,000021	0,127075	0,016879	0,000004	0,422239	0,000897	0,015982
23	0,000012	2,853996	0,000435	0,000001	1,756228	0,00006	0,000375
29	0,000018	1,947456	0,000912	0,000001	1,13805	0,000072	0,00084
35	0,000056	13,021658	0,000426	0,000001	9,359756	0,000013	0,000413
37	0,000214	34,524409	0,000619	0,000003	12,556153	0,00002	0,000599
41	0,000261	20,53904	0,001269	0,000017	36,55428	0,000045	0,001224
43	0,000153	16,198031	0,000942	0,000013	35,954546	0,000036	0,000906
47	0,000046	1,736566	0,002643	0,000002	4,038926	0,000042	0,002601
49	0,000027	0,75872	0,003581	0,000001	1,755999	0,000046	0,003535

Tabela 1- Resultados de distorção harmônica com e sem banco de capacitores, e a redução na DHI
Fonte: Autoria própria (2023)

DHT Máx com relação ao estado do banco de capacitores (%)		
Ligado	Desligado	Redução
0,003161	0,01787	0,014709

Tabela 2 – Redução da DHT após inserção do banco de capacitores
Fonte: Autoria própria (2023)



Figura 6 - Resposta em frequência do PAC com e sem banco de capacitores
Fonte: Autoria própria (2023)

4.2 Resultados da simulação de afundamentos de tensão

Este item visa a apresentação dos resultados obtidos durante a simulação de afundamentos de tensão, sentidos na barra de 230 kV do PAC, devido à ocorrência de curto-circuito, desde monofásicos, bifásicos-terra e trifásicos-terra. Foi tomado como premissa as falhas de maior incidência, que são as momentâneas, na qual após um determinado tempo se auto extingue, retornando o sistema em suas condições normais pós-falta. As condições iniciais de operação do sistema em regime permanente, tais como, níveis de tensão e potência fornecidas pelo grupo de aerogeradores estudado, foram realizadas por meio do software ANAREDE, tendo como base o caso VERÃO 2023/2024 média.

4.2.1 Curto-circuito LT 230 kV BPAC-BAR01

O parque eólico estudado está localizado no Rio Grande do Norte, possui ao todo 149 aerogeradores, que totalizam aproximadamente 312,9 MW de potência instalada e estão conectados nas barras de 34,5 kV BARGG1, BARGG2 e BARGG3. As redes coletoras são alimentadas em 34,5 kV, que direcionam toda potência gerada via cabos aéreos e subterrâneos até o transformador elevador de 230 kV, que está conectado a barra de 230 kV BAPAC.

O afundamento sentido pelo PAC, durante a execução de curto-circuito trifásico-terra no meio da LT 230 kV BPAC-BAR01, que está localizada entre o parque eólico e a barra BAR01 na primeira vizinhança, em uma falha desta característica com duração de 150 milissegundos, ocorre afundamentos de tensão que chegam a valores de aproximadamente 0,089 p.u conforme ilustrado na Figura 7.




Figura 7 - Afundamento de tensão na barra do PAC por curto-circuito trifásico-terra na barra 1
Fonte: Autoria própria (2023)

O valor da corrente de curto-circuito encontrada na simulação do ATPDraw foi de aproximadamente 9,3 kA, visando estimar um parâmetro de referência para o estudo, foi realizado a mesma simulação no software ANAFAS, que tem por objetivo específico a realização de análises de curto-circuito no sistema elétrico brasileiro, sendo a ferramenta recomendada pelo ONS para as empresas do setor. O resultado encontrado de corrente de curto-circuito durante a simulação no ANAFAS foi de aproximadamente 9,6 kA, sendo assim, houve uma diferença de 3,3% entre os valores obtidos nos dois sistemas, desta forma, entende-se que para simulações de curto-circuito, em razão das altas correntes envolvidas nessas análises, os resultados estão dentro de parâmetros aceitáveis e validam os valores encontrados na modelagem realizada no ATPDraw.

4.2.2 Curto-circuito demais vizinhanças

A verificação do afundamento de tensão causado no PAC, que são sentidas pelos aerogeradores, devido à ocorrência de curto-circuito fase-terra, bifásico-terra e trifásico-terra em todas as demais vizinhanças, foram simuladas utilizando o mesmo processo apresentado anteriormente, que possibilitaram o levantamento de todos os níveis de afundamento de tensão em p.u., que o parque eólico está sujeito durante as faltas, tendo como base os valores das simulações de curto-circuito do software ATPDraw. No Quadro 7 é apresentado os resultados dos afundamentos de tensão obtidos por local do curto-circuito.

Quadro 7 - Parâmetros dos cabos das redes coletoras

Local do curto-circuito	Fase-terra(p.u)	Bifásico-terra(p.u)	Trifásico-terra(p.u)
LT 230 kV BPAC-BAR01	0,122	0,192	0,089
LT 230 kV BAR01-BAR02	0,371	0,274	0,198
LT 230 kV BAR01-BAR03	0,431	0,290	0,186
LT 230 kV BAR03-BAR06 C1	0,814	0,707	0,665
LT 230 kV BAR03-BAR06 C2	0,828	0,698	0,653
LT 230 kV BAR03-BAR05 C1	0,725	0,530	0,483
LT 230 kV BAR03-BAR05 C2	0,673	0,463	0,419
BARRA 04 500 KV	0,599	0,450	0,447

Fonte: Autoria própria (2023)

Foi realizado a simulação com as mesmas características e locais de curto-circuito, por meio do software ANAFAS em todas as vizinhanças mais relevantes, conforme manual de estudos de transmissão e procedimentos de rede elaborados pelo ONS, ao qual o parque eólico está conectado. A comparação dos valores de corrente de curto-circuito obtidos pelo software ATPDraw com o ANAFAS, serviu como parâmetro de referência e identificação eventuais erros de simulação. No entanto, os resultados

encontrados nas simulações do ATPDraw se mostraram satisfatórios e em consonância com os valores obtidos pelo ANAFAS.

Ao realizar a comparação do resultado entre os softwares ATPDraw e ANAFAS, foi verificado que em 75% das simulações, os valores de variações percentuais de corrente de curto-circuito, foram inferiores a 2%, sendo que as maiores variações percentuais registradas ainda ficaram abaixo de 5%, conforme apresentado no Quadro 8.

Quadro 8 - Resultados obtidos nas simulações nos softwares ATPDraw e ANAFAS

Local do curto	Fase-terra			Fase-fase-terra			Fase-fase-fase-terra		
	Icc(kA) ANAFAS	Icc (kA) ATP	Δ(%)	Icc(kA) ANAFAS	Icc (kA) ATP	Δ(%)	Icc(kA) ANAFAS	Icc (kA) ATP	Δ(%)
LT 230 kV BPAC-BAR01	9,62	9,30	3,4	7,51	7,33	2,5	8,72	8,68	0,5
LT 230 kV BAR01-BAR02	8,99	8,56	4,9	9,04	9,06	0,3	8,66	8,78	1,4
LT 230 kV BAR01-BAR03	11,62	11,51	0,9	13,89	13,94	0,3	14,42	14,45	0,2
LT 230 kV BAR03-BAR06 C1	12,94	13,03	0,7	16,96	16,71	1,4	18,11	18,17	0,4
LT 230 kV BAR03-BAR06 C2	11,55	11,50	0,4	17,39	17,13	1,5	18,85	18,68	0,9
LT 230 kV BAR03-BAR05 C1	18,08	18,21	0,7	22,08	22,04	0,2	22,94	23,61	2,9
LT 230 kV BAR03-BAR05 C2	22,72	22,63	0,4	25,68	25,65	0,1	26,13	26,86	2,8
BARRA 04 500 kV	22,96	22,59	1,6	24,16	24,26	0,4	24,44	25,22	3,2

Fonte: Autoria própria (2023)

Com base nos resultados das simulações de curto-circuito e seus devidos valores de afundamentos de tensão, observadas na barra de 230 kV BAPAC, em função das faltas nas linhas de transmissão, apresentadas anteriormente no quadro 24, foi elaborado uma representação gráfica desses valores por meio da figura 8.

De acordo com a curva de suportabilidade a afundamentos de tensão, estabelecidas pelos procedimentos de rede do ONS, na qual durante a ocorrência de um evento no SIN, que venha a provocar a queda da tensão eficaz da rede para valores inferiores a 0,2 p.u., é permitido a desconexão das máquinas do parque eólico para garantir a proteção dos equipamentos envolvidos no processo de geração de energia.

Com base nos resultados apresentados, verifica-se que há pontos de ocorrência de curto-circuito, que se encontram abaixo da linha vermelha de 0,2 p.u. destacada na Figura 16. É possível identificar que todas as faltas que ocorrem na linha de transmissão que conecta a barra de 230 kV BAPAC a barra 230 kV BAR01 da primeira vizinhança, estão com valores inferiores a 0,2 p.u., resultado já esperado devido à característica radial do trecho analisado.

Entretanto, é possível notar que existe mais dois pontos, que possuem valores de tensão residual inferiores ao de 0,2 p.u., causadas pela ocorrência de curto-circuito trifásico-terra em duas linhas de transmissão, que estão localizadas entre a primeira e segunda vizinhança, a LT 230 kV BAR01-BAR02 e a LT 230 kV BAR01-BAR03.




Figura 8 - Afundamento de tensão x tipo de curto-circuito
Fonte: Autoria própria (2023)

5. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

O presente trabalho apresentou um panorama sobre a análise e comportamento de desempenho de um complexo eólico já instalado e em operação comercial do Brasil, foram caracterizados os critérios de desempenho de resistência ao afundamento de tensão em curto-circuito e as influências da distorção harmônica sobre os outros dois parâmetros de qualidade em regime permanente e em condição de falta.

Com o intuito de analisar a vulnerabilidade dos aerogeradores foi realizado simulações da ocorrência de curto-circuito nas vizinhanças do sistema de transmissão da região, o que resulta em um afundamento de tensão residual no sistema. Conforme procedimentos de rede do ONS, o complexo eólico deve suportar afundamentos da ordem de 0,2 p.u., de modo que possa contribuir para o restabelecimento da tensão aos seus limites nominais, durante e após a ocorrência das faltas.

Com base nos resultados obtidos, foi identificado que há alguns tipos de faltas, principalmente para as trifásicas, que se ocorrerem em determinadas vizinhanças, causam afundamentos de tensão residual maiores que os estipulados pelas diretrizes vigentes, deste modo, seria permitida a desconexão das máquinas do parque eólico. Tendo em vista que tal cenário no SIN, pode representar a ausência de uma fonte de contribuição para a recomposição dos níveis de tensão, durante e após a falta, é de grande relevância que com o crescimento da carga instalada deste tipo de fonte no sistema, haja estudos de planejamento de expansão de redes, que garantam a confiabilidade e contemplem tais condições operacionais.

Diante desse contexto, cabe ressaltar que este trabalho abordou uma análise qualitativa para um estudo de caso, o que por sua vez, pode fomentar o surgimento de novos trabalhos, que proponham soluções diversas de conexões destas fontes no sistema, bem como tecnologias que permitam o seu aprimoramento, do ponto de vista técnico, operacional e regulatório nas tratativas do fenômeno abordado.

O estudo do comportamento em relação aos limites de distorção harmônica foi conduzido de forma a aproximar um trabalho acadêmico ao modelo de estudos e de apresentação exigidos pelo ONS.

A decomposição do sistema em circuitos harmônicos acaba gerando novos circuitos não lineares, devido à característica não linear das resistências em função da variação da frequência. Realizar multiplicação dos valores das correntes harmônicas por alguma constante, com o objetivo de aproximar as distorções resultantes de vários parques conectados à mesma subestação coletora não é modelo válido, apesar das similaridades. Sendo assim, para avaliação dos limites globais de distorção harmônica se requer o estudo completo do complexo eólico.

Avalia-se a entrada em operação de um banco de capacitores futuro, com redução da impedância da rede sem aumento de ressonância. Essa redução atenua a geração de tensões de distorção. A quantificação destes efeitos é possível de ser analisada com os métodos apresentados neste trabalho mas não com a licença acadêmica do HarmZ.

Quanto a sugestão para estudos futuros, propõe-se analisar a qualidade de energia no quesito desequilíbrio de tensão quando da ocorrência de variações cíclicas de velocidade, em sistemas de geração eólica, estudando as variáveis como: velocidade de vento; velocidades de rajadas; variedade de variações do vento, além das perturbações usuais da rede.

REFERÊNCIAS

ANEEL - Agência Nacional de Energia Elétrica, **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST**. 2022, Disponível em: <<https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>> Acesso em: 06 mai. 2023.

ANEEL - Agência Nacional de Energia Elétrica, **Expansão da matriz elétrica Brasileira, 2023**, Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/noticias/2023/novas-usinas-em-operacao-comercial-no-ano-somam-4-610-20-mw>> Acesso em: 16 jun. 2023.

CEPEL - CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA. Site da CRESESB. **Tipos de Aerogeradores para Geração de Energia Elétrica**, 2014. Disponível em: <http://paje.fe.usp.br/~mef-pietro/mef2/app.upload/7/_mefmi_003-05.pdf>, P 08, . Acesso em: 06 mai. 2022.

CEPEL - CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA. **ANAREDE – Análise de Redes Elétricas**. Disponível em <<https://www.cepel.br/produtos/anared-2/>>. Acesso em 06 mai. 2023.

CEPEL - CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA. **ANAFAS: Um programa na medida para cálculos de curto-circuito** Disponível em <<https://www.cepel.br/produtos/anafas-2/>>. Acesso em: 06 mai. 2023.

ENERGIE. 2001. **Wind Turbine Grid Connection and Interaction**. Deutsches Windenergie-Institut GmbH Germany, Tech-wise A/S Denmark, DM Energy United Kingdom.

EPE (Empresa de Pesquisa Energética) **Balanco Energético Nacional (BEN) 2021**: Ano base 2020, 2021. Disponível em < <https://ben.epe.gov.br> > Acesso em: 04 jun. 2022.

EPE (Empresa de Pesquisa Energética) **Plano Decenal de Expansão de Energia 2031**, 2022. <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-pde> Acesso em: 04 jun. 2022.

GWEC [Global Wind Energy Council] **Global Wind Report 2022**, 2022. Disponível em: <<https://gwec.net/global-wind-report-2022/>> Acesso em: 04 jun. 2022.

IEEE (Institute of Electrical and Electronics Engineers) **Recommended Practice for Monitoring Electric Power Quality**, in IEEE Std 1159-1995 , vol., no., pp.1-80, 30 Nov. 1995, doi: 10.1109/IEEESTD.1995.79050.

KINDERMANN, G. **Curto-circuito**. 2. ed. Porto Alegre: Sagra-DC Luzzato, 1997.

MANWELL J. F.; MCGOWAN. J. G.; ROGERS. A. L., **Wind Energy Explained. Theory, Design and Application**. Ed Wiley 577p.w, England, 2004.

MULJADI, Eduard; GEVORGIAN, Vahan. Short-circuit modeling of a wind power plant. In: **2011 IEEE Power and Energy Society General Meeting**. IEEE, 2011. p. 1-9.

ONS (Operador Nacional Do Sistema Elétrico) - **Procedimentos de rede, ONS**, Disponível em: <<https://www.ons.org.br/paginas/sobre-o-ons/procedimentos-de-rede/vigentes>>. Acesso em: 04 jun. 2022.

ONS (Operador Nacional Do Sistema Elétrico). **Sistema Interligado Nacional – Rede de Operação – Horizonte 2023**, 2023. Disponível em: <<http://sindat.ons.org.br/SINDAT/Home/ControleSistema>> Acesso em 27 mai 2023.

PRIKLER, L., HØIDALEN, H. K. **ATPDraw version 5.6 for windows 9x/NT/2000/XP/Vista User Manual**. Norway, 2009. 270 p.

SÖDER, Lennart; ACKERMANN, Thomas. Wind power in power systems: an introduction. **Wind power in power systems**, v. 140, 2005.

STEVENSON William D. Jr. **ELEMENTOS DE ANÁLISE DE SISTEMAS DE POTÊNCIA**, 1986. 4ª Edição americana, 2ª Edição em português.

IMPROVED OPERATIONAL EFFICIENCY IN THE DATA CLEANING OF WIND TURBINE POWER CURVES USING MACHINE LEARNING

Fernando Saraiva¹, Osmar Alexandre¹, Rodrigo Queiroz¹, Vitória Sousa¹, Gustavo Carvalho¹

¹ Delfos Energy

fernando.filho@delfos.energy, osmar.alexandre@delfos.energy, rodrigo.queiroz@delfos.energy,
vitoria.sousa@delfos.energy, gustavo.carvalho@delfos.energy

ABSTRACT

In this work, we address the process of data cleaning when modeling wind turbine power curves. This is a fundamental step because in real-world scenarios, the data usually contains a series of anomalies related to machine limitations, technical unavailability or malfunction of the pitch and yaw control system.

Sometimes, there are no available and reliable logs of events, which would help identify such anomalies. A common alternative would be to apply manual filters, which is a non-scalable approach. Instead, we propose applying a machine learning algorithm, namely the Gaussian Process, which allows the fitting of equivalent power curves, eliminating the need to apply manual filters and increasing the efficiency of the modeling process.

Keywords:

Data cleaning; Gaussian Process; Power Curve

RESUMO

Neste trabalho, abordamos o processo de limpeza de dados durante a modelagem de curvas de potência de turbinas de vento. Essa é uma etapa fundamental porque, em cenários reais, os dados costumam conter uma série de anomalias relativas à limitações da máquina, indisponibilidade técnica ou mal funcionamento dos sistemas de *pitch* e de *yaw*.

Por vezes, não há registros disponíveis e confiáveis de eventos, o que ajudaria a identificar tais anomalias. Uma alternativa comum seria a aplicação de filtros manuais, que não é uma abordagem escalável. Em vez disso, propomos a aplicação de um algoritmo de aprendizado de máquina, a saber, Processo Gaussiano, que permite o ajuste de curvas de potência equivalentes, eliminando a necessidade de aplicação de filtros manuais e aumentando a eficiência do processo de modelagem.

Palavras-chaves:

Limpeza de dados; Processo Gaussiano; Curva de Potência

1. INTRODUCTION

Wind energy has become one of the most important sources of energy around the world. In a scenario where concerns about sustainability are growing, wind energy has gained an increasingly prominent role. The essence of this energy generation process is using wind turbines that convert the kinetic energy of the wind into electrical energy.

The wind turbine power curve (WTPC) of a wind turbine generator (WTG) expresses the power output as a function of the hub height wind speed and every turbine has a unique one (LYDIA et al.,

2014). This kind of curve provides an adequate way to model the performance of wind turbines, and accurate models of power curves are very useful for forecasting of power and monitoring of the turbines (SOHONI, GUPTA, NEMA, 2016).

The standard methodology for measuring the power performance characteristics of a wind turbine has been specified in the International Standard IEC 61400-12-1 was prepared by the International Electrotechnical Commission (IEC) technical committee 88: Wind turbines. The methodology states that measurements of wind speed and power output should be made at a test site for a long enough duration in different atmospheric conditions to obtain a database. The measured power curve is then obtained out of that dataset by the so-called method of bins, which is further explained in section 2.3.

However, as stated in (TRIVELLATO, BATISTI, MIORI, 2012), even though the correct way to investigate wind turbines is by field tests, the power curve obtained by such tests is inescapably affected by various factors, in particular, the turbulence existing in the calibration site. Therefore, the direct application of the power curves to other sites should be avoided and so the need for modeling site-specific curves arises.

In real-world operation scenarios, wind speed and power collected by supervisory control and data acquisition systems (SCADA) usually have some anomalies, which prevents their direct use for the performance analysis of wind turbines. Because of this, in order to obtain curves that really reflect the operating performance of wind turbines, it is fundamental to clean the data collected by SCADA (LAI et al., 2023).

1.1 Objective

SCADA systems provide not only aggregated 10-minute data but also logs of events of the wind turbine throughout their operational lifecycle. Using this information, each 10-minute observation can be classified according to the most severe active alarm category during its interval. Therefore, if the state of a measurement is classified as “Power Limitation” or “Stop”, this point should be filtered and not be used in the power curve modeling.

However, it is important to note that event logs are not always available or completely reliable in the process of modeling a WTPC. For this reason, the need arises to apply customized manual filters for each new curve modeling process.

In this work, we propose the use of the Gaussian Process along with default filters as an approach to avoid the necessity of applying customized filters for each new wind turbine. This way, the process of power curve modeling becomes more efficient, scalable, and automated.

Unlike other works that use GP as a means to model the power curve, in our work, we intend to use the GP and its capability to model uncertainty as a tool to filter the data so that, posteriorly, we can use the method of bins, the approach recommended in the standard IEC-61400-12-2, to model the power curve.

In order to confirm the success of applying Gaussian filtering, we use as a comparison metric the Annual Energy Production (AEP) associated with each fitted power curve, which is one of the main indicators to detect underperformance. Therefore, to ratify the practicality of using gaussian filtering instead of manual filtering in our problem, it is enough to show that the AEPs obtained through the two methods have a negligible difference.

2. THEORETICAL BACKGROUND AND LITERATURE OVERVIEW AND

2.1 Wind turbine power curve modeling

A power curve modeling problem can be stated as the construction of a mathematical model that describes the electrical power produced by a WTG in terms of the wind speed received by its rotor (VIRGOLINO et al., 2020). The typical power curve for a pitch-regulated wind turbine can be generically represented by a sigmoidal-shaped function, as shown in Figure 1.




Figure 1 - Power Curve model of a pitch-regulated wind turbine generator (Source: (SOHONI, GUPTA, NEMA, 2016))

The power curve is divided into four regions. The first region occurs when the wind speed (v) is below the cut-in speed ($v_{cut\ in}$), where there is not enough wind to start the generator and produce energy. In the second region ($v_{cut\ in} < v < v_{rated}$), the turbine begins to generate energy but hasn't yet reached its maximum rated power output, characterized by its wind speed rated (v_{rated}). Region 3 ($v_{rated} < v < v_{cut\ off}$) represents the wind speed range where the turbine operates at its maximum available power. Finally, in region 4 ($v > v_{cut\ off}$), the turbine's control system stops power generation to minimize the aerodynamic forces on the blades.

Setting a baseline power curve that considers local and environmental conditions is crucial for online monitoring purposes and the decision-making process related to performance evaluation because it provides more accurate energy forecasts (SOHONI, GUPTA, NEMA, 2016). When using a data-driven approach, in addition to the classic challenges - such as cut-in and cut-out wind turbine behaviors, wind speed extrapolations, and air density normalization (SOHONI, GUPTA, NEMA, 2016) - we also face the difficulties associated with poor data quality, which do not accurately represent the behavior of the wind turbine under proper operational conditions. This data may include power limitations, turbulence effects, technical unavailabilities, malfunctions in the pitch and yaw systems, etc.

Filtering this poor data is challenging, as it may require feature engineering and additional wind turbine operating information that may not be consistently available during modeling. While manual data removal is an option, it can be costly for large datasets.

After filtering and processing data, various methodologies can be applied to the power curve modeling. One of them is the IEC standard, which is widely accepted by the wind industry. The IEC Standard describes the data acquisition process and model fitting procedures to obtain the power curve of a WTG, which include data consolidation into 10-minute averages and air density normalization, for example (VIRGOLINO et al., 2020).

Due to the nature of its fitting process, the bins method is highly sensitive to outliers, whose presence can cause discontinuities in the power curve. These outliers can significantly distort the results, leading to an inaccurate representation of the turbine's performance. Therefore, more than a manual approach, it is crucial to identify and remove these values through a more robust and scalable method to ensure accurate and reliable modeling.

2.2 Literature Overview of Data Cleaning methods

As depicted in Figure 2, three categories of abnormal data can be seen. Type 1 abnormal data refers to instances where power values are negative or nearly zero despite wind speeds being higher

than the cut-in speed. This typically happens due to unexpected repairs or turbine breakdowns. Type 2 abnormal data are characterized by interruptions or random patterns caused by sensor malfunctions in the control system, noise, or errors in wind direction. Type 3 abnormal data consists of repeated data points over a certain duration, usually resulting from wind curtailment commands, communication issues, or significant differences in wind direction.




Figure 2: Categories of abnormal data

Essentially, the goal of the WTPC abnormal data cleaning algorithm is to identify and remove these anomalies by modeling the distributions of normal data. Creating accurate wind power curve models is challenging because the recorded power curves often do not align with the theoretical ones for various reasons. An effective cleaning algorithm should not only correct data inaccuracies but also maintain the accuracy of the model as much as possible.

(LIANG *et al.*, 2020) identified two categories of algorithms for detecting and cleaning abnormal data in wind power curves (WTPCs). The first category leverages statistical characteristics to differentiate abnormal data from normal data. The second category involves constructing curve models using large datasets of normal data, and then identifying data points that fall outside the established boundaries as abnormal. The authors present various methods for each category and cite numerous references.

According to (SOHONI, GUPTA, NEMA, 2016), the most common method for cleaning abnormal data is through a visual inspection of wind speed and power output plots. However this method can lead to inaccurate results. In (YIN *et al.*, 2022), it is presented the image method, which converts scattered data into digital images, thereby transforming the data cleaning task into an image segmentation problem. However, a significant drawback of the image method is its high demand for computational resources.

The work (WU, ZHANG, HUANG, 2022) presents a statistical method for identifying outliers based on the IQR method (Interquartile Range). The method involves classifying each wind speed into bins, typically 0.5 m/s intervals, analyzing the power distribution within each bin, and identifying anomalous data using the quartile method. (ZHAO *et al.*, 2017), in turn, proposed an algorithm that combines the quartile method with Density-Based Spatial Clustering of Applications with Noise (DBSCAN) to optimize the power curve. Another numerical method can be applied using characteristics like distance, density, and variance, with well-known algorithms such as k-means and local outlier factor.

2.3 Method of Bins

The method known as the method of bins (MoB), recommended by the IEC standard for constructing mathematical models of the Wind Turbine Power Curve (WTPC), involves organizing wind speed (v_i) and power (P_i) measurements into discrete groups, known as bins. Each bin represents a specific range of wind speeds. Within each bin, the average wind speed (\bar{v}_k) and corresponding turbine

power output (\bar{P}_k) are calculated based on recorded data. These averages are then utilized to construct the turbine's Power Curve $P = f(v)$, illustrating how its energy production varies with different wind speeds.

The method of bins (MoB) divides observations into bins b_k with a predefined width. For each bin b_k , the mean wind speed \bar{v}_k and mean power \bar{P}_k are computed as follows:

$$\bar{v}_k = \frac{1}{N_k} \sum_{i \in b_k} v_i,$$

$$\bar{P}_k = \frac{1}{N_k} \sum_{i \in b_k} p_i,$$

where N_k denotes the number of observations in bin b_k .

Despite its simplicity and direct application in WTPC modeling, the method of bins has limitations due to the discrete segmentation of data, which may introduce minor inaccuracies. Nonetheless, owing to its widespread adoption as a technical standard and comparative benchmark in studies of WTPC modeling, the MoB underscores its significance in the field.

2.4 Annual Energy Production (AEP)

The annual energy production is an expectancy of how much energy, in kWh, the WTG will produce in the current year, assuming its power curve remains constant throughout the period and considering the local wind speed distribution. This measure takes into account the output power as a function of the wind speed, and its probability distribution. The relation between wind speed and output power is established through the obtained power curve, highlighting the need to find the one that best reflects the real behavior of the WTG.

2.5 Gaussian Process

A Gaussian Process (GP) is a bayesian, non-parametric, non-linear regression machine learning approach. Due to their ease of operation and algorithm construction flexibility, GPs have been used in several applications related to wind turbines (VIRGOLINO et al., 2020), (PANDIT, INFIELD, KOLIOS, 2020). For the task of wind turbine power curve modeling, this kind of model presents many useful properties: they automatically quantify uncertainty in predictions, require little a priori input and have a good capability of modeling even if the measured data is corrupted by high-level noise (ROGERS et al., 2020).

The GP is used for modeling functions of the form:

$$y = f(x) + \varepsilon \quad \varepsilon \sim N(0, \sigma^2) \quad (1)$$

From equation (1), we see that it models data as the output of a function $f(x)$ corrupted by an additive gaussian noise ε with zero mean and a fixed variance σ^2 .

The GP is completely determined by its mean function and its covariance function, as shown in the following equation:

$$f(x) \sim GP(m(x), k(x, x')) \quad (2)$$

where the mean function and the covariance function are defined as follows:

$$m(x) = E[f(x)] \quad (3)$$

$$k(x, x') = E[f(x) - m(x)][f(x') - m(x')] \quad (4)$$

2.6 Logistic Functions

The bayesian nature of the Gaussian process models also enables the modeler to inject expert knowledge into it in the form of the prior distributions. As discussed in (VIRGOLINO et al., 2020), the usual S-shape of the power curve can be represented by setting the Gaussian process mean function as a logistic function:

$$p(v) = \left[1 + \exp\left(-\left(\frac{v-v_0}{s}\right)\right)\right]^{-\gamma} \quad (5)$$

Where $p(v)$ is the normalized power as a function of v , the wind speed, and v_0, s, γ are parameters to fit the curve to the actual data. In this work, we follow the recommendation of (VIRGOLINO et al., 2020) and set $\gamma = 1$ to initialize the parameters. Furthermore, (8) is re-written as:

$$\log(p(v)^{-1} - 1) = (v_0/s) + (-s^{-1})v \quad (6)$$

This form can be used to estimate the coefficients (v_0/s) and $(-s^{-1})v$ with least squares linear regression, which provides a way to initialize the parameters with values closer to their optimal values when fitting the Gaussian process models.

3. MATERIALS AND METHODS

3.1 Data description and pre-processing

In this work, we use historical 10-minute average supervisory control and data acquisition (SCADA) datasets from 2 different kinds of wind turbines of two manufacturers.

3.2 Experiments

In the process of modeling WTPC, it is a common procedure to apply a variety of standard filters related to, for example, cut in wind speed, turbulence, and other aspects. However, sometimes it is also necessary to apply manual filters in scenarios in which even after the application of standard filters, dirty data remains unfiltered.

In the first experiment, the goal is to show that the gaussian filtering is a good alternative to the process of manual filtering. Thus, using the dataset of the wind turbine of the first manufacturer, we prove the necessity of using manual filtering, by showing that a priori, not using this manual filter, leads to an unsatisfactory result. However, as using manual filters is a process that ideally should be avoided, we show subsequently that using gaussian filtering leads to a satisfactory fitted power curve with a very similar AEP.

In the second experiment, our goal is to show that gaussian filtering is a good approach when the log of events of the turbine is missing. For this, we use a dataset that actually has a log of events, and therefore, allows the application of a filter of severity, that excludes all the points related to severity_id = 2, related to machine limitations. In order to prove our argument, we compare the power curve obtained with the severity filter with the one obtained using the gaussian filter.

3.3 Implementation

The development of the Gaussian process-based filter was performed using a Python script, utilizing various open-source libraries and the main one was GPFlow (MATTHEWS et al., 2017). It was used for modeling the likelihood and mean functions, for example.

It used the `gpflow.kernels.SeparateIndependent` kernel class to independently model the correlation between the two dimensions, with each dimension having its own kernel. The model was implemented using the `gpflow.models.SVGP` class. The training data were used as input to the model for parameter fitting. Finally, the boundaries of confidence of the GP model were used to outliers detection.

4. RESULTS AND DISCUSSION

4.1 First Case of Study: Manufacturer 1

In this first case, the raw data of power versus wind speed may be seen in Figure 3:




Figure 3: Raw data of power of Manufacturer 1

Applying the original filters, we obtain the curve shown in Figure 4, which has an associated AEP of 1632.0.




Figure 4: Fitted power curve obtained through application of original filters

As it may be seen in Figure 4, the data was not properly filtered and there were many remaining points for which the turbine was limited. Therefore, it was not necessary to apply the manual filter associated with the two following lists:

"ws": [9, 10, 10.6, 11.35, 13.2], "p": [744,1060,1385,1736,2258]

For each pair (ws, p) , the manual filter removes all the points that have wind speed greater than ws and power lesser than p . Applying this filter, it obtained the curve shown in Figure 5, which has an associated AEP of 1673.2.




Figure 5: Fitted power curve obtained through application of original filters and manual filter

From Figure 5, we can see that the manual filter was effective in filtering the points clearly associated with limitations. However, the use of manual filters should be avoided, as it is not a scalable procedure, because it demands a case-by-case analysis. Therefore, replacing the manual filter by the filter gaussian filter, we obtain the curve shown in Figure 6. The curve obtained from the gaussian filter has an AEP of 1668.3.




Figure 6: Comparison of fitted power curves obtained from manual filtering and gaussian filtering

The percentage difference between the AEP in the two scenarios is
 $(1673.2 - 1668.3)/1673.2 = 0.29\%$

This negligible difference shows that the gaussian filtering is equally capable of filtering the remaining points, having the advantage of not requiring manual analysis to determine the cutoff points.

4.2 Second case of study: Manufacturer 2

In this first case, the raw data of power versus wind speed may be seen in Figure 7.




Figure 7: Raw data of power of manufacturer B

In this case, we had the log events and, therefore the severity variable, as may be seen in Figure 8.




Figure 8: Raw data of power of manufacturer B classified by severity id

The points with severity 2 are the points associated with limitation moments. Applying the original filters, not including the severity_id filter, we obtain the curve shown in Figure 9, which has an associated AEP of 1423.4.




Figure 9: Fitted power curve obtained through application of original filters

As it may be seen in Figure 9, the data was not properly filtered and there were many remaining points for which the turbine was limited. Applying the severity_id filter, however, we obtain the curve shown in Figure 10, which has an associated AEP of 1431.6.

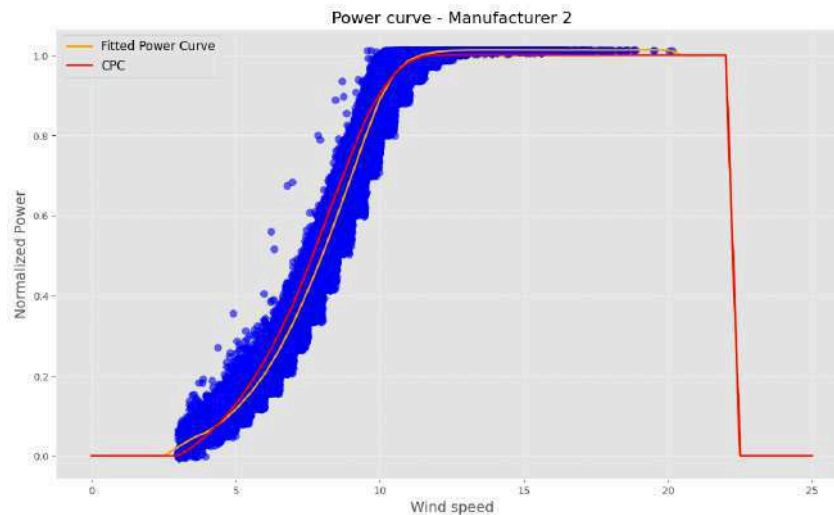


Figure 10: Fitted power curve obtained through application of original filters and severity filter

From Figure 10, we can see that the severity filter actually was effective in removing the points associated with limitations. However, as previously mentioned, the application of this filter is not always possible, as the log of limitation events is not always available or reliable. Therefore, by replacing the severity filter with a gaussian filter, we obtain the curve shown in Figure 11. The curve obtained from the gaussian filter has an AEP of 1435.2.




Figure 11: Comparison of fitted power curves obtained from severity filtering and gaussian filtering

The percentage difference between the AEP in the two scenarios is

$$(1431.6 - 1435.2)/1431.6 = -0.25\%$$

This negligible difference shows that the gaussian filtering is equally capable of filtering the remaining points, even if it was not possible to filter points with severity 2 in the absence of logs of limitation events.

5. CONCLUSION AND FUTURE WORK

In this work, we addressed the problem of data cleaning of wind turbine power curves, which is a very important step in the process of modeling such curves.

We proposed the application of a bayesian non-parametric machine learning algorithm, namely Gaussian Process, as a filtering approach useful to replace manual filters and useful in scenarios where the log of events of limitation of a wind turbine is missing.

By means of showing that the obtained AEP values using gaussian filtering were very similar to the ones obtained using the other approaches, we could show that it is a promising approach, that allows the increase of efficiency in the process of data cleaning, and consequently, the efficiency of the modeling as a whole.

As future work, more tests can be conducted using other kinds of wind turbines. In addition, further tests can be conducted, removing other standard filters to verify the ability of Gaussian modeling to remove outliers, even if practically no other filters are used.

BIBLIOGRAPHY

Lai, G., Liao, L., Zhang, L., & Li, T. (2023, February). Wind Speed Power Data Cleaning Method for Wind Turbines Based on Fan Characteristics and Isolated Forests. In *Journal of Physics: Conference Series* (Vol. 2427, No. 1, p. 012001). IOP Publishing.

Liang, G., Su, Y., Chen, F., Long, H., Song, Z., & Gan, Y. (2020). Wind power curve data cleaning by image thresholding based on class uncertainty and shape dissimilarity. *IEEE Transactions on Sustainable Energy*, 12(2), 1383-1393.

Lydia, M., Kumar, S. S., Selvakumar, A. I., & Kumar, G. E. P. (2014). A comprehensive review on wind turbine power curve modeling techniques. *Renewable and Sustainable Energy Reviews*, 30, 452-460.

Matthews, A. G. D. G., Van Der Wilk, M., Nickson, T., Fujii, K., Boukouvalas, A., Le, P., ... & Hensman, J. (2017). GPflow: A Gaussian process library using TensorFlow. *Journal of Machine Learning Research*, 18(40), 1-6.

Pandit, R. K., Infield, D., & Kolios, A. (2020). Gaussian process power curve models incorporating wind turbine operational variables. *Energy Reports*, 6, 1658-1669.

Rogers, T. J., Gardner, P., Dervilis, N., Worden, K., Maguire, A. E., Papatheou, E., & Cross, E. J. (2020). Probabilistic modelling of wind turbine power curves with application of heteroscedastic Gaussian process regression. *Renewable Energy*, 148, 1124-1136.

Sohoni, V., Gupta, S. C., & Nema, R. K. (2016). A critical review on wind turbine power curve modelling techniques and their applications in wind based energy systems. *Journal of Energy*, 2016.

Trivellato, F., Battisti, L., & Miori, G. (2012). The ideal power curve of small wind turbines from field data. *Journal of Wind Engineering and Industrial Aerodynamics*, 107, 263-273.

Virgolino, G. C., Mattos, C. L., Magalhães, J. A. F., & Barreto, G. A. (2020). Gaussian processes with logistic mean function for modeling wind turbine power curves. *Renewable Energy*, 162, 458-465.

Wu, Y., Zhang, J., & Huang, S. (2022). Anomaly data identification for wind farms based on composite machine learning. *Journal of Renewable and Sustainable Energy*, 14(6).

Yin, X., Liu, Y., Yang, L., & Gao, W. (2022). Abnormal Data Cleaning Method for Wind Turbines Based on Constrained Curve Fitting. *Energies*, 15(17), 6373.

Zhao, Y., Ye, L., Wang, W., Sun, H., Ju, Y., & Tang, Y. (2017). Data-driven correction approach to refine power curve of wind farm under wind curtailment. *IEEE Transactions on Sustainable Energy*, 9(1), 95-105.

Analytical Model for a Wind Turbine with a Doubly-Fed Induction Generator Emulating Electrical Faults in the Rotor and Stator

R. V. Rocha¹, R. N. Tominaga¹, S. L. Avila^{1,2}, R. M. Monaro¹, M. B. C. Salles¹, B. S. Carmo¹

¹ Advanced Electrical Networks Laboratory, University of São Paulo (USP), Brazil

² Laboratory of Applied Scientific Computing, Federal Institute of Santa Catarina (IFSC), Brazil

Corresponding author: sergio.avila@ifsc.edu.br

Acknowledgement: Total Energies and USP support this research under grant ANP: 23683-6.

ABSTRACT

Analytical models accelerate the understanding of the machines and systems performance. Wind turbines are complex and relatively recent large-scale electromechanical energy conversion systems, which still require a lot of development, mainly driven by energy transition needed. We contributed to proposing an electrical modeling of the wind turbine Doubly Fed Induction Generator (DFIG). In turbines with DFIG, speed and flow regulation are achieved through the flow of active and reactive power in the rotor winding. Thus, our model comprises the machine and its control. We can also emulate short-circuits between turns of each phase on the stator and on the rotor. Therefore, we contribute to an analytical model for a wind turbine with DFIG and its electrical failures on stator and rotor. It will allow the application of electrical current signature analysis, which combined with computational intelligence techniques, certainly helped to increase the accuracy in identifying faults. This research paper seeks wind potential improvement through the study and mitigation of generation deviations and failures aims to improve the use of the wind resource by achieving the following aim: updating the energy conversion models.

Keywords: analytical model, wind turbine, double fed induction generator, electrical faults.

1. INTRODUCTION

Researchers at Total Energies and USP have been working on the macro concept of digital wind farm, which is an integrated set of computational tools, using various techniques such as high-performance computing and artificial intelligence, for the simulation of phenomena and scenarios related to the business of wind power generation, to make diagnoses and forecasts that add value. Examples of these tools are wind resource forecasting models, wind farm layout optimization methods, integrated optimal wind farm control strategies, tools for studies and better failure predictability, lifetime prediction algorithms, among others. This project fits in this main line, being an opportunity to take an important step towards this major goal.

The research team sees that the components of generation, which in its complete form involves wind resources (wind), blades, hub, gearbox, generator and its controls, transformer, and circuit breaker are important assets to the power utilities and the electric power system, whose availability of uninterrupted operation is essential to the company's revenue for the reliability of the interconnected system. In this context, the proposed diagnostic system composes a predictive tool for detecting incipient failures in time to prevent their evolution to serious failures and greater understanding of deviations in the generation. It is important to optimize the management of operation and maintenance (O&M) resources, and the project also aims to develop functionalities that allow prioritizing and grouping machines that need attention.

So, we intend to make further progress in this research and development direction, mastering the energy potential through the analysis of the main factors causing the deviation of generation with the help of artificial intelligence tools, and perform a study of failures of the wind turbines. Our goal is to reduce the

downtime of the machine with scheduled maintenance, increasing the reliability of the system and the company's revenues, enabling the reduction of maintenance costs and thus developing predictive maintenance routines considering the specifics of the farm (site and wind turbines). A work like this is consistent with the trend of fleet primarization that has been observed in the generation sector, since it provides better control of the assets themselves, and constant and intelligent monitoring of their condition. The development of competitive national technology leads to social progress for the nation and technological self-reliance.

In this paper, we contribute to an analytical model for a wind turbine with DFIG and its electrical failures on stator and rotor. It will allow the application of electrical currents signature analysis (MCSA). MCSA combined with computational intelligence techniques, certainly helped to increase the accuracy in identifying faults.

2. BACKGROUND KNOWLEDGE

In the literature, the field of O&M has been one frontier of study in the wind energy sector. Badihi et al. (2022) provided a comprehensive review of techniques and technologies for diagnosing and prognosticating wind turbine components, considering aspects of fault detection and diagnosis and lifetime prognosis. They discussed the advantages, disadvantages, and functionalities of each technique in signal-based condition monitoring models (models based on data collected in the field, such as those based on SCADA) and model-based condition models (which employ mathematical models that do not require high resolution like signal-based models). They also recommended a hybrid approach between signal-based and model-based techniques to complement the shortcomings of each technique, such as the limitation of monitoring a single turbine and its components with signal-based methods and limitations in the accuracy and robustness of mathematical models applied in model-based techniques. A hybrid model is helpful in the short term for the industry and provides practical experience for researchers and the industry in the long term.

Pulikollu et al. (2023) discuss generator reliability and technological advancements over the years to mitigate failures in this component of wind turbines. Using the WinNER tool (Wind Network for Enhanced Reliability) database, based on several generators that together have some 44.2 GW of capacity, the authors identified the major causes of generator defects and analyzed their financial and operational life impact. By tracking health and failure data, it was possible to improve operation and maintenance models and reduce significant costs. Industry collaboration and early fault detection have been driving efficiency and reliability in wind energy. The authors emphasize the importance of predictive techniques in the O&M sector and suggest expanding the WinNER database tool. They also recommended that suppliers should provide more detailed specifications related to generator design and selection to enable owners and operators to conduct more accurate predictive failure studies for their investments.

Studies on the prognosis of wind turbine components and sub-components were reviewed by Rezamand et al. (2020). The article detailed and categorized the different failures caused by each component of the wind turbine and reviewed the literature on different prognosis methods. These methods were categorized into physics-based, AI-based, stochastic-based, and hybrid models, which are a combination of different prognosis methods. Because of the high precision of separate components, the authors defined the hybrid model as the most valid tool for this type of study. Physics-based methods yielded good results with limited data available but showed to be limited in terms of individual component prognostics. Stochastic and AI-based prognostics showed good accuracy in predicting the remaining lifespan of components, but AI-based models required large amounts of data to make an acceptable prediction.

The monitoring method most used by the industry still is mechanical vibration analysis (Sarma et al. 2023)(Neupane et al., 2024)(Salameh et al., 2018). Another approach is to use the machine current signature analysis (MCSA) (Niu et al. 2023). MCSA typically uses frequency domain analysis of the current signal through steady-state machine operation. An advantage of MCSA over other techniques is the simplicity of its instrumentation. There is no requirement for complex mechanical adjustments like the ones

needed for vibration sensors (accelerometers and proximeters). MCSA highlights are non-invasive technology, early detection of faults before they become catastrophic, reduce lost production and increase plant readiness, detect faults in new assets or recently repaired failed assets because of, for example, manufacturing defects, improper installation, etc. MCSA drawbacks could be that the driver system produces many harmonics, noise from anywhere, quality of measuring instrumentation, and sample size and cost to store the dataset. MCSA can be described as a technique that helps determine the machine's operating condition (Niu et al., 2023; Sarma et al., 2023; Yakhni et al., 2023; Imamura et al., 2022). In MCSA, the current signal is processed to get the frequency spectrum, usually referred to as the current signature. The MCSA uses this current spectrum of the machine for fault frequency identification. When faults are present, the frequency spectrum of the current becomes different from that of a healthy machine. Figure 1 shows our proposed architecture for diagnosing faults in wind turbines from MCSA with edge-computing concepts.

The main aim is to develop a DFIG model to use analytical data on electrical currents from healthy or faulty machines to train computational intelligence tools through MCSA.




Figure 1. Framework for diagnosing faults in wind turbines using MCSA with edge computing concepts.

3. Method – Analytical model for doubly-fed electric generator (DFIG)

The DFIG modeling process under turn-to-turn faults started with the doubly fed induction machine (DFIM) healthy model. The equations of interest for modeling the machine under internal electrical faults are the differential equations that relate electrical voltages, currents, and flows. Software such as Simulink has models of electrical machines for simulation. Typically, these models are implemented using the machine's electrical equations in dq coordinates. The DFIM stator and rotor equations in dq space are given by (Wu et al., 2011; Yazdani & Iravani, 2010) where R_s is the stator resistance, R_r the rotor resistance, L_s the stator inductance, L_r is the rotor inductance, L_m the magnetizing inductance, ω_e is the stator electrical speed, ω_{slp} the slip speed ($\omega_{slp} = \omega_e - \omega_r$) and ψ the connection flux. The subscripts ds and qs denote dq stator variables, while dr and qr denote dq rotor variables.

$$\begin{cases} v_{ds} = R_s i_{ds} + \frac{d\psi_{ds}}{dt} - \omega_e \psi_{qs} \\ v_{qs} = R_s i_{qs} + \frac{d\psi_{qs}}{dt} + \omega_e \psi_{ds} \\ v_{dr} = R_r i_{dr} + \frac{d\psi_{dr}}{dt} - \omega_{slp} \psi_{qr} = 0 \\ v_{qr} = R_r i_{qr} + \frac{d\psi_{qr}}{dt} + \omega_{slp} \psi_{dr} = 0 \end{cases} \quad (1)$$

$$\begin{cases} \psi_{ds} = L_s i_{ds} + L_m i_{dr} \\ \psi_{qs} = L_s i_{qs} + L_m i_{qr} \\ \psi_{dr} = L_r i_{dr} + L_m i_{ds} \\ \psi_{qr} = L_r i_{qr} + L_m i_{qs} \end{cases}$$

The representation and simulation in dq coordinate of the healthy machine has the advantage of simplifying the dynamic analysis and calculations in numerical simulations. For this reason, this approach is the most used for control design and dynamic analysis of healthy machines. To represent electrical faults internal to the machine, it is more convenient to adopt the equations in coordinates abc (Yazidi et al., 2005),

$$\mathbf{v} = \mathbf{Ri} + \frac{d\boldsymbol{\varphi}}{dt}, \quad (2)$$

where v , i and $\boldsymbol{\varphi}$ are defined, respectively, by

$$\begin{aligned} \mathbf{v} &= [v_{as} \ v_{bs} \ v_{cs} \ v_{ar} \ v_{br} \ v_{cr}]^T, \\ \mathbf{i} &= [i_{as} \ i_{bs} \ i_{cs} \ i_{ar} \ i_{br} \ i_{cr}]^T, \\ \boldsymbol{\varphi} &= \mathbf{Li}. \end{aligned} \quad (3)$$

The induction matrix is

$$\mathbf{L} = \begin{bmatrix} L_{as} & L_{as,bs} & L_{as,cs} & L_{as,ar} & L_{as,br} & L_{as,cr} \\ L_{as,bs} & L_{bs} & L_{bs,cs} & L_{bs,ar} & L_{bs,br} & L_{bs,cr} \\ L_{as,cs} & L_{bs,cs} & L_{cs} & L_{cs,ar} & L_{cs,br} & L_{cs,cr} \\ L_{as,ar} & L_{bs,ar} & L_{cs,ar} & L_{ar} & L_{ar,br} & L_{ar,cr} \\ L_{as,br} & L_{bs,br} & L_{cs,br} & L_{ar,br} & L_{br} & L_{br,cr} \\ L_{as,cr} & L_{bs,cr} & L_{cs,cr} & L_{ar,cr} & L_{br,cr} & L_{cr} \end{bmatrix} \quad (4)$$

The values of the stator and rotor self and mutual inductance are given by (Yazidi et al., 2005):

$$\begin{aligned}
 L_{as} &= L_{bs} = L_{cs} = L_s, \\
 L_{ar} &= L_{br} = L_{cr} = L_r, \\
 L_{as,bs} &= L_{as,cs} = L_{bs,cs} = L_{ar,br} = L_{ar,cr} = L_{br,cr} = -0.5L_m, \\
 L_{as,ar} &= L_{bs,br} = L_{cs,cr} = L_m \cos(\theta_r), \\
 L_{as,br} &= L_{bs,cr} = L_{cs,ar} = L_m \cos\left(\theta_r + \frac{2\pi}{3}\right), \\
 L_{as,cr} &= L_{bs,ar} = L_{cs,br} = L_m \cos\left(\theta_r - \frac{2\pi}{3}\right),
 \end{aligned} \tag{5}$$

where L_s is the stator self-inductance, L_r for rotor and L_m for mutual. The mutual inductances between stator and rotor have a value dependent on the position of the rotor θ_r . The resistance matrix is:

$$\mathbf{R} = \begin{bmatrix} R_{as} & 0 & 0 & 0 & 0 & 0 \\ 0 & R_{bs} & 0 & 0 & 0 & 0 \\ 0 & 0 & R_{cs} & 0 & 0 & 0 \\ 0 & 0 & 0 & R_{ar} & 0 & 0 \\ 0 & 0 & 0 & 0 & R_{br} & 0 \\ 0 & 0 & 0 & 0 & 0 & R_{cr} \end{bmatrix}, \tag{6}$$

with

$$\begin{aligned}
 R_{as} &= R_{bs} = R_{cs} = R_s, \\
 R_{ar} &= R_{br} = R_{cr} = R_r,
 \end{aligned}$$

where R_s is the stator resistance and R_r the rotor resistance. These equations can be solved as a system in state space,

$$\begin{cases} \dot{\varphi} = \mathbf{R}\mathbf{L}^{-1}\varphi + \mathbf{v} \\ \mathbf{i} = \mathbf{L}^{-1}\varphi \end{cases} \tag{7}$$

in which the voltages v applied to the DFIM windings are considered the system inputs, the states are the fluxes φ , and the outputs are the i currents.

3.1. Model with short circuit between turns of one phase of the stator winding

The representation of an inter-turn fault in phase a is done by modifying the previous equations. It is considered that, with the occurrence of a short circuit between turns of phase a , this winding divides into two parts, one that remains operating, carried by the current i_{as} and the other by the fault current i_{fault} .

$$\mathbf{v} = \mathbf{R}\mathbf{i} + \frac{d\varphi}{dt} \tag{8}$$

The voltage and current vectors are now organized as

$$\mathbf{v} = [v_{as} \ v_{bs} \ v_{cs} \ 0 \ v_{ar} \ v_{br} \ v_{cr}]^T \quad (9)$$

$$\mathbf{i} = [i_{as} \ i_{bs} \ i_{cs} \ (i_{as} - i_{falta}) \ i_{ar} \ i_{br} \ i_{cr}]^T$$

The inductances related to the faulty portion are added to the inductance matrix (10). The inductances related to the portion that remains operational of the phase a winding is changed because of the fault (Bouزيد et al. 2017).

$$\mathbf{L} = \begin{bmatrix} L_{ash} & L_{ash,bs} & L_{ash,cs} & L_{ash,asf} & L_{ash,ar} & L_{ash,br} & L_{ash,cr} \\ L_{ash,bs} & L_{bs} & L_{bs,cs} & L_{asf,bs} & L_{bs,ar} & L_{bs,br} & L_{bs,cr} \\ L_{ash,cs} & L_{bs,cs} & L_{cs} & L_{asf,cs} & L_{cs,ar} & L_{cs,br} & L_{cs,cr} \\ L_{ash,asf} & L_{asf,bs} & L_{asf,cs} & L_{asf} & L_{asf,ar} & L_{asf,br} & L_{asf,cr} \\ L_{ash,ar} & L_{bs,ar} & L_{cs,ar} & L_{asf,ar} & L_{ar} & L_{ar,br} & L_{ar,cr} \\ L_{ash,br} & L_{bs,br} & L_{cs,br} & L_{asf,br} & L_{ar,br} & L_{br} & L_{br,cr} \\ L_{ash,cr} & L_{bs,cr} & L_{cs,cr} & L_{asf,cr} & L_{ar,cr} & L_{br,cr} & L_{cr} \end{bmatrix} \quad (10)$$

The values of the inductances of the machine under fault are given in (11), where μ is the portion of turns involved in the fault ($\mu = N_{fault}/N_{total}$).

$$\begin{aligned} L_{ash} &= (1 - \mu^2)L_s & L_{asf,bs} &= L_{asf,cs} = -0.5\mu L_m \\ L_{ash,bs} &= L_{ash,cs} = -0.5(1 - \mu)L_m & L_{asf,ar} &= \mu L_{as,ar} \\ L_{ash,ar} &= (1 - \mu)L_{as,ar} & L_{asf,br} &= \mu L_{as,br} \\ L_{ash,br} &= (1 - \mu)L_{as,br} & L_{asf,cr} &= \mu L_{as,cr} \\ L_{ash,cr} &= (1 - \mu)L_{as,cr} & L_{ash,asf} &= (\mu - \mu^2)L_m \\ L_{asf} &= \mu^2 L_s & & \end{aligned} \quad (11)$$

The resistance matrix is also changed (12).

$$\mathbf{R} = \begin{bmatrix} R_{ash} & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & R_{bs} & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & R_{cs} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -(R_{asf} + R_{falta}) & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & R_{ar} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & R_{br} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & R_{cr} \end{bmatrix} \quad (12)$$

Where: $R_{ash} = (1 - \mu)R_s$ and $R_{asf} = \mu R_s$.

3.2. DFIG control

For back-to-back converters, control can be divided into Grid-side Converter Control (GCC) and Machine-side Converter Control (MCC), which are performed using d_{q0} transformation and proportional-integral controllers (Wu et al. 2011). GCC voltage-oriented control (VOC) is used, illustrated in Figure 2(a), which aims to regulate the DC voltage (V_{DC}) through the flow of active power on its AC side, defined by the current I_d . The nominal VDC is chosen to accord with the machine's network and line voltages.

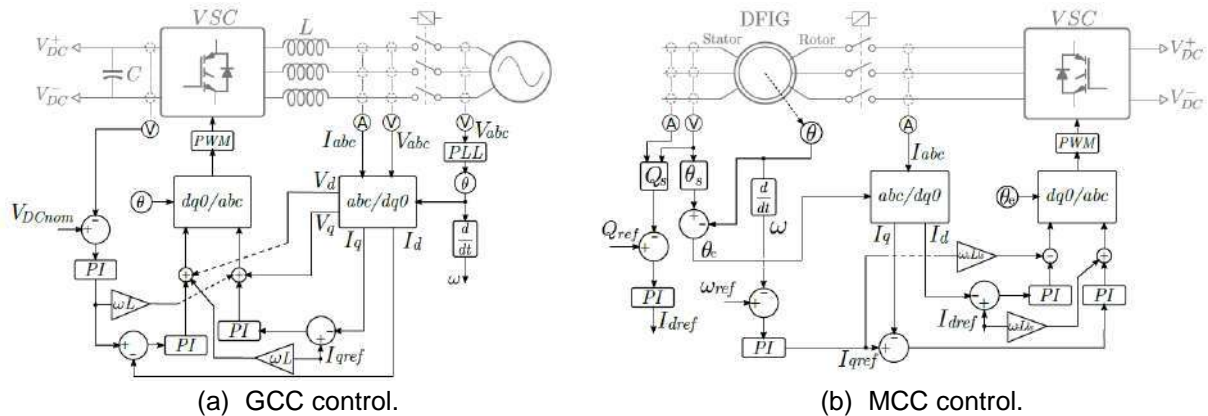


Figure 2. DFIG control: (a) grid converter control, (b) generator converter control.

The main aim of wind turbine control is to maximize the active power generated for a wind speed. This is achieved using a Maximum Power Point Tracking (MPPT) algorithm, which provides the reference speed for the generator. Next, the MCC regulates the speed through torque control, using the I_{dq} currents. In turbines with DFIG, speed and flow regulation are achieved through the flow of active and reactive power in the rotor winding. Figure 2(b) shows the VOC diagram of the DFIG stator (Wu et al. 2011).

5. DISCUSSION AND RESULTS

The machine model and control were implemented in the Matlab/Simulink program using the equations presented in the previous sections. This program was adopted because it can integrate the mechanical/aerodynamic part, made with OPENFAST, and the electrical part, implemented by state space equations in Simulink. Simulink has a healthy DFIM machine model available, which is typically used in simulations and control studies of wind turbines in our research group. Therefore, there is a model for comparison and validation of the approach used to model the machine in abc coordinates, both in normal and faulty conditions. Generator speed control was not implemented in Simulink because all the mechanical parts of the turbine and generator are done in OPENFAST. The electrical model and current control of the DFIM, implemented in Simulink, provide the torque and speed of the generator.

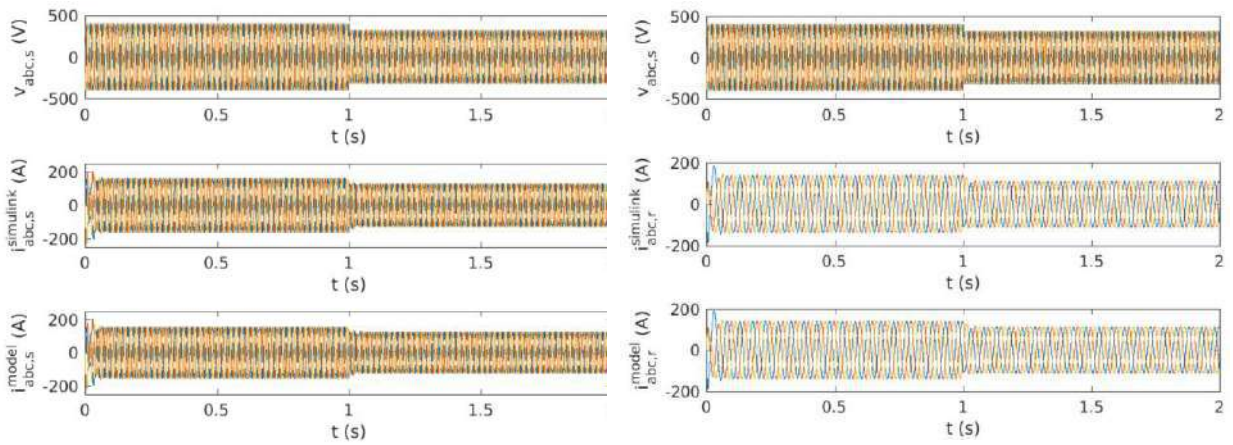
5.1. Validation of the DFIM model

First, the machine model of control was evaluated, simulating it as an induction motor, with stator voltage defined by a three-phase AC voltage source and short-circuited rotor windings. Then, the response was compared with that of the model available in the Simulink library. Both machines were simulated with the same parameters, described in the Tab 1.

Figure 3 illustrates the stator and rotor currents used in the two models. The response of the models was similar in amplitude and transients. Figure 4 illustrates the electromagnetic torques of each model. Note that the lines of both are overlapping, with a small difference during the transients. Figure 5 shows that the initial transient of the stator and rotor currents are the same for both models. Figure 6 illustrates the electromagnetic torques in two distinct time intervals: initial transient and transient because of the change in voltage applied to the stator.

Table 1. Electrical and mechanical parameters of the DFIG used in the simulation validation.

Parameter	Value	Parameter	Value
P_n	18.45 kW	V_n	400 V
V_s/V_r	1	f_n	50 Hz
R_s	0.5968 Ω	R_r	0.6258 Ω
L_{ls}	0.3495 mH	L_{lr}	5.473 mH
L_m	35.4 mH	J	0.05 kg.m ²
p	2	F	0.005879 N.m.s



(a) Stator considering the same stator voltage.

(b) Rotor currents considering the same stator voltage.

Figure 3. Stator and Rotor currents using the two models.




Figure 4. Electromagnetic torques.

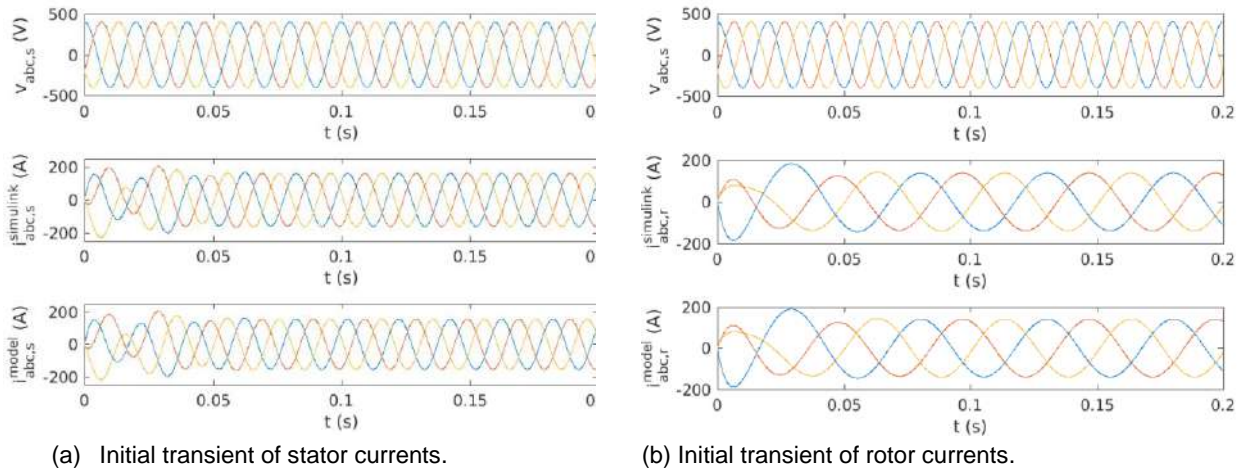


Figure 5. Initial transients of the stator and rotor currents are the same for both models.

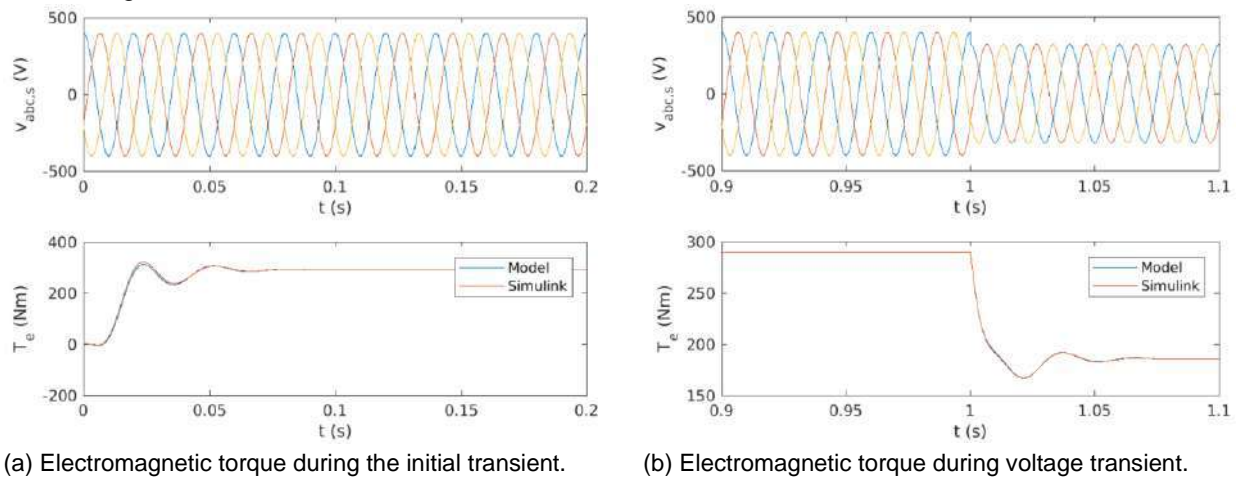


Figure 6. The electromagnetic torques occur in two distinct time intervals.

5.2. Validation of DFIG control

After these initial tests, control of the rotor currents was implemented, performed by the rotor supply voltages, given by the converter connected to the rotor, while the stator voltages continue to be given by the three-phase source. Control of rotor currents is used for speed and torque control of the DFIM. Figure 7 illustrates the control response for step tests at current references i_{dq} and shows the resulting electromagnetic torque because of the rotor current steps. Figure 8 presents details of one of the step tests performed. The control can reach the reference current quickly and with a small overshoot.

5.3. Evaluation of the DFIG model with a short circuit between turns of phase a of the stator.

After performing the control tests, the machine model with a fault between turns of the stator winding of phase a was evaluated. Therefore, the machine equations with turn-to-turn short circuit were implemented. The rotor current control algorithm was maintained. Figure 9 illustrates the stator and rotor currents of the DFIG with a short circuit involving 1% of the turns of phase a . The fault current has a high amplitude, with the occurrence of the fault there is a great imbalance in the stator currents and that, because of the existing coupling between stator and rotor fluxes, there is also an imbalance in the rotor currents at a lower intensity. The effects of unbalance in the stator currents are noted in the i_{dq} control currents as an oscillation with twice the fundamental frequency of the stator currents, as shown in Figure 9. Oscillation also occurs in the rotor currents dq , as illustrated in Figure 10, with twice the frequency of the rotating field and an amplitude

smaller than that of the oscillation of the stator currents. Oscillations in the rotor and stator currents dq result in oscillations in the electromagnetic torque, as illustrated in Figure 11.

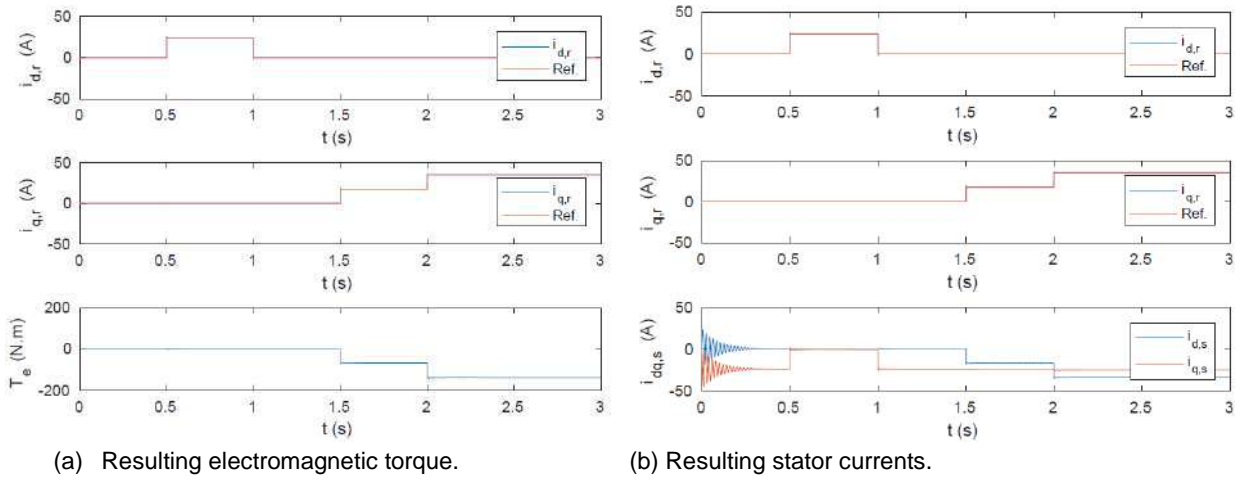


Figure 7. Rotor current control response to steps in the i_{dq} references.

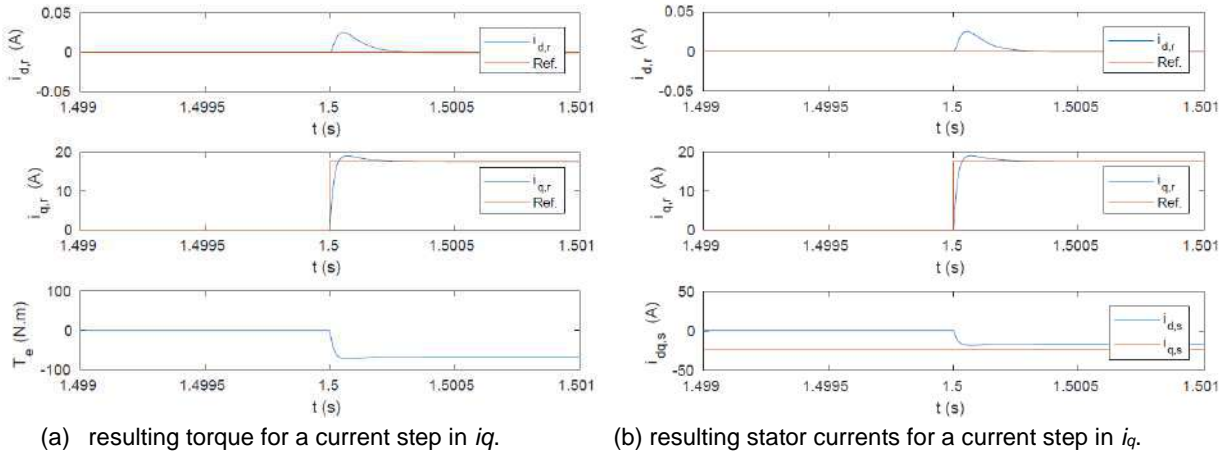


Figure 8. Detail of the control response.




Figure 9. DFIM stator, fault and rotor currents during short circuit involving 1% of phase a.

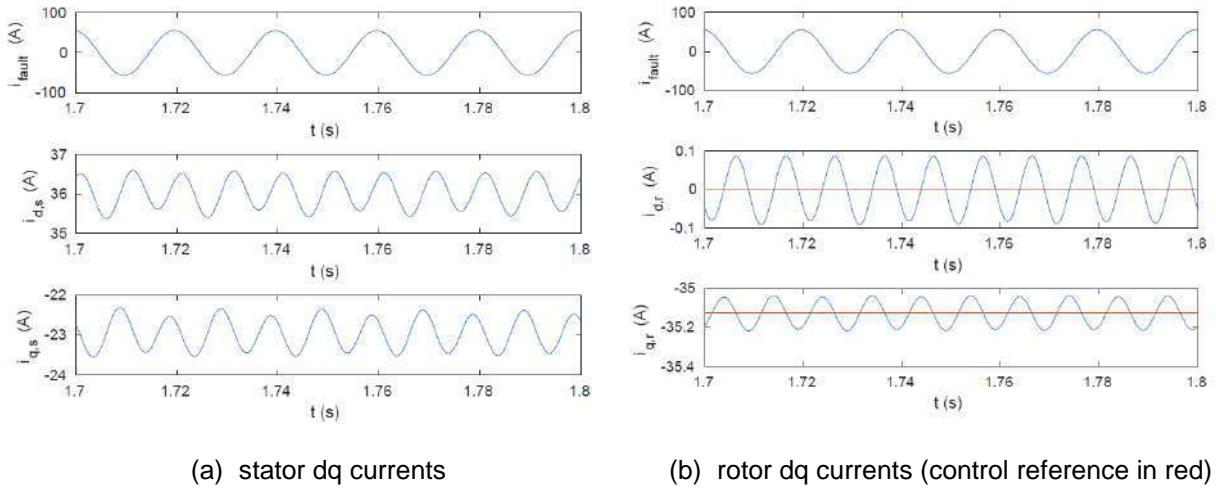




Figure 10. Fault current and DFIM stator and rotor currents dq during short circuit involving 1% of phase a.

5.4. Experimental validation of the DFIM model with short-circuits between stator turns

The model was also validated by experimental data, got using a real converter and electric machine in a laboratory environment, specifically designed to evaluate the effects of faults in the winding of modern wind generators technologies, using equipment with scaled power ratings, with a 2 kW generator. The experimental platform comprises an inverter-controlled 2 kW induction motor, employed to emulate the torque developed by a wind turbine; a 2,2 kW wound-rotor induction machine, with stator winding taps that make it possible to define faults during its operation; this machine is used in DFIG configuration, with stator directly connected to the grid and rotor voltages provided by a back-to-back converter, formed by two voltage-source inverters. Figure 11 illustrates the experimental platform, which is thoroughly described in Rocha et al., 2023.



(a) experimental platform



(b) winding taps of the DFIG

Figure 11. Experimental platform used to validate the model of the DFIG.

The parameters of the DFIG of the experimental platform are presented in Tab. 2. The same parameters were used in the model simulations, to compare the simulation and the experimental results. The same fault case was considered for both experimental and simulation generators: short-circuit ($R_{fault} = 0 \Omega$) involving 13% of the turns in the phase b winding; same operational conditions were also considered: rotor speed of 150 rad/s and nominal torque (3.3 N.m).

Table 2. Electrical and mechanical parameters of the DFIG used in the experimental platform.

Parameter	Value	Parameter	Value
P_n	2.2 kW	V_n	230 V
V_s/V_r	4.73	f_n	60 Hz
R_s	1.805 Ω	R_r	0.071 Ω
L_{ls}	15.94 mH	L_{lr}	0.637 mH
L_m	48.69 mH	J	0.022 kg.m ²
p	2	F	0.001 N.m.s

Figures 12 - 14 illustrate the results got with the experimental setup, together with the results got by simulation using the model with the same parameters as the real equipment. The model correctly approximates the behavior got with the experimental platform.

During the fault, the current of phase b, which has the short-circuited turns, is greater than the currents of the phases a and c. This behavior was confirmed by both the experimental and simulation results. However, there are differences between the waveforms gained in laboratory and by simulation, as illustrated in Fig. 12. That is mainly because of the simplifications made during the model definition, such as inductances approximated by sinusoids and dis-considering core saturation. Therefore, the model can be improved, provided that the application requires it.

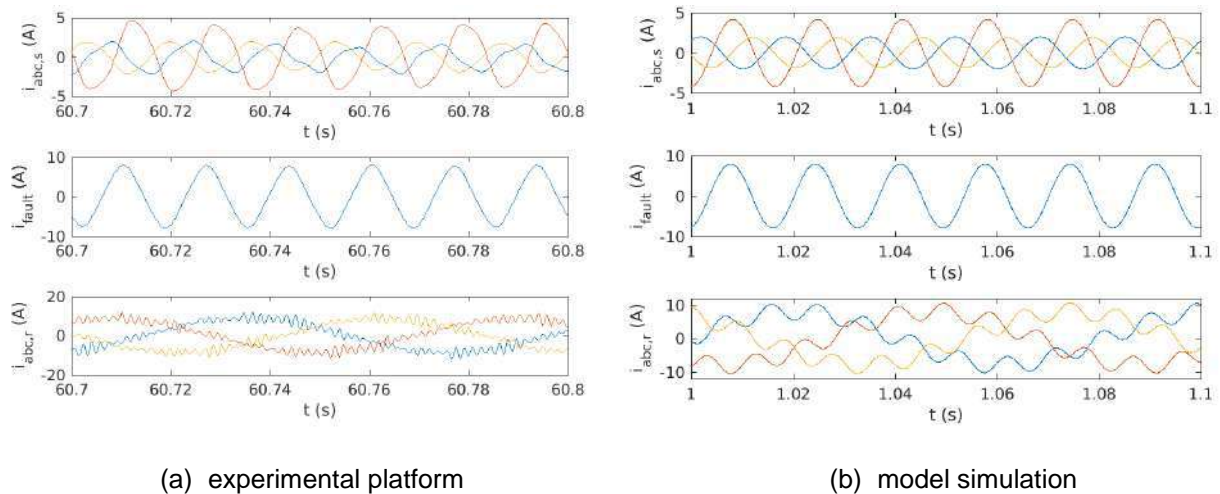


Figure 12. Experimental and simulation results got for the stator, fault and rotor currents, during a short-circuit involving 13% of the turns in the phase b winding.

The unbalance in the stator currents during the fault causes distortion of the rotor currents. As the abc currents are affected, so are the dq currents of both the stator and rotor. Figures 13 and 14 show the oscillation verified in these currents. Despite some differences in the waveforms, which are caused by motives pointed before, the same behavior was observed in experimental and model simulation results.

Considering the results presented here, and additional tests performed in the laboratory, the model can correctly approximate the behavior of a real DFIG with faults in the stator or rotor wiring.

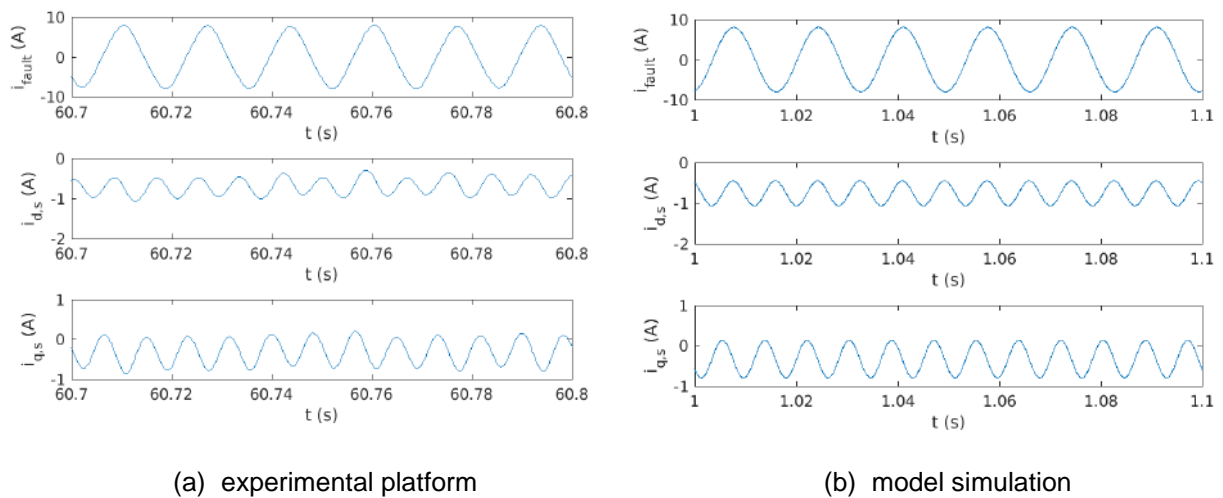


Figure 13. Experimental and simulation results obtained for the stator dq currents, during a short-circuit involving 13% of the turns in the phase b winding.

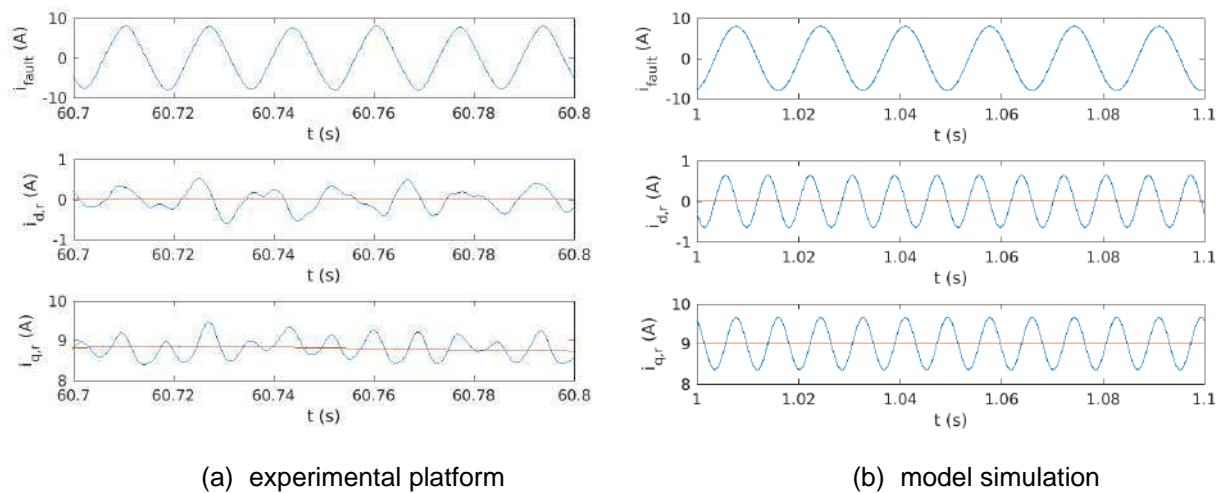


Figure 14. Experimental and simulation results obtained for the rotor dq currents, during a short-circuit involving 13% of the turns in the phase b winding.

6. CONCLUDING REMARKS

This research paper seeks wind potential improvement through the study and mitigation of generation deviations and failures aims to improve the use of the wind resource by achieving the following aim: updating the energy conversion models. Here, we have been presented an analytical model for a wind turbine with a doubly fed induction generator and its rotor and stator electrical failures. It has the potential to generate significant impact for the business because, by mapping wind turbine failures and their causes, they will enable the implementation of more efficient operation and maintenance procedures, which will lead to an increase in the capacity factor, energy efficiency and lifespan of wind farm assets.

We proposed a DFIG modeling process under turn-to-turn faults started from the doubly fed induction machine healthy model. The equations of interest for modeling the machine under internal electrical faults are the differential equations that relate electrical voltages, currents and flows. After performing the control tests, the machine model with a fault between turns of the stator winding of phase *a* was evaluated. Therefore, the machine equations with turn-to-turn short circuit were implemented. The rotor current control algorithm was maintained. The fault current has a high amplitude, with the occurrence of the fault there is a great imbalance in the stator currents and that, because of the existing coupling between stator and rotor fluxes, there is also an imbalance in the rotor currents at a lower intensity. The results have coherence with

real life wind turbines, as the model was validated by an experimental platform that employs the same technology, such as the same converter topology and type of machine, of modern turbines.

The results presented in this paper show that the model can correctly approximate the behavior of a real generator under electrical fault conditions. Therefore, through the simulation of a relatively simple system of equations, it is possible to generate data to train and test algorithms for fault detection and diagnosis. Future works are addressed to develop AI tools for the identification of electrical failures based on electrical current signature analysis (MCSA) and the development of an advanced framework of predictive maintenance.

REFERENCES

- H. Badihi, Y. Zhang, B. Jiang, P. Pillay and S. Rakheja, "A Comprehensive Review on Signal-Based and Model-Based Condition Monitoring of Wind Turbines: Fault Diagnosis and Lifetime Prognosis," in *Proceedings of the IEEE*, vol. 110, no. 6, pp. 754-806, June 2022, doi: 10.1109/JPROC.2022.3171691
- M. Ben Khader Bouzid, G. Champenois, A. Maalaoui and S. Tnani, "Efficient Simplified Physical Faulty Model of a Permanent Magnet Synchronous Generator Dedicated to the Stator Fault Diagnosis Part I: Faulty Model Conception," in *IEEE Transactions on Industry Applications*, vol. 53, no. 3, pp. 2752-2761, May-June 2017, doi: 10.1109/TIA.2017.2661846.
- L. Y. Imamura, S. L. Avila, F. S. Pacheco, M. B. C. Salles, and L. S. Jablon, "Diagnosis of unbalance in lightweight rotating machines using a recurrent neural network suitable for an edge-computing framework," *Journal of Control, Automation and Electrical Systems*, 2022, doi.org/10.1007/s40313-021-00893-9.
- D. Neupane, R. Bouadjenek, R. Dazeley, and S. Aryal, "Data-driven machinery fault detection: A comprehensive review," 2024, <https://arxiv.org/pdf/2405.18843>.
- G. Niu, X. Dong and Y. Chen, "Motor Fault Diagnostics Based on Current Signatures: A Review," in *IEEE Transactions on Instrumentation and Measurement*, vol. 72, pp. 1-19, 2023, Art no. 3520919, doi: 10.1109/TIM.2023.3285999.
- R. V. Pulikollu, W. Erdman, J. Mclaughlin, K. Alewine, S. Sheng, and J. Bezner, *Wind Turbine Generator Reliability Analysis to Reduce Operations and Maintenance (O&M) Costs*, 2023, National Renewable Energy Laboratory, <https://books.google.com.br/books?id=pnhA0AEACAAJ>
- M. Rezamand, M. Kordestani, R. Carriveau, D. S. . -K. Ting, M. E. Orchard and M. Saif, "Critical Wind Turbine Components Prognostics: A Comprehensive Review," in *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 12, pp. 9306-9328, Dec. 2020, doi: 10.1109/TIM.2020.3030165
- J. P. Salameh, S. Cauet, E. Etien, A. Sakout, and L. Rambault, "Gearbox condition monitoring in wind turbines: A review," *Mechanical Systems and Signal Processing*, vol. 111, pp. 251-264, 10 2018, doi: 10.1016/j.ymsp.2018.03.052
- N. Sarma, P. Tuohy, and S. Djurovic, *Condition Monitoring of Rotating Electrical Machines*, 2023, ISBN 9780128035818.
- B. Wu, Y. Lang, N. Zargari, S. Kouro, *Power Conversion and Control of Wind Energy Systems*, 2011, John Wiley & Sons, ISBN 978-0470593653.
- M. F. Yakhni, S. Cauet, A. Sakout, H. Assoum, E. Etien, L. Rambault, M. El-Gohary, *Variable speed induction motors' fault detection based on transient motor current signatures analysis: A review*, *Mechanical Systems and Signal Processing*, vol. 184, 2023, doi:10.1016/j.ymsp.2022.109737.
- A. Yazdani, R. Iravani, *Voltage Sourced Converters in Power Systems - Modeling, Control, and Applications*, Wiley-IEEE Press, ISBN 978-0470551578.
- A. Yazidi, H. Heno, G-A. Capolino, D. Casadei and F. Filippetti, "Double-fed three-phase induction machine abc model for simulation and control purposes," 31st Annual Conference of IEEE Industrial Electronics Society, 2005. IECON 2005., Raleigh, NC, USA, 2005, pp. 6 pp.-, doi: 10.1109/IECON.2005.1569309.
- R. V. Rocha, L. A. Sousa and R. M. Monaro, "Experimental Platform for Evaluation of Full-Scale Variable-Speed Wind Generators Under Stator Winding Faults," in *IEEE Transactions on Energy Conversion*, vol. 38, no. 2, pp. 800-812, June 2023, doi: 10.1109/TEC.2022.3230260.

APLICAÇÃO DE NORMAS AERONÁUTICAS FUNDAMENTADAS PELA MANUTENÇÃO PRODUTIVA TOTAL NO SETOR DE MANUTENÇÃO DE ENERGIA EÓLICA

**Guilherme Gomes Noronha¹, Leandro Augusto Lemos Franco², Nelson Bezerra Ferreira Junior³,
Pedro Henrique Pedrosa Pereira⁴**

1 Instituto Tecnológico de Aeronáutica, 2 Instituto de Aeronáutica e Espaço, 3 Universidade de Fortaleza,
4 Pontifícia Universidade Católica de Minas Gerais

noronha.gui@gmail.com, dr.leandro.cta@gmail.com, nbjf@hotmail.com, pedrosa.pereira@hotmail.com

RESUMO

A indústria eólica, semelhante ao setor aeronáutico, requer alta disponibilidade e confiabilidade dos equipamentos, essenciais para o retorno financeiro dos investidores. No entanto, o setor eólico no Brasil ainda é jovem e carece de normas específicas de manutenção, ao contrário do setor aeronáutico, que possui normas avançadas e bem estabelecidas pela Agência Nacional de Aviação Civil (ANAC). Este trabalho propõe a aplicação das normas da ANAC, focadas na segurança de voo e manutenção aeronáutica, ao setor de Operação e Manutenção (OeM) de parques eólicos no litoral cearense. A correlação dessas normas com a TPM visa reduzir manutenções corretivas e aumentar a disponibilidade dos aerogeradores. Os resultados demonstram que a implementação dessas práticas no setor eólico melhora a eficiência e a confiabilidade da manutenção, aumentando a disponibilidade operacional dos equipamentos e reduzindo falhas, beneficiando assim os proprietários dos parques eólicos.

Palavras-chaves:

Energia eólica, Manutenção, ANAC, Aeronáutica, TPM.

ABSTRACT

The wind industry, similar to the aviation sector, requires high availability and reliability of equipment, which are essential for investors' financial returns. However, the wind sector in Brazil is still young and lacks specific maintenance standards, unlike the aviation sector, which has advanced and well-established standards set by the National Civil Aviation Agency (ANAC). This work proposes the application of ANAC standards, focused on flight safety and aircraft maintenance, to the Operation and Maintenance (OeM) sector of wind farms along the Ceará coast. Correlating these standards with TPM aims to reduce corrective maintenance and increase the availability of wind turbines. The results demonstrate that implementing these practices in the wind sector improves maintenance efficiency and reliability, increasing the operational availability of equipment and reducing failures, thus benefiting the wind farm owners.

Keywords:

Wind Energy, Maintenance, ANAC, Aeronautics, TPM.

1. INTRODUÇÃO

Nos últimos anos, os métodos de manutenção técnica e industrial modernizaram-se significativamente devido ao aumento da demanda por produtos e à mecanização das linhas de produção. Novas técnicas de manutenção surgiram globalmente, auxiliadas por visões organizacionais (Takahashi & Osada, 2015). No Japão, o desenvolvimento de sistemas de controle de qualidade, como a TQM (Total Quality Management), marcou conquistas estratégicas para a indústria, inicialmente focando no aumento da produtividade e levando ao desenvolvimento da TPM (Total Productive Maintenance) (Almeida & Souza,

2001).

A TPM visa reduzir custos, treinar funcionários e aperfeiçoar processos de produção, eliminando danos e erros organizacionais com novas tecnologias (Fernandes, 2011). Seu propósito é estabelecer um padrão de manutenção produtiva, evitando quebras e defeitos de forma eficaz e econômica.

A manutenção exige altos níveis de competência devido às graves consequências de erros, incluindo riscos ocupacionais como espaço restrito, riscos físicos, atmosféricos e sobrecarga mental (Martins, 2005). A indústria aeronáutica, caracterizada por elevados investimentos e mão-de-obra qualificada, enfrenta esses riscos, sendo uma atividade produtiva com baixa automação e alta integração de atividades multidisciplinares (Kinnisson, 2004). Por trabalhar com altos padrões de qualidade, disponibilidade e segurança, a indústria aeronáutica torna-se uma referência para diversos setores.

Para assegurar todos esses padrões, existem agências reguladoras que são responsáveis pela formulação das normas que regem os procedimentos e regras da aviação civil. Cada país tem sua agência reguladora, com normas e procedimentos definidos de acordo com suas particularidades. No Brasil, a ANAC - Agência Nacional de Aviação Civil é a entidade que regula e controla a aviação civil brasileira. Além disso, ela é responsável pela formulação de normas para a aviação civil. Para isso, a ANAC emite os Regulamentos Brasileiros de Homologação Aeronáutica (RBHA) e os Regulamentos Brasileiros de Aviação Civil (RBAC), que incluem seis regulamentos e quatorze instruções suplementares relacionados à manutenção aeronáutica para garantir a segurança do transporte aéreo (Ferreira, 2019).

Já no setor de energia eólica, a Det Norske Veritas - Germanischer Lloyd (DNV-GL) emite normas para energias renováveis, sendo uma das principais entidades normatizadoras. A norma DNV-GL-SE-0448 (2016) é uma referência para a manutenção de parques eólicos, servindo como guia não obrigatório para operadores e mantenedores (DNV-GL, 2021).

Ao contrário do setor eólico, que segue normas não obrigatórias, o setor aeronáutico é regulado por diretrizes obrigatórias, proporcionando práticas consolidadas e eficientes. Pesquisas e práticas do setor aeronáutico podem beneficiar o setor eólico ao introduzir metodologias mais robustas e eficazes, baseadas na regulamentação estabelecida na aviação.

Estudos, como o de Ferreira (2019), mostram que práticas de Manutenção Produtiva Total (TPM) correlacionadas com normas da ANAC podem melhorar significativamente indicadores de manutenção, segurança operacional e aeronavegabilidade, aumentando a competitividade das organizações. A aplicação das normas da ANAC em parques eólicos pode também gerar melhorias operacionais e fornecer feedback valioso para aprimorar normas aeronáuticas, fortalecendo a segurança de voo e o setor aeronáutico.

1.2 Objetivo

O objetivo principal deste trabalho é utilizar as normas e instruções da ANAC relacionadas à segurança de voo e manutenção aeronáutica no setor de Operação e Manutenção (OeM) em parques eólicos no litoral cearense. A correlação com a Manutenção Produtiva Total (TPM) visa reduzir a taxa de falhas e aumentar a disponibilidade dos aerogeradores. O estudo mostra na prática os ganhos obtidos nas usinas analisadas. A aplicação dessas normas da ANAC resultará em melhorias de confiabilidade e disponibilidade no setor eólico.

1.3 Justificativa

A justificativa para aplicar este trabalho no setor de energia eólica baseia-se em três pontos principais: a carência de normas de manutenção específicas, a excelência do setor aeronáutico como fonte de inspiração e a eficácia das boas práticas de manutenção aeronáutica.

Primeiro, o setor eólico brasileiro, embora em crescimento, ainda carece de normas específicas e padrões consolidados para a manutenção. Com 31,1 GW de capacidade instalada e em teste e mais de 11.180 aerogeradores distribuídos pelo país (ABEEólica, 2024), em comparação com o setor aeronáutico a indústria eólica ainda é jovem e precisa de diretrizes claras para assegurar a eficiência e a confiabilidade de seus equipamentos. A ausência de normas específicas pode levar a práticas de manutenção

inconsistentes, aumentando o risco de falhas inesperadas e reduzindo a disponibilidade operacional.

Segundo, a excelência do setor aeronáutico, regido por normas rigorosas estabelecidas pela ANAC, oferece uma valiosa fonte de inspiração. A aviação desenvolveu práticas de manutenção que garantem altos padrões de segurança e confiabilidade, fundamentais para a operação segura das aeronaves. Esses padrões são essenciais para assegurar a confiança de investidores e usuários, e sua aplicação pode beneficiar significativamente o setor eólico ao proporcionar uma base sólida para a elaboração de normas de manutenção.

Terceiro, a aplicação das boas práticas de manutenção aeronáutica, através das normas da ANAC correlacionadas à TPM, pode ser uma estratégia eficaz para estruturar o setor de manutenção eólico no Brasil. Ao adotar essas práticas, os técnicos poderão trabalhar de forma organizada e planejada, utilizando os recursos corretamente e no momento adequado. Isso resultará em maior disponibilidade e confiabilidade dos aerogeradores, além de reduzir a necessidade de manutenções corretivas. Assim, a implementação dessas práticas pode contribuir para a eficiência operacional e o crescimento sustentável do setor de energia eólica no Brasil.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Por que a TPM?

Para Levitt (2010), a TPM acarreta ao sistema produtivo um custo menor, na medida em que elimina desperdícios, gerencia perdas e reduz variações nos processos. Estas mudanças estimulam nos colaboradores um senso de protagonismo que se reflete nos resultados da companhia. Desta forma, a TPM, atuando sobre pessoas, os protagonistas dos resultados organizacionais, e sobre processos, acaba contribuindo para a eliminação de perdas.

2.2 Manutenção em usinas eólicas

Por trás da aparente simplicidade ou semelhança das atividades de manutenção eólica com a manutenção industrial convencional, surge um desafio crucial que diferencia esse setor: a escassez de capacitação profissional no cenário brasileiro. A falta de escolas e cursos especializados para a formação específica em energia eólica contribui para a deficiência de profissionais qualificados. Muitos desses especialistas adquirem conhecimento principalmente por meio da prática diária em campo ou, em alguns casos, em cursos e oficinas realizados no exterior, resultando em uma ausência de certificação por órgãos competentes nesse domínio (CORREIO DO POVO, 2023).

Nesse contexto desafiador, a manutenção em energia eólica enfrenta obstáculos adicionais que impactam suas rotinas e resultados. Entre essas dificuldades, destacam-se o acesso remoto e as complicações logísticas, a altura de trabalho e a complexidade das estruturas, as variações climáticas, o custo elevado de paradas não programadas e a necessidade de sincronização com a demanda energética do país. Superar esses desafios exige não apenas abordagens inovadoras e investimentos em treinamento, mas também o contínuo desenvolvimento de tecnologias específicas de manutenção para o setor eólico. Essa conjuntura demanda uma resposta integrada que vá além das práticas convencionais, visando o avanço sustentável da manutenção em energia eólica.

2.2.1 Normatização do setor eólico brasileiro

No Brasil, o setor eólico está sujeito à regulação da Agência Nacional de Energia Elétrica (ANEEL), uma entidade responsável por regular e fiscalizar a produção, transmissão, distribuição e comercialização de energia elétrica no país, conforme estabelecido pela Lei Nº 9.427, de 26 de dezembro de 1996 (Brasil, 1996). Contudo, é essencial salientar que, até o momento, não foram estabelecidas normas específicas, fiscalizações ou orientações pela ANEEL relacionadas à manutenção de aerogeradores no setor eólico.

Dessa forma, a responsabilidade pela manutenção dos aerogeradores recai integralmente sobre o proprietário do empreendimento eólico ou sobre os contratados designados para executar tais atividades. A ausência de regulamentação nesse contexto destaca a necessidade de uma abordagem autônoma por parte dos envolvidos na operação e manutenção de parques eólicos, que devem buscar as melhores práticas do setor e adaptá-las conforme as demandas específicas de cada empreendimento.

No cenário internacional, a DNV-GL desempenha um papel relevante no setor eólico. A DNV-GL formulou a norma DNV-GL-SE-0448, uma referência que propõe melhores práticas para a manutenção de aerogeradores. É importante ressaltar que, ao contrário de algumas outras áreas regulamentadas, não existem órgãos específicos regulamentadores para a manutenção de aerogeradores.

Essa lacuna em órgãos regulamentadores específicos destaca ainda mais a importância das normas e iniciativas estabelecidas por organizações reconhecidas, como a DNV-GL, na promoção de padrões elevados e seguros para a indústria de aerogeradores.

2.3 Manutenção na aviação civil

Segundo Aubin (2004), a manutenção na aviação civil é uma área crítica que desempenha um papel fundamental na garantia da segurança, confiabilidade e desempenho das aeronaves. Essa atividade visa assegurar que as aeronaves estejam em condições adequadas para operação, cumprindo os rigorosos padrões de segurança estabelecidos pelas autoridades de aviação civil.

A manutenção na aviação civil segue regulamentações rigorosas, e as atividades devem ser realizadas por profissionais altamente qualificados. As organizações de manutenção devem cumprir normas específicas, como as estabelecidas pela ANAC no Brasil.

Além disso, a documentação detalhada é essencial em todas as fases da manutenção, garantindo que cada etapa seja registrada e que a aeronave permaneça em conformidade com as regulamentações. Isso inclui registros de inspeções, reparos, modificações e substituições de componentes (AUBIN, 2004).

2.4 Manutenção na aviação civil x manutenção em usinas eólicas

A partir do estudo apresentado nos itens 2.2, 2.3 e a experiência profissional dos autores, pode-se afirmar, a manutenção em usinas eólicas e a manutenção na aviação civil, embora distintas em suas aplicações, compartilham elementos fundamentais e apresentam diferenças significativas em termos de contextos, desafios e práticas.

Similaridades:

Modalidades de Manutenção: ambos os setores adotam modalidades de manutenção preventiva, preditiva e corretiva. A manutenção preventiva visa antecipar falhas, a preditiva busca prever problemas com base em monitoramento avançado, e a corretiva atua em resposta a falhas identificadas.

Diferenças:

Ambiente de Operação: as usinas eólicas operam em ambientes terrestres ou marítimos, sujeitas a condições climáticas variáveis. Em contrapartida, a aviação civil lida com a operação de aeronaves no espaço aéreo, enfrentando desafios como variações de altitude e pressão atmosférica.

Padrões e Normas de Manutenção: enquanto a aviação civil segue rigorosas normas e padrões estabelecidos por órgãos reguladores, a manutenção em usinas eólicas muitas vezes carece de normas específicas, resultando em uma abordagem mais flexível e adaptativa.

Requisitos de segurança: A aviação civil é uma indústria altamente regulamentada, com requisitos rigorosos de segurança. A manutenção de aeronaves é, portanto, uma atividade de alta prioridade, que deve ser realizada por profissionais qualificados e experientes. A manutenção de aerogeradores também é importante para garantir a segurança, mas os requisitos não são tão rigorosos quanto na aviação civil.

Impacto Econômico de Paradas: o custo de paradas não programadas é crítico em ambas as áreas, mas as consequências econômicas podem variar. Na aviação civil, paradas não programadas podem afetar itinerários e operações comerciais, enquanto nas usinas eólicas, podem impactar a produção de energia.

Procedimentos de manutenção: Os procedimentos de manutenção de aerogeradores e de aeronaves são desenvolvidos por fabricantes e organizações de regulamentação. Os procedimentos de manutenção de aerogeradores são geralmente menos complexos do que os procedimentos de manutenção de aeronaves.

Capacitação Profissional: enquanto a aviação civil conta com uma rede estabelecida de escolas especializadas na formação de profissionais, o setor de usinas eólicas frequentemente enfrenta a escassez de instituições educacionais dedicadas. A formação nesse campo muitas vezes ocorre de maneira mais prática, refletindo a falta de estrutura educacional específica para o setor eólico.

2.5 Melhores práticas do setor aeronáuticos e da TPM

A partir das análises apresentadas nos itens 2.1 e 2.3, conclui-se que o setor aeronáutico e a Manutenção Produtiva Total (TPM) compartilham um compromisso fundamental com a segurança, confiabilidade e eficiência operacional. Portanto, a implementação de práticas comprovadas em ambos os setores pode resultar em melhorias significativas.

Setor aeronáutico

A partir de Franciscone e Lima (2023) e Leal (2020), é possível afirmar que o setor aeronáutico é reconhecido mundialmente por sua cultura de segurança, confiabilidade e eficiência operacional. Essa excelência se deve à implementação rigorosa de diversas melhores práticas, que podem ser resumidas em quatro pilares fundamentais:

Cultura de Segurança: pilar fundamental na indústria aeronáutica, promovendo a conscientização, o treinamento e a adesão rigorosa aos padrões e procedimentos de segurança. Isso inclui a implementação de programas de segurança ocupacional, auditorias regulares de segurança, investigação de incidentes e ações preventivas para garantir um ambiente de trabalho seguro e confiável.

Gestão de Riscos: prática essencial no setor aeronáutico para identificar, avaliar e mitigar possíveis ameaças à segurança e à eficiência das operações de manutenção. Isso inclui a análise de riscos de falhas de componentes, riscos operacionais e riscos de conformidade regulatória.

Colaboração e Comunicação: cultura de colaboração entre equipes de manutenção, operações e engenharia é fundamental no setor aeronáutico, incentivando a comunicação aberta e o compartilhamento de conhecimento para identificar e resolver problemas de forma eficaz.

Gestão de Ativos: sistemas de gestão de ativos é uma prática essencial no setor aeronáutico para monitorar o desempenho dos componentes das aeronaves, programar manutenções e garantir a conformidade com regulamentos e padrões de segurança.

Manutenção Centrada em Confiabilidade (MCC): a MCC é uma abordagem adotada pelo setor aeronáutico para concentrar-se na análise de riscos e na implementação de manutenção preventiva em componentes críticos, visando garantir a segurança e a confiabilidade das aeronaves.

Manutenção Planejada e Programada: prática de programar manutenções com base em intervalos predefinidos e em análises preditivas é comum, o que contribui para a redução do tempo de inatividade das aeronaves e a prevenção de falhas inesperadas.

Manutenção Autônoma: envolve os operadores na realização de manutenções básicas e inspeções regulares, é valorizada no setor aeronáutico por aumentar a eficiência operacional e a capacidade de identificar problemas de forma rápida.

Uso de Tecnologias Avançadas: o setor tem incorporado tecnologias avançadas, como sensores IoT e análise de dados em tempo real, em busca de uma manutenção mais proativa e eficiente.

Padronização de Procedimentos: prática comum na indústria aeronáutica, garantindo consistência, qualidade e segurança nas operações de manutenção por meio do estabelecimento de protocolos para cada tipo de manutenção.

Treinamento e Qualificação: no setor aeronáutico, é priorizado o investimento em treinamento contínuo e certificação dos técnicos de manutenção para garantir que estejam atualizados com as melhores práticas.

Melhorias Contínuas: uma filosofia amplamente adotada na indústria aeronáutica, incentivando a inovação,

a eficiência operacional e a qualidade dos serviços de manutenção. Isso envolve a realização de análises de desempenho, feedback dos clientes e implementação de ações corretivas e preventivas para aprimorar constantemente os processos de manutenção.

2.6 Regulamentos aeronáuticos vigentes no Brasil relacionados a manutenção (TPM) – Lista auxiliar

No Brasil, no que diz a respeito da regulação da aviação civil, a ANAC é a responsável por normatizar e supervisionar o setor, através especialmente dos RBACs e dos RBHAs. Sendo uma autarquia especial brasileira, com autonomia administrativa e funcional, é vinculada ao Ministério da Infraestrutura.

De acordo com Ferreira (2019), no Brasil os serviços de manutenção de aeronaves e seus equipamentos devem seguir seis RBACs e/ou RBHAs emitidas pela ANAC, que são apresentados a seguir na Tabela 1.

Norma	Descrição
RBAC 43	Manutenção, manutenção preventiva, reconstrução e alteração.
RBAC 65	Licenças, habilitações e regras gerais para Despachante Operacional de Voo (DOV) e Mecânico de Manutenção Aeronáutica (MMA).
RBAC 91	Requisitos gerais de operação para aeronaves civis.
RBAC 145	Organizações de manutenção de produto aeronáutico.
RBAC 121 Subparte L	Operações de transporte aéreo público com aviões com configuração máxima certificada de assentos para passageiros de mais 19 assentos ou capacidade máxima de carga paga acima de 3.400 kg. Manutenção, manutenção preventiva, modificações e reparos.
RBAC 135 Subparte J	Requisitos operacionais: operações complementares e por demanda. Regras adicionais àquelas contidas em outros regulamentos sobre manutenção, manutenção preventiva, modificações e reparos.

Tabela 1. RBACs relacionados a serviços de manutenção

Fonte: Agência Nacional de Aviação Civil (2022).

Além das normas citadas anteriormente as Instruções Suplementares (IS) da ANAC listadas a seguir na Tabela 2 complementam os regulamentos relacionados a manutenção aeronáutica, no que tange a manutenção.

IS	Descrição
119-008	Apresentar os procedimentos para a implementação de um Programa de Acompanhamento e Análise de Dados de Voo (PAADV)
21-003	Descrever meios aceitáveis para o desenvolvimento e a aprovação de uma Lista Mestre de Equipamentos Mínimos (MMEL - Master Minimum Equipment Lis)
43-012	Manutenção preventiva por pilotos
43.13-004	Procedimentos para Reparo de Aeronaves Avariadas em Acidente/Incidente Aeronáutico ou Ocorrência de Solo com Avarias Estruturais de Grande Monta.
145.151-001	Cadastramento de Responsável Técnico de Organização de Manutenção de Produto Aeronáutico.
00-001	Sistema de Dificuldades em Serviço
00-010	Treinamento de Gerenciamento de Recursos de Equipes (Corporate Resource Management - CRM)
145-010	Programa de Treinamento de Organizações de Manutenção
145-002	Certificação de Organização de Manutenção Estrangeira
121-006	Procedimentos gerais para elaboração, aprovação, revisão e utilização de programas de treinamento operacional (PTO) de operadores aéreos regidos pelo RBAC nº 121.
135.21-001	Instruções para a Elaboração do Manual Geral de Manutenção (MGM) – Táxis Aéreos Operando Exclusivamente Aeronaves com Configuração Máxima para Passageiros Igual ou Inferior a 9 (Nove) Assentos

145-009	Manual da Organização de Manutenção, Manual de Controle da Qualidade e Declaração de Conformidade
145.214-001	Sistema de Gerenciamento da Segurança Operacional em Organizações de Manutenção de Produto Aeronáutico

Tabela 2. IS relacionadas a serviços de manutenção

Fonte: Agência Nacional de Aviação Civil (2022).

2.7 Operação e manutenção do complexo eólico – Objeto de estudo

O complexo eólico, onde o presente estudo foi aplicado, possui 182 aerogeradores com potência de 2.1 MW (Megawatt) cada, totalizando 382,2 MW de potência instalada, energia que pode abastecer aproximadamente 550 mil residências durante um ano, equivalente ao consumo de uma cidade como Curitiba - PR. Toda a produção é vendida através do PROINFA, programa que agrega alto valor para o investidor na energia produzida devido aos incentivos econômicos concedidos pela Lei Nº 10.438, de 26 de Abril de 2002 (Brasil, 2002).

Atualmente as atividades de operações e manutenções são feitas pela empresa proprietária por meio de seus colaboradores, ou seja, a companhia dona do complexo usa mão de obra do seu próprio corpo técnico na gestão da manutenção, prática não comum no mercado de energia eólica brasileiro, porém difundida em mercados americanos e europeus.

2.8 Estado da arte

É fundamental compreender como os princípios e práticas da TPM têm sido implementados e adaptados para otimizar a eficiência operacional e a confiabilidade dos equipamentos nessas duas áreas distintas, mas inter-relacionadas neste trabalho.

2.8.1 Aplicação da TPM e suas ferramentas na indústria aeronáutica

Destacam-se estudos que descrevem as estratégias de manutenção autônoma, manutenção planejada, controle inicial e educação e treinamento, demonstrando como esses elementos são aplicados para melhorar a disponibilidade das aeronaves, reduzir custos operacionais e aumentar a segurança dos voos.

1. Leanness e Manutenção Produtiva Total (TPM). Modelo de Produtividade e Competitividade. Estudo de Caso. Sérgio Manuel Gaião Jesus, 2012.
2. Uso Da Manutenção Centrada Em Confiabilidade Em Indústrias De Asas Rotativas. Lucas Vieites Silva, 2019.
3. Princípios Da Metodologia Lean Aplicados Em Uma Linha De Manutenção Em Uma Companhia Aérea: Um Estudo De Caso Da Aeronave (Helicóptero Modelo S-70). Rodrigo Tito De Almeida, 2021.

2.8.2 Sinergias entre a TPM na aeronáutica e manutenção na indústria

Destaca-se a importância da padronização e da incorporação de uma cultura de melhoria contínua adaptada às especificidades de cada setor industrial.

1. Implementação de conceitos de manutenção aeronáutica à TPM de fornos de Tratamento Térmico. Luiz Sbegue, 2021.

3. MÉTODO DO ESTUDO

Esta pesquisa adotou uma abordagem comparativa entre a gestão da manutenção nos setores aeronáutico e eólico, explorando as lacunas regulatórias e os métodos de melhoria contínua. Foi realizada uma análise detalhada das normas e procedimentos da Agência Nacional de Aviação Civil (ANAC) em

relação a manutenção aeronáutica e à segurança de voo, correlacionando estas normas com pilares da TPM e aplicando esses princípios no contexto da operação e manutenção de parques eólicos.

Foi implementado o ciclo PDCA, para estruturar a implementação deste trabalho, com foco na redução de manutenções corretivas e no aumento da disponibilidade dos aerogeradores. Os resultados foram avaliados e comparados antes e depois da implementação.

3.1 Justificativa metodológica

Segundo Snee (2007), o ciclo PDCA é uma escolha metodológica sólida para esta pesquisa devido à sua estrutura sistemática e foco na melhoria contínua. Essa metodologia proporcionou uma estrutura clara para a implementação das normas, análise dos resultados e ajustes necessários, alinhando-se perfeitamente com o propósito de melhorar a eficiência da manutenção e aumentar a disponibilidade dos aerogeradores. Além disso, o PDCA facilitou a comparação entre os estados pré e pós-implementação, fornecendo dados tangíveis sobre a eficácia das práticas de gestão inspiradas na aviação aplicadas ao setor eólico. A seguir na Figura 1 é apresentado uma matriz com os passos da metodologia que este trabalho seguiu.



Figura 1 – Matriz do PDCA

3.2 Primeiros passos para aplicação da TPM (Planejamento - *Plan*)

Dentre algumas literaturas, Thorata (2018) mostra que uma implementação de sucesso segue alguns passos importantes, dentre eles os seguintes foram seguidos antes do início da fase de aplicação da TPM:

Conhecimento do processo – foi realizado um estudo detalhado dos processos e metodologias de trabalho utilizadas no dia a dia da organização para mapeamento de possíveis falhas e pontos de melhoria;

Identificação dos problemas – foram mapeadas as principais falhas onde a TPM pudesse atuar e obter melhoras através de seus pilares;

Revisão de literatura – foi realizada uma busca bibliográfica sobre o assunto, através de estudo de manuais e livros, tudo que pode ser usado para solucionar os problemas descritos;

Aquisição de dados – através de levantamento de dados disponíveis, foi realizada pesquisa qualitativa e quantitativa a fim de buscar os dados dos problemas identificados previamente;

Análise de Pareto – através do princípio de Pareto foram distribuídos os principais problemas que trouxeram um maior retorno para a organização;

Implementação de estratégias da TPM – Desenvolvimento e implementação de um plano de ação para resolver e aprimorar os problemas identificados, utilizando as práticas e pilares da TPM. Este plano foi cuidadosamente concebido para assegurar a conformidade com as normas da ANAC e a aplicação efetiva dos princípios da TPM. A Figura 2 ilustra como foi a concepção do plano.




Figura 2 – Concepção do plano

Esses seis passos supracitados, são representados na Figura 3, eles forneceram uma base sólida para a aplicação da TPM, aumentando a confiança na obtenção de resultados eficazes. Por isso, a aplicação da TPM só se iniciou após a conclusão desses cinco estágios iniciais.




Figura Erro! Nenhum texto com o estilo especificado foi encontrado no documento. – Primeiros passos para aplicação da TPM

3.3 Desenvolvimento e execução de plano de ação (Execução - Do)

A execução gradual do plano de ação foi cuidadosamente conduzida, acompanhada de um processo monitoramento. Esse procedimento possibilitou uma avaliação contínua do desempenho dos equipamentos, permitindo a pronta identificação de melhorias ou desafios encontrados.

3.4 Verificação dos efeitos do trabalho executado (Checar - Check)

O principal propósito desse procedimento foi realizar uma análise comparativa dos resultados obtidos em relação às metas estabelecidas durante a fase de planejamento. Esse processo de verificação proporcionou uma visão crítica e analítica do desempenho, fornecendo insights essenciais que alimentaram diretamente as decisões na etapa seguinte do ciclo PDCA, conhecida como "Action".

3.5 Atuação no processo em função dos resultados (Ação - Action)

Com base nos resultados obtidos, foi feita a identificação de áreas que demandam intervenção adicional. Este processo envolveu a análise crítica das deficiências persistentes, lacunas nas práticas de manutenção e quaisquer desvios em relação aos objetivos inicialmente delineados.

4. Plano macro de aplicação

4.1 Conhecimento do processo

A estrutura de manutenção do OeM é vista como centralizada, na qual existe um time único, dividido por regiões, assistindo à toda frota em suas necessidades de manutenção. Tais equipes atendem

manutenções corretivas programadas, não programadas e preventivas, sendo todos estes tipos de manutenções baseadas em manuais e instruções do fabricante dos aerogeradores.

Completando a equipe de manutenção existe uma equipe de suporte técnico formada pelos profissionais mais experientes da companhia, por meio da qual atua de forma rotativa nas usinas em ações pontuais, na medida em que as equipes locais não conseguem intervir em falhas de forma assertiva. Esta equipe, além de realizar manutenções corretivas complexas, fica responsável também pela tarefa de tirar dúvidas e acompanhar novos projetos.

4.1.1 Identificação do problema

Abaixo listaram-se os principais problemas identificados:

- Baixa conservação dos ativos;
- Baixa disponibilidade da frota;
- Alta taxa de falhas;
- Falta de registro sistematizado de informações.

4.1.2 Análise de Pareto de problemas identificados

Na Figura 4 é mostrado um gráfico que facilita a análise pelo princípio de Pareto, o qual afirma que, para muitos eventos, aproximadamente 80% dos efeitos são oriundos de 20% das causas (The Balance, 2019). Através desta análise, percebeu-se com clareza que há três principais falhas que devem ser solucionadas por meio do plano macro de aplicação deste trabalho, são elas:

- Substituição da caixa multiplicadora;
- Substituição dos rolamentos de pás;
- Reparos de pá;



Figura 4. Princípio de Pareto para principais falhas nos aerogeradores

Por meio de uma análise mais detalhada das três falhas, notou-se que somando-se o tempo total delas é obtido o valor de 19.747,3 horas, que representa 822,4 dias, o qual equivale a média de 2,25 aerogeradores fora de operação na frota durante um ano.

4.1.4 Lista com principais pontos de melhoria

Na Tabela 3 a seguir é apresentada a lista com os principais pontos de melhoria levantados.

Ponto	Descrição
01	Envolvimento executivo na manutenção

02	Sem uma definição clara da matriz de responsabilidades de cada setor e seus colaboradores
03	Sem metodologia alguma quanto a organização de tarefas
04	Ausência de documentação padrão, como também falta de definição de fluxo organizacional de controle.
05	Sem registros de qualquer estudo de análise ou solução de problemas
06	Falta de um plano de manutenção baseado na condição vigente dos aerogeradores, quanto ao local de operação, idade e condições ambientais
07	Ausência de registros e organização de relatórios de atividades de manutenção
08	Falta de uma matriz de habilidades para os colaboradores para acompanhamento e treinamento
09	Ausência de busca por melhorias em processos de manutenção
10	Falta de alinhamento entre áreas de operação e manutenção para definição de plano estratégico orçamentário de curto e médio prazo
11	Ferramental das equipes sem qualquer rastreio de calibração e com potencial para modernização
12	Falta de monitoramento minucioso de todo o sistema operacional dos aerogeradores

Tabela 3. Principais pontos de melhoria levantados

4.2 Plano macro de aplicação de TPM

Com base nos 12 pontos apresentados na Tabela 3, foi desenvolvido um plano de ação abrangente, apresentado na Tabela 4, para a implementação do trabalho na organização de manutenção. O plano inclui ações fundamentadas nos pilares da TPM e nas normas da ANAC, que estão detalhadas na tabela para cada ação proposta. Cada número de ação nesta tabela está correlacionado ao mesmo número do problema identificado na Tabela 3.

Ação	Pilar TPM	Norma ANAC	Descrição
01	Controle Inicial		Apresentação e aval do projeto pela alta gestão da organização
02	Controle Inicial	RBAC 145 na subparte E	Definição de matriz de responsabilidades
03	Manutenção Autônoma		Implementação de metodologia 5S
04	Manutenção Planejada	RBAC 145, na subparte E	Revisão e padronização da documentação interna
05	Educação e Treinamento Melhoria Contínua	Instrução Normativa nº 154	Capacitação em ferramentas de análise e solução de problemas
06	Manutenção Planejada	RBAC 145, na subparte E	Revisão dos planos de manutenção da frota
07	Manutenção da Qualidade	RBAC 145 na subparte E, RBAC 43 e IS 135.21-001.	Arquivamento e registros de atividades
08	Manutenção Autônoma Educação e Treinamento	RBAC 145, RBAC 121, RBAC 135 na subparte J e as IS 135.21-001, 121.006 e IS 145-010	Treinamentos em novos procedimentos e processos de manutenção
09	Melhoria Contínua Manutenção planejada Educação e treinamento	IS 145.214-001	Aplicação de melhorias na frota

10	Gestão Administrativa	IS 145-009 e IS 135.21-001	Implementação de processos de gestão integrada do orçamento entre manutenção e operação
11	Controle Inicial Melhoria Contínua Manutenção de Qualidade	RBAC 145 subparte C, RBAC 43 e IS 135.21-001	Modernização e controle de qualidade ferramental de manutenção
12	Melhoria Contínua Controle Inicial Manutenção de Qualidade	IS 119-008 Revisão A da ANAC	Melhoria dos sistemas de monitoramento de condição da frota

Tabela 4. Plano macro de aplicação

5. SITUAÇÃO DOS ATIVOS APÓS APLICAÇÃO DO TRABALHO

Como consequência do trabalho aplicado houveram diversas melhoras nos ativos, destacam-se:

Conservação dos ativos:

Atividades de cuidados básicos, como lubrificação e limpeza, passaram a ser executadas em todas as visitas aos aerogeradores, além da execução de limpeza e restauração de alguns ativos que apresentavam degradação por corrosão.

Disponibilidade da frota:

Planejamentos de manutenções preventivas e corretivas foram cumpridos, possibilitando a troca de componentes essenciais à operação das máquinas, deixando-as em condições de operação e com componentes novos e em bom estado para operação.

Falta de registro sistematizado de informações

Os registros de manutenção foram feitos e foram disponibilizados com todos os colaboradores responsáveis pelas manutenções, tornando possível acompanhar o histórico de manutenção dos ativos.

Taxa de falhas

Baixos índices de falhas foram registrados nas operações da frota após aplicação do trabalho, o que resultou em uma redução significativa no número de paradas dos aerogeradores. Este contexto aliviou a carga de trabalho sobre as equipes de manutenção, contribuindo positivamente para a eficiência operacional das usinas eólicas.

6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

6.1 Análise da hipótese

A aplicação de metodologias de segurança de voo, através das normas da aviação brasileira, aumentaria os padrões de confiabilidade e disponibilidade da indústria eólica?

Sim. No item 4 foi apresentado um plano de redução de taxa de falhas e aumento de disponibilidade a partir das normas da aviação brasileira e no item 5, são apresentados os ganhos da frota obtidos após a aplicação deste plano.

Comparado ao setor aeronáutico, o setor eólico apresenta notáveis diferenças regulatórias. Embora exista uma agência reguladora para o setor eólico, ainda não há regulamentos específicos que abordem a manutenção nesta agência. Daí a relevância deste estudo. Como é possível aprimorar a segurança se não existem normas comparativas para orientar as práticas de manutenção? Nesse cenário, a utilização das normas do setor aeronáutico se tornou crucial. Essas normas aeronáuticas já estabelecidas forneceram uma base sólida de padrões de segurança e procedimentos, facilitando a implementação de práticas eficazes e adaptadas às necessidades da manutenção em energia eólica.

6.2 Avaliação do objetivo

O presente trabalho conseguiu utilizar as normas e instruções da ANAC, mencionadas nas tabelas 1 e 2, relacionadas à segurança (*safety*) de voo e manutenção aeronáutica no setor de OEM para um conjunto de parques eólicos, correlacionadas a TPM.

Foi realizado um estudo das normas e instruções que tinham relação com a manutenção; em seguida, fez-se um levantamento das principais deficiências do setor de OEM no campo da indústria eólica, baseado neste levantamento elaborou-se um plano de implementação das boas práticas identificadas nas normas e instruções a fim de gerar um maior impacto no setor em estudo.

Após a implementação do plano, evidenciou-se que a aplicação destas normas obteve resultados positivos, reduzindo as taxas de falhas e aumentando a disponibilidade dos aerogeradores. Os ganhos mensurados nos produtos deste trabalho foram apresentados no capítulo 5 e discutidos no capítulo 6. Comprovou-se assim que as boas práticas adotadas no setor aeronáutico podem sim propiciar resultados relevantes impactando na gestão de ativos quando aplicados de forma inteligente, sendo opção de modelo de gestão e organização para os setores eólico e industrial geral.

6.3 Sugestão para trabalhos futuros

Algumas propostas para esta área de aplicação podem ser desenvolvidas. Dentre temas em potencial para pesquisas futuras, as sugestões são listadas a seguir:

- (a) Elaboração de manual com melhores práticas de operação e manutenção no setor de energia eólica a fim de padronizar o setor.
- (b) Criação de um manual de treinamento e capacitação para técnicos exclusivamente do setor de manutenção de energias renováveis, tomando como base as normas e instruções aeronáuticas;
- (c) Realização de um estudo prático com intercâmbio entre profissionais do setor de energia eólica e manutenção aeronáutica, possibilitando a integração e a troca de experiências entre as categorias a fim de difundir novas ideias e novas tendências tecnológicas;
- (d) Realização de um estudo das principais falhas de manutenção nas organizações aeronáuticas e usinas de energia eólica, listando pontos de melhorias que possam ser aplicados em ambos os setores;

6.4 Comentários finais

Além de trazer resultados importantes de disponibilidade a frota, a utilização das normas e instruções suplementares da ANAC fundamentadas pela TPM elevou o nível de confiança dos ativos, reduzindo drasticamente o número de paradas e falhas, tornando os aerogeradores mais confiáveis e disponíveis. Desta forma, fica evidenciado que a aplicação de normas aeronáuticas no setor de energia eólica obteve resultados satisfatórios em termos de:

- Taxa de falhas – redução do número de falhas e conseqüentemente o número de manutenções corretivas;
- Disponibilidade – aumento da disponibilidade global da frota e conseqüentemente a confiabilidade;
- Produtividade – com um número maior de aerogeradores disponíveis, a produção geral de energia aumentou.

REFERÊNCIAS

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. RBAC - Regulamentos Brasileiros da Aviação Civil. Brasília, 2022 Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac>. Acesso em: 23 maio 2023

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. IS - Instrução Suplementar. Brasília, 2022. Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/iac-e-is/is>. Acesso em: 23 maio 2023

ALMEIDA, A. T. (Org.); SOUZA, F. M. C. de (Org.). Gestão da Manutenção na Direção da Competitividade. 1ª. ed. Recife: Universitária, 2001. 380 p.

ASSOCIAÇÃO BRASILEIRA DE ENERGIA EOLICA. Infovento 34. São Paulo, 2024. Disponível em: https://abeeolica.org.br/wp-content/uploads/2024/03/424_ABEEOLICA_INFOVENTO_ED34_PT_V3.pdf
Acesso em: 22 abr. 2024

AUBIN, B. R. Aircraft Maintenance. The Art and Science of Keeping Aircraft Safe. Warrendale, PA: SAE Permissions, 2004.

CORREIO DO POVO. Faltam engenheiros para mercado de energia limpa. Disponível em: <https://www.correiodopovo.com.br/not%C3%ADcias/economia/f%C3%B3rum-de-energias-renov%C3%A1veis/faltam-engenheiros-para-mercado-de-energia-limpa-1.1078653> Acesso em: 06 dez. 2023

DNV GL. DNVGL-SE-0448: Certification of service and maintenance activities in the wind energy industry. Disponível em: <https://rules.dnv.com/docs/pdf/DNV/SE/2016-08/DNVGL-SE-0448.pdf> Acesso em: 20 mar. 2020

DNV GL. Nossa História. Disponível em: <https://www.dnvgl.com.br/about/in-brief/nossahistoria.html> . Acesso em: 25 abr. 2021.

FERREIRA, Nelson Bezerra, Jr. Uso da manutenção produtiva total (TPM) como ferramenta de gestão no setor aeronáutico. 2019. Dissertação de mestrado profissional em Segurança da Aviação e Aeronavegabilidade Continuada – Instituto Tecnológico de Aeronáutica, São José dos Campos.

FERNANDES, Waldir Algarte. O Movimento da qualidade no Brasil. São Paulo: Essencial Idea Publishing. INMETRO, 2011, 155p.

FRANCISCONE, B. G.; LIMA, P. A. L. . A Consolidação Da Aviação Civil Internacional E Suas Implicações Para A Implementação Do Plano Global De Navegação Aérea. Revista Brasileira de Aviação Civil & Ciências Aeronáuticas, [S. l.], v. 1, n. 2, p. 6–32, 2023.

KINNISSON, H. A., PH.D. Aviation maintenance management. Mcgraw Hill 2ª. ed., 2004

LEAL, ALEXANDRE ALVES DA SILVA. Sistema De Gerenciamento Da Segurança Operacional Na Aviação: Alta Direção, Cultura E Os Benefícios Resultantes Da Implementação Desse Sistema De Gerenciamento. 2020. 36 f. Monografia (Curso de graduação em Ciências Aeronáuticas) - UNIVERSIDADE DO SUL DE SANTA CATARINA, [S. l.], 2020.

LEVITT, Joel .TPM Total Productive Maintenance. 1ª. Ed. New York – NY: Industrial Press Inc., 2010

MARTINS, D. de A. Estresse ocupacional e qualidade de vida de trabalhadores de manutenção de aeronaves de uma instituição militar brasileira. 2005. Dissertação (Mestrado em psicologia) – Universidade Católica Dom Bosco, Campo Grande.

SNEE, Ronald. Use DMAIC to make improvement part of 'the way we work', (define, measure, analyze, improve, and control). Quality Progress, 2007.

TAKAHASHI, Yoshikazu; OSADA Takashi: TPM/MPT: Manutenção Produtiva Total. 5.ed. São Paulo: Imam, 2015. 311 p.

THE BALANCE. Pareto's Principle: How the 80/20 Rule Can Help Improve Your Performance. 2019.

THORATA, Rohan; G. T., Mahesha Improvement in productivity through TPM Implementation. International Conference on Advances in Materials and Manufacturing Applications, IConAMMA 2018.

Use of convolutional neural network to failure detection in WTs drivetrains

Eduardo J.N. Menezes^{1,2,*}, Carolina Calvo Neves¹, Hallason Matias¹

Evoluce Tecnologia

Priscilla Ghisi³, Marlos Diógenes³, Maurício Nunes³, Thiago Costa³

AES Brasil S.A.

¹Evoluce Tecnologia / ²Departamento de Engenharia Mecânica, Universidade Federal de Pernambuco
eduardo.menezes@evolucetecnologia.com.br, carolina.neves@evolucetecnologia.com.br,
hallason.matias@evolucetecnologia.com.br

³AES Brasil S.A.

priscilla.ghisi@aes.com, marlos.diogenes@aes.com, mauricio.andre@aes.com, thiago.costa@aes.com

ABSTRACT

Drivetrain related failures are one of the main concerns for wind turbines (WTs) operation. They are responsible for increased downtimes and associated high O&M costs. Condition monitoring systems based on vibration measurements are the standard in WT applications, but they still rely on vibration analysts and complex frequency-domain analysis to provide diagnostic results. In the present paper, we demonstrate a new monitoring solution, based on artificial intelligence tools, to run diagnosis of WT main components. The developed algorithm enables identification of time-series anomalies in several drivetrain stages, by extracting time-frequency information using Short-Time Fourier Transform and convolutional layers. Effectiveness of the method is proven on a real WT CMS vibration database.

Keywords:

condition monitoring; deep learning; convolutional networks; predictive maintenance; O&M cost reductions.

1. INTRODUCTION

Many complex industrial sectors face the challenge of reducing operation and maintenance (O&M) costs. These are responsible for impacting a significant part of the profitability during a project lifetime, due to unforeseen failure modes and failure scenarios. This is even more pronounced in the wind energy assets, due to their harsh operational conditions and continuously variable loads. Indeed, there is a large amount of premature failures, especially in the load-carrying components, such as bearings and gears. These are responsible for an increased downtime and consequent production losses caused to the wind farm

operator.

On the other hand, the investments in wind turbines (WTs) attain a huge amount, requiring the appropriate financial return. In the last decade, installed wind potential increased from approximately 320 GW in 2013 to the milestone of 1 TW in 2023 (GWEC, 2023). In Brazil, more than 42 billion dollars were invested in the wind sector from 2012 to 2022, and wind energy reaches 28 GW of installed power, being the second largest source of generation in the country, only behind of the hydroelectric energy (ABEEólica, 2023). For all these investments to be profitable, it is essential to optimize the availability and productivity of wind turbines, reducing costs and maximizing the profitability of the asset. The reduction of O&M cost becomes essential in this scenario, since a cost breakdown analysis collected by industry stakeholders show that O&M expenses can attain 25-30% of the levelized cost of energy (LCOE) in a wind project (NREL, 2022).

In this context, one of the main pathways is the use of Prognostics and Health Management (PHM) to predict the health state of an engineering component or system. PHM relies on data collection of key variables related to the asset operation, such as vibration, temperature or acoustic emissions, and use this information to run failure diagnosis and prognosis, by means of artificial intelligence (AI). Therefore, a predictive maintenance policy can be established by the WT operator, allowing better control over the monitored asset. Typically, the WTs are able to store information in the Supervisory Control and Data Acquisition (SCADA) and in the Condition Monitoring System (CMS). Any of the variables present in these two systems can be used to manage WT maintenance, but several research papers demonstrate the vibration time-series are the best option to estimate drivetrain failures (Chaleshtori & Aghaie, 2024; Moghadam & Nejad, 2022). Further, these types of failure are responsible for the major costs in WT maintenance (Dao et al., 2019).

Regardless of vibration CMS being present in most WTs, many difficulties in the diagnosis of drivetrain failures still arise. First, the WT has components working in different frequency ranges, which appear aggregated in the time signal. Second, the essentially random wind loading imposed to the WT structure propagates through the drivetrain, introducing complex vibration patterns in the measured vibration waveform. Third, the analysis and diagnosis of failures using the CMS vibration is still highly dependent on human experts, which uses various signal processing techniques and engineering judgment to indicate failure occurrence. In other words, there is no use of PHM algorithms which could be faster and provide a complete and reliable WT diagnosis.

In order to overcome the challenges in the use of WT monitoring data, we have been developing several failure detection methods, capable of run diagnosis and detect anomalies in CMS time-series data. The developed methods rely on deep learning (DL) techniques, which can process raw information to extract the main features of the monitored asset. In fact, DL is a branch of AI applications, characterized by the use of neural networks composed of three or more hidden layers (Deisenroth et al., 2020). In this paper, we present one of our PHM solutions, which enables the detection of drivetrain failures without the need of following specific frequencies. Our approach converts the time-series data to a 2D domain, by using

the Short-Time Fourier Transform (STFT). The proof of concept is realized through testing in a commercial wind farm.

2. LITERATURE REVIEW REGARDING AI APPLICATIONS IN MONITORING

A large amount of research has been executed in AI for evaluating the health of machines, systems or structures (Berghout & Benbouzid, 2022). In this research field, several PHM papers rely on laboratory test data which not necessarily corresponds to real conditions. Nevertheless, they present useful methods that worth consideration and that can be combined and adapted for use in real WTs. This paper presents a diagnostic solution which, among other considerations, is also a product from literature survey, and this is why a brief review follows.

The first monitoring techniques for WTs are essentially derived from methods applied to gears and bearings in general rotating machinery (Leite et al., 2018). Older industries such as hydraulic and steam power have a long story of condition monitoring of their components, and therefore they possess very well-established procedures to evaluate equipment's health. Besides, they have smoother operational conditions when compared to WTs, what makes easier the application of general rules, while in the wind industry the solution must be customized. This is another reason for that DL approaches fit so well in WTs analysis, since they are inherently nonlinear. With the increase in computational power and the advent of big data, the last decade has seen an impressive increase in DL research, including using collected vibration data to run diagnosis (Do & Söffker, 2021).

One of the first attempts was carried out by (Kankar et al., 2011), where the raw vibration data is processed through wavelets. Authors compare the performance of Support Vector Machines (SVMs) with Self-Organizing Maps (SOMs) for bearing defect classification. In the work of (Malhi et al., 2011), wavelets are also used, but this time for establishing the remaining useful life (RUL) of bearings using recurrent neural networks (RNNs). A specific application of machine learning for WTs is first presented (Y. Zhang et al., 2014) which presents a neuro-fuzzy method to evaluate pitch faults using the power signal, but without vibration data. The vibration analysis of WTs appears in (Zimroz et al., 2014), where the authors propose the use of statistical measures, such as signal RMS, considering the non-stationarity of WT operations. The work aims to improve the recommendations of the german standard VDI 3834 (VDI, 2009). This was the first norm to preview limits for WT vibrations, classifying different zones of attention for vibration RMS levels. Afterwards, in 2015, the classical ISO 10816 has issued its Part 21, containing recommendations for WT vibration analysis. However, these standards are rather prescriptive and general, and their use has limitations. In 2013, (Bechhoefer et al., 2013) have made a complete analysis of the Fourier Fast Transform (FFT) as applied to vibration signal monitoring. FFT is largely used in the posterior PHM papers and in WT condition monitoring, as in (Verstraete et al., 2017). Other processing techniques were also used for vibration data, such as Hilbert-Huang transform (Soualhi et al., 2015), wavelet packet transform (Song et

al., 2018) and empirical mode decomposition (Wu, Jiang, et al., 2019). Nevertheless, FFT with envelope analysis is consolidated as the standard tool for WT vibration analysis in the wind industry.

Most recent works have focused on DL methods. In the work of Guo et al. (2017), a health indicator (HI) is constructed based on the training of a RNN using vibration time and time-frequency features, which are ranked by their monotonicity. Authors test their tool in a WT bearing prognosis, achieving a suitable degradation trend, compatible with the field data. Li et al. (2019) have estimated the RUL of bearings with a convolutional neural network (CNN), using as input the short-time Fourier transform (STFT) of the vibration signal, using multi-scale vibration signal. Indeed, the STFT corresponds to the Fourier transform in reduced time window, such that, for every vibration data sample, a 2-D matrix is output. In this context, Wu et al. (2019) propose the construction of a HI based on the bathtub curve, to model the bearing degradation and estimate the RUL. Pecht et al. (2020) employ CNNs with residual blocks of deep NNs, whose input is given by wavelet packet transform. The focus is the classification of bearings and gear failures using vibration data, into 9 different classes. The three classical bearing failures are considered, i.e., inner race, outer race and cage faults. Also, Zhao et al. (2020) have conducted a benchmark analysis of various DL diagnostic methods, where an autoencoder is pointed as one of the promising tools. Autoencoders are also present in the research paper of (Wang et al., 2021), in which the latent space is used for estimating the RUL. The previous papers are focused towards diagnostic and prognostic using vibration signals from laboratory data, mainly from the largely known IEEE-PRONOSTIA platform and the CWRU or MFPT datasets (CWRU, 2013; MFPT, 2016; Nectoux et al., 2012). More extensive reviews regarding DL-based failure detection are presented, e.g., in Zhang et al. (2020) and Rezamand et al. (2020).

Literature review shows that papers focused in providing diagnostic solutions for real WT data is scarce, since there is a necessity of a lot of historical data to implement the developed solutions. This could be executed in a second phase of the CMS implementation, when the operator could use its own historical data to implement estimation of RUL and classification of failure types. First, it is necessary to provide the operator with a tool to identify the WT bearing failures using DL cluster analysis to identify anomalies in the vibration data, and notify the operator to proceed with the condition-based maintenance (CBM). Two papers in this direction are the ones of Ben Ali et al. (2018) and J. Guo et al. (2018). The present paper is aligned with this maintenance philosophy, building a solution applied in real WT CMS vibration data. The developed tool allows the diagnostic of bearing failures, using a deep learning convolutional network through processing of raw vibration data. There is no need of spectral or envelope analysis, as it is usually realized in conventional CMS.

3 METHODOLOGY

3.1 Convolutional Neural Networks

Convolutional neural networks (CNNs) are specifically designed for variable and complex signals, which have two remarkable characteristics, i.e. spatially shared weights and spatial pooling. CNNs have shown remarkable success in various applications in the past few years, including image classification and

speech recognition (Li et al., 2019). Originally developed for computer vision tasks, CNNs have been recently adapted for various applications, including condition monitoring and fault diagnosis in industrial systems using vibration data. The convolutional layers involve the use of certain matrices, also known as kernel-size filters, which are convolved over the time-series raw data, extracting the meaningful features from the raw sequences. Afterwards, a constant bias is added to each convolution, followed by a maximum pooling or average pooling layer, which usually closes a block layer of CNNs. A graphic representation of convolutional operation is shown in Fig. 1.

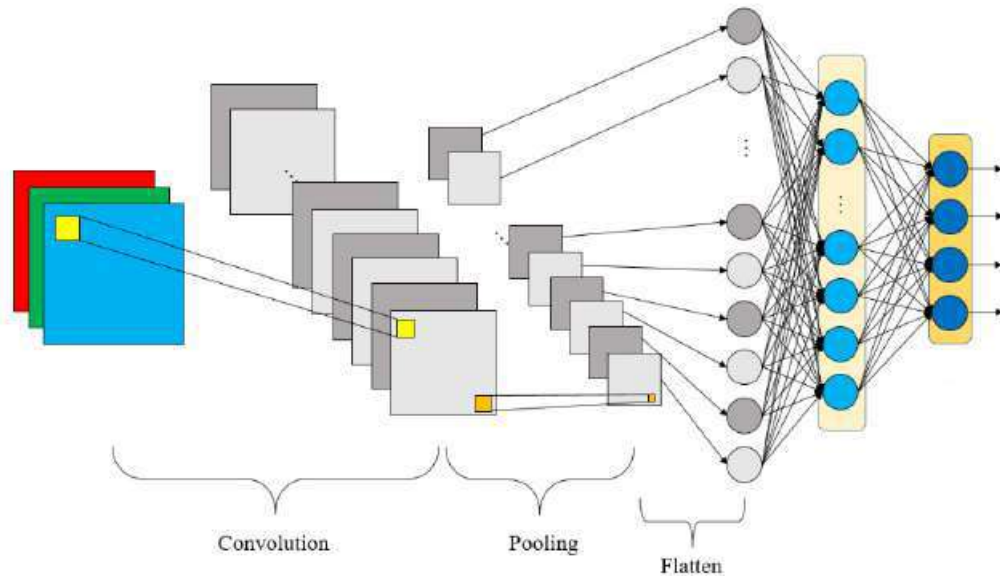


Figure 1: Convolution operation using a 2D-input, flattened at the last layer

The CNNs typically operate in 2D-data, even though convolutional 1D layers can also be defined. The use of 2D-data implies the information is input as a matrix convolved over the layers according to a mathematical expression. Given a tensor (or input image) I of dimensions $C \times H \times W$, where C is the number of channels, H is the number of tensor lines and W the number of tensor columns, be K a convolutional filter with dimensions $k_h \times k_w$, where k_h is the filter height and k_w is the filter width. In this case, the convolution operation is given by Eq. 1:

$$Out(N_i, C_{out,j}) = b(C_{out,j}) + \sum_{k=0}^{C_{in}-1} W(C_{out,j}, k) * I(N_i, k)$$

Where N_i is the batch size and C_{in} , C_{out} are the input and output channels, respectively. After each convolutional layer, a ReLU activation and 2D batch normalization are also executed on the data. In this paper, the use of the CNN for diagnosis of WT failures is based on the reconstruction error of the signal. The advantage of this approach is the possibility of unsupervised training, without the need for data labels. In order to do that, a CNN-autoencoder is designed, using transposed convolution layers in the decoder phase of the network. The reconstruction error used as anomaly metric is the mean squared error,

presented in Eq. 2:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (x_i - x_i')^2$$

3.2 Processing of the Time-Series using Short-Time Fourier Transform

As discussed in the previous section, the input to the CNNs consists of 2D-data, disposed in a square-matrix. For the CMS vibration dataset, the sensors distributed along the drivetrain provide time-series 1D signals, which need to be transformed for time-frequency domain. Indeed, the use of Fourier or Wavelet transforms translate the 1D into 2D signals, while preserving and extracting the main characteristics of the time-series. In this paper, the short-time Fourier transform (STFT) is used to realize this aim. The CMS data is sampled with $f_s = 25600 \text{ Hz}$, leading to a definition of a Hamming window with size 64. Further, it is chosen a size of 32x32 to the data input of CNNs, using the resize procedure of the PyTorch library. The implemented mathematical procedure is shown in Eq. 3:

$$S(t, f) = \sum_{n=-\infty}^{\infty} x(n) \cdot w(n-t) \cdot e^{-j2\pi fn}$$

Where $S(t, f)$ is the coefficient of the STFT in the time t and frequency f , $x(n)$ is the original signal in the time n , $w(n-t)$ is the window function centered in t and $e^{-j2\pi fn}$ is the Fourier kernel. The application of Eq. 3 to the original data converts the time-signal to a 2D-matrix, represented in gray-scale by the image in Fig. 2. The 2D-matrix represented in the right is able to be recognized by the CNN network.

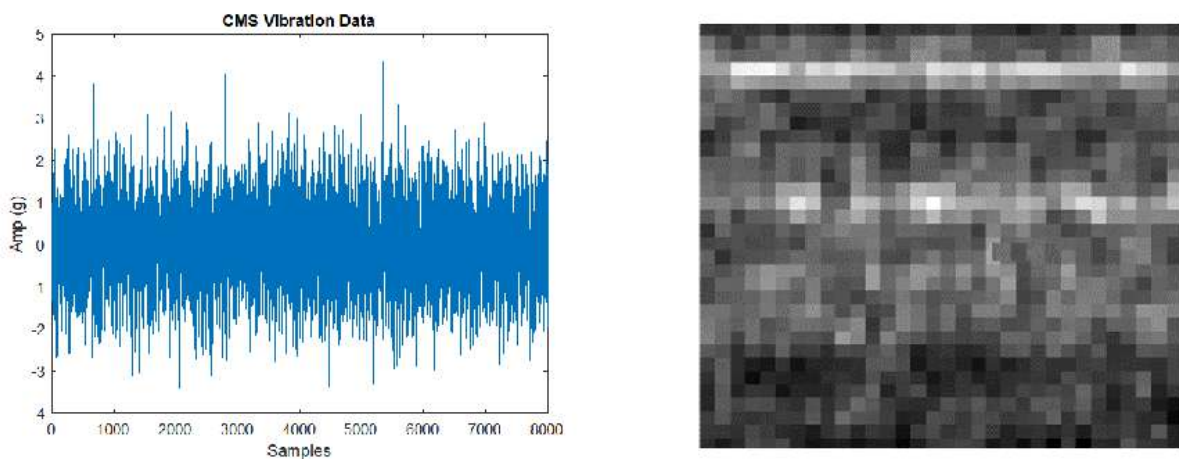


Figure 2: Transformation of time-series to image 2D-matrix

3.3 Architecture of the CNN Diagnosis Network

The CNN used in our diagnosis tool is composed by 8 convolutional layers and 2 fully-connected (FCs) layers, as the interface between the two CNN phases. Our objective is the enabling of anomaly detection and the obtaining of diagnosis without the need of labeled data. This means that the CNNs are

arranged in an autoencoder structure, whose network output try to reconstruct the data input. Therefore, the encoder part consists of 4 convolutional layers, followed by batch normalization and ReLU activation function. The number of channels is preserved through the network in 32 signals, consistent with the 32x32 image input. Further, it is chosen unitary padding and stride to the convolutional filters, which are set of size 3x3. The latent space consists in the two FC layers, which receive the encoder signal after flattening. The FCs reduce dimensionality until to 16 data points, that are followed by the decoder CNNs. The aim of this part of the network is to reconstruct the 32x32 input by using transposed convolutional layers, using the same filter size, stride and padding. The proposed architecture is summarized in Table 1.

Layer	Architecture
CNN-Encoder	Layer 1: CNN layer (Input = 3, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)
	Layer 2: Batch Norm. 2D
	Layer 3: ReLU activation function
	Layer 4: CNN layer (Input = 32, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)
	Layer 5: Batch Norm. 2D
	Layer 6: ReLU activation function
	Layer 7: CNN layer (Input = 32, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)
	Layer 8: Batch Norm. 2D
	Layer 9: ReLU activation function
	Layer 10: CNN layer (Input = 32, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)
	Layer 11: Batch Norm. 2D
	Layer 12: ReLU activation function.
	Layer 13: Flattening Layer (Input=16x16x32,Output=16*16*32)
	Layer 14: FC layer (Input = 16*16*32, Output = 256)
	Layer 15: FC layer (Input =256, Output=16)
	Layer 16: ReLU activation function
CNN-Decoder	Layer 17: Transposed CNN layer (Input = 32, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)
	Layer 18: Batch Norm. 2D
	Layer 19: ReLU activation function
	Layer 20: Transposed CNN layer (Input = 32, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)
	Layer 21: Batch Norm. 2D
	Layer 22: ReLU activation function
	Layer 23: Transposed CNN layer (Input = 32, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)
	Layer 24: Batch Norm. 2D
	Layer 25: ReLU activation function
Layer 26: Transposed CNN layer (Input = 32, Output = 32, Kernel Size = 3x3, Stride=1, Padding=1)	
Layer 27: Batch Norm. 2D	
Layer 28: ReLU activation function	
Layer 29: Regression layer (MSE loss)	

Table 1: Architecture of the proposed CNN

3.4 Utilized CMS Dataset and Monitored Wind Turbines

The CNN-based diagnosis tool has been used in a specific area from a commercial wind farm, composed of 25 wind turbines, with average rated power of 2 MW, located in the west of the state of Bahia,

Brazil. Details are protected by confidentiality issues. The WT's are monitored by several accelerometers along the different stages of the drivetrain. Sampling rate is set to 25600 Hz, adjustable through the procedure of synchronous sampling (B. Zhang et al., 2022). CMS collects data approximately every 4-hours, which can be changed if an anomalous event or trigger comes to happen. Database of WT's condition has been gathered for the last 3 years, appointing healthy and unhealthy machines along this time window. To proof the concept, we have chosen the case study of a maintenance carried out at the high-speed shaft (HSS) of a pre-determined WT. Time-series data from 2-years before the failure is utilized. It is worth to emphasize that, since the diagnosis tool uses reconstruction error (see Section 3.5), data from healthy conditions in the same wind farm are also used to feed the CNN network. For the HSS database, length of the time-series results in 8192 data points, transformed through STFT to 32x32 input matrices.

3.5 Failure diagnosis using the reconstruction error

Given the chosen 32x32 input, it should be reconstructed when passing through the trained CNN network with minimum loss. Further, by executing CNN training only on vibration data of healthy WT, the output of the network should indicate anomalous conditions if it is exposed to faulty input data. In a diagnosis tool, we must select reconstruction metrics that provide assurance of the failure detection. For this, we utilize a metric that captures the overall variation between healthy and faulty time-series, i.e., the mean absolute error (MAE), as shown in Eq. 4:

$$MAE = \frac{1}{m \cdot n} \sum_{i=1}^m \sum_{j=1}^n \|x_{ji} - x'_{ji}\| \quad (4)$$

Where m and n are the number of features in each sample, and x , x' are the encoder inputs and outputs, respectively. Therefore, the anomaly will be detected if the MAE surpasses a certain value. The threshold of failure condition must be obtained by using the $MAEs$ from healthy data. As we will see in Sec. 4.2, the extreme MAE value found for healthy time-series are employed to set this limit. It is important to observe that the obtained thresholds are specific for each wind farm (WF) and should be calculated by training the CNN in the healthy data from its own WT's. Indeed, the failure limits will be established through the histograms of $MAEs$ from healthy WT's, without recent failure occurrence (Jonas et al., 2022).

4. RESULTS

4.1 Diagnosis procedure

It is worth to note our diagnosis tool can be used with any accelerometer of the CMS, depending on what drivetrain component should be monitored. In the present paper, we will use the accelerometer of the output shaft. This was the chosen data because it is related to the failure registered in one of the analyzed WT's. Indeed, it is known from operation logs that the WT numbered as 11 (herein called WT11) presented a failure in its output shaft bearing. Operator relates the need for bearing replacement at the planetary stage of the dataset, demonstrating the tracking of the failure frequencies by conventional methods is not always effective, since the bearing defect actually happened in Stage 3. The CNN-based diagnosis tries to reproduce this result in a more effective way. In order to do that, the neural network is exposed to healthy

wind turbine data, from a neighbor wind turbine, numbered as 12 (herein called WT12). It has not shown in any failure during 12 months, utilized for training, which corresponds to a total of 2100 time-series of 8192 data points. The dataset split is executed using 70% for training and 30% for test. In addition, 20% of the training data is set as validation data, where 80% is completely used to update network weights. Backpropagation is used to update the network weights, with Adam optimization algorithm running over the mini-batches with size of 64 samples. Training occurs during 50 epochs, since after that there is no gain in network accuracy, according to the run of numerous trials. Results for the mean absolute error (MAE) are shown in Figure 3, for the WT12 healthy data. As one can see, the training loss stabilizes at around 0.0024,




Figure 3: Loss during training and reconstruction error during validation

while the MAE calculated on the validation dataset attains the maximum value around 0.18.

However, the conclusion about failure threshold needs to be mathematically defined using the histogram of maximum errors. In this case, Fig. 4 shows that the superior limit is set in 0.17, which will be used to evaluate failure in unhealthy data. Furthermore, Fig. 5 shows the visual reconstruction of 2D-input matrices generated by the STFT, according to the procedure outlined in Section 3.2. A heatmap is presented in the most right of the picture, showing the differences between the two STFT images.




Figure 4: Histogram of the test set reconstruction error, expressed using MAE




Figure 5: Input and reconstructed output matrices, represented in gray-scale. The heat map in the right emphasizes the reconstruction errors

After the validation and test set assessments, the diagnosis tool is ready to be feed with monitored WT data, to check for anomalous conditions in the drivetrain. Using the WT11 input data to the CNN tool, one obtains the reconstruction images showed in Fig. 6. As it is clearly observed, the fact WT11 is in anomalous conditions causes a worse reconstruction. Nonetheless, this needs to be numerically verified against the threshold of 0.17, defined previously. Results for the numerical verification can be plotted in a MAE graphic, shown in Fig. 7. It is noteworthy that there are more data points for the WT12, since all the data collected during monitoring was used, over approximately 2 years, changing the resolution of the plot compared to the one in right-side of Fig. 3. The increase in reconstruction error above the threshold of 0.17 is outstanding, attaining 0.4 units and demonstrating the failure of the WT11 drivetrain, in the high-speed third stage, from where data time-series are gathered.




Figure 6: Input and reconstructed output matrices, represented in gray-scale. The heat map in the right emphasizes the reconstruction errors, for monitored wind turbine data.




Figure 7: MAE reconstruction error for anomalous drivetrain of WT11

5. CONCLUSIONS

The present paper demonstrated the development of a new monitoring tool for WTs, completely based on a deep learning algorithm, earlier utilized for image recognition tasks. Indeed, the 1D time-series collected by CMS installed in commercial turbines is converted through the Short-Time Fourier Transform in 2D input matrices, which are placed in convolutional neural networks. The procedure uses the raw data, without any frequency tracking of drivetrain specific anomalies. This has been proven to enable the following of WT defects by analyzing the whole time-frequency information, avoiding the misleading of wrong diagnosis by local vibration analysis. Furthermore, unlike other deep learning approaches, our diagnosis tool does not rely on labeled data and can be used since the first day of a wind farm operation, given it uses an unsupervised training procedure. Finally, as future work, we plan to focus in alternative diagnosis networks, mainly dedicated to attention and long-short term mechanisms, which can be used to capture the temporal dependence of the CMS samples.

REFERENCES

Bechhoefer, E., Van Hecke, B., & He, D. (2013). Processing for Improved Spectral Analysis.

Ben Ali, J., Saidi, L., Harrath, S., Bechhoefer, E., & Benbouzid, M. (2018). Online automatic diagnosis of wind turbine bearings progressive degradations under real experimental conditions based on unsupervised machine learning. *Applied Acoustics*, 132, 167–181.
<https://doi.org/10.1016/j.apacoust.2017.11.021>

Berghout, T., & Benbouzid, M. (2022). A Systematic Guide for Predicting Remaining Useful Life with Machine Learning. In *Electronics (Switzerland)* (Vol. 11, Issue 7). MDPI.
<https://doi.org/10.3390/electronics11071125>

Chen, B., Matthews, P. C., & Tavner, P. J. (2013). Wind turbine pitch faults prognosis using a-priori knowledge-based ANFIS. *Expert Systems with Applications*, 40(17), 6863–6876.
<https://doi.org/10.1016/j.eswa.2013.06.018>

CWRU. (2013). Case Western Reserve University (CWRU) Bearing Data Center.

Dao, C., Kazemtabrizi, B., & Crabtree, C. (2019). Wind turbine reliability data review and impacts on levelised cost of energy. In *Wind Energy* (Vol. 22, Issue 12, pp. 1848–1871). John Wiley and Sons Ltd.
<https://doi.org/10.1002/we.2404>

Deisenroth, M. P., Faisal, A. A., & Ong, C. S. (2020). *Mathematics for Machine Learning*. Cambridge University Press. <https://books.google.com.br/books?id=pbONxAEACAAJ>

Do, M. H., & Söffker, D. (2021). State-of-the-art in integrated prognostics and health management control for utility-scale wind turbines. *Renewable and Sustainable Energy Reviews*, 145. <https://doi.org/10.1016/j.rser.2021.111102>

EPBR. (2022). Eólica chega a 21 GW de capacidade instalada no Brasil. <https://epbr.com.br/eolica-chega-a-21-gw-de-capacidade-instalada-no-brasil/>

Finke, T., Krämer, M., Morandini, A., Mück, A., & Oleksiyuk, I. (2021). Autoencoders for unsupervised anomaly detection in high energy physics. *Journal of High Energy Physics*, 2021(6), 161. [https://doi.org/10.1007/JHEP06\(2021\)161](https://doi.org/10.1007/JHEP06(2021)161)

Guo, J., Lu, S., Zhai, C., & He, Q. (2018). Automatic bearing fault diagnosis of permanent magnet synchronous generators in wind turbines subjected to noise interference. *Measurement Science and Technology*, 29(2). <https://doi.org/10.1088/1361-6501/aa92d6>

Guo, L., Li, N., Jia, F., Lei, Y., & Lin, J. (2017). A recurrent neural network based health indicator for remaining useful life prediction of bearings. *Neurocomputing*, 240, 98–109. <https://doi.org/10.1016/j.neucom.2017.02.045>

Jonas, S., Anagnostos, D., Brodbeck, B., & Meyer, A. (2022). Vibration fault detection in wind turbines based on normal behaviour models without feature engineering.

Kankar, P. K., Sharma, S. C., & Harsha, S. P. (2011). Rolling element bearing fault diagnosis using wavelet transform. *Neurocomputing*, 74(10), 1638–1645. <https://doi.org/10.1016/j.neucom.2011.01.021>

Leite, G. de N. P., Araújo, A. M., & Rosas, P. A. C. (2018). Prognostic techniques applied to maintenance of wind turbines: a concise and specific review. In *Renewable and Sustainable Energy Reviews* (Vol. 81, pp. 1917–1925). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2017.06.002>

Li, X., Zhang, W., & Ding, Q. (2019). Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering and System Safety*, 182, 208–218. <https://doi.org/10.1016/j.res.2018.11.011>

Liu, Z., & Zhang, L. (2020). A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings. In *Measurement: Journal of the International Measurement Confederation* (Vol. 149). Elsevier B.V. <https://doi.org/10.1016/j.measurement.2019.107002>

Malhi, A., Yan, R., & Gao, R. X. (2011). Prognosis of defect propagation based on recurrent neural networks. *IEEE Transactions on Instrumentation and Measurement*, 60(3), 703–711. <https://doi.org/10.1109/TIM.2010.2078296>

Meng, H., Lien, F. S., Glinka, G., & Geiger, P. (2019). Study on fatigue life of bend-twist coupling wind turbine blade based on anisotropic beam model and stress-based fatigue analysis method. *Composite Structures*, 208, 678–701. <https://doi.org/10.1016/J.COMPSTRUCT.2018.10.032>

MFPT. (2016). Society for Machinery Failure Prevention Technology.

Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Morello, B., Zerhouni, N., & Varnier, C. (2012). PRONOSTIA: An Experimental Platform for Bearings Accelerated Degradation Tests.

Song, L., Wang, H., & Chen, P. (2018). Vibration-Based Intelligent Fault Diagnosis for Roller Bearings in Low-Speed Rotating Machinery. *IEEE Transactions on Instrumentation and Measurement*, 67(8), 1887–1899. <https://doi.org/10.1109/TIM.2018.2806984>

Song, Y., Hyun, S., & Cheong, Y. G. (2021). Analysis of autoencoders for network intrusion detection†. *Sensors*, 21(13). <https://doi.org/10.3390/s21134294>

- Soualhi, A., Medjaher, K., & Zerhouni, N. (2015). Bearing health monitoring based on hilbert-huang transform, support vector machine, and regression. *IEEE Transactions on Instrumentation and Measurement*, 64(1), 52–62. <https://doi.org/10.1109/TIM.2014.2330494>
- Strömbergsson, D., Marklund, P., Berglund, K., & Larsson, P. E. (2020). Bearing monitoring in the wind turbine drivetrain: A comparative study of the FFT and wavelet transforms. *Wind Energy*, 23(6), 1381–1393. <https://doi.org/10.1002/we.2491>
- VDI. (2009). VDI 3834 Blatt 1 - Wind turbines with gearbox.
- Verstraete, D., Ferrada, A., Droguett, E. L., Meruane, V., & Modarres, M. (2017). Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings. *Shock and Vibration*, 2017. <https://doi.org/10.1155/2017/5067651>
- Wang, C., Jiang, W., Yang, X., & Zhang, S. (2021). Rul prediction of rolling bearings based on a dcae and cnn. *Applied Sciences (Switzerland)*, 11(23). <https://doi.org/10.3390/app112311516>
- Wu, C., Feng, F., Wu, S., Jiang, P., & Wang, J. (2019). A method for constructing rolling bearing lifetime health indicator based on multi-scale convolutional neural networks. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 41(11). <https://doi.org/10.1007/s40430-019-2010-6>
- Wu, C., Jiang, P., Ding, C., Feng, F., & Chen, T. (2019). Intelligent fault diagnosis of rotating machinery based on one-dimensional convolutional neural network. *Computers in Industry*, 108, 53–61. <https://doi.org/10.1016/j.compind.2018.12.001>
- Wymore, M. L., Van Dam, J. E., Ceylan, H., & Qiao, D. (2015). A survey of health monitoring systems for wind turbines. In *Renewable and Sustainable Energy Reviews* (Vol. 52, pp. 976–990). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2015.07.110>
- Zhang, S., Zhang, S., Wang, B., & Habetler, T. G. (2020). Deep Learning Algorithms for Bearing Fault Diagnostics - A Comprehensive Review. In *IEEE Access* (Vol. 8, pp. 29857–29881). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2020.2972859>
- Zhao, Z., Li, T., Wu, J., Sun, C., Wang, S., Yan, R., & Chen, X. (2020). Deep learning algorithms for rotating machinery intelligent diagnosis: An open source benchmark study. *ISA Transactions*, 107, 224–255. <https://doi.org/10.1016/j.isatra.2020.08.010>
- Zimroz, R., Bartelmus, W., Barszcz, T., & Urbanek, J. (2014). Diagnostics of bearings in presence of strong operating conditions non-stationarity - A procedure of load-dependent features processing with application to wind turbine bearings. *Mechanical Systems and Signal Processing*, 46(1), 16–27. <https://doi.org/10.1016/j.ymssp.2013.09.010>

Integrating Causal Engineering and Machine Learning for Fault Detection in Wind Turbines Using SCADA Data

Gabriel de Souza Pereira Gomes¹, Daniel Carrijo⁴, Rogério Andrade Flauzino³, Luciano Freire¹
Luís Henrique Meazzini Sepulvene¹, Iony Patriota², João Marcelo Aguiar Pereira¹
Lucas Fritoli³ Bernardo Loureiro⁵

Genesis Pesquisa e Desenvolvimento¹

Tecnix²

Treetech Sistemas Digitais³

Universidade de São Paulo⁴

Rapid Canvas Inc.⁵

gabriel.gomes@genesis-dataculture.com

daniel.carrijo@treetech.com.br

RESUMO

Este artigo apresenta uma nova estrutura para a detecção de falhas em subsistemas de turbinas eólicas usando uma abordagem indireta com dados SCADA. A estrutura visa reduzir os custos de operação e manutenção (O&M) ao permitir a manutenção preditiva por meio da detecção precoce de falhas. O estudo foca na previsão da temperatura da gearbox, um parâmetro crítico que influencia a saúde das turbinas eólicas. Um estimador causal foi usado para identificar as principais variáveis SCADA que impactam a temperatura da gearbox, e vários modelos de aprendizado de máquina foram avaliados. O Random Forest demonstrou o melhor desempenho, prevendo com precisão a temperatura da caixa de engrenagens e identificando possíveis defeitos. A estrutura proposta foi validada usando dados de cinco turbinas eólicas, destacando sua aplicabilidade prática e eficácia na redução de custos de manutenção e melhoria da confiabilidade operacional. Os resultados ressaltam a importância de aproveitar técnicas avançadas de análise de dados e modelagem causal para aumentar a eficiência dos sistemas de energia renovável e apresentam os benefícios de se combinar engenharia, inteligência artificial e estatística.

Palavras-chaves:

Detecção de falhas; Manutenção preditiva; Turbinas eólicas; SCADA; Causalidade.

ABSTRACT

This paper presents a novel framework for detecting faults in wind turbine subsystems using an indirect approach with SCADA data. The framework aims to reduce operation and maintenance (O&M) costs by enabling predictive maintenance through early fault detection. The study focuses on predicting gearbox temperature, a critical parameter influencing wind turbine health. A causal estimator was used to identify

key SCADA variables impacting gearbox temperature, and several machine learning models were evaluated. The Random Forest Regressor demonstrated the best performance, accurately predicting gearbox temperature and identifying potential defects. The proposed framework was validated using data from five wind turbines, highlighting its practical applicability and effectiveness in reducing maintenance costs and improving operational reliability. The findings underscore the importance of leveraging advanced data analytics and causal modeling techniques to enhance the efficiency of renewable energy systems.

Keywords:

Fault detection; Predictive maintenance; Wind turbines; SCADA; Causality.

1. INTRODUÇÃO

In order to align with global sustainable development goals, enhance energy security, and reduce dependency on fossil fuels, the share of renewable sources in the global energy matrix has experienced a noticeable increase in recent years. Among renewable sources, wind energy generation stands as the second fastest-growing source, only behind solar power. In 2022, the insertion of wind power into the global energy matrix increased by 14 %. However, in order to achieve the Net Zero Emissions scenario by 2050, an annual growth rate of at least 17 % for this energy source is required. To facilitate such growth, collaborative efforts across various sectors are essential. One of the key aspects to contribute to the expansion of wind energy is the reduction of operation and maintenance costs associated with wind farms

Furthermore, additional attention has been given to O&M methods due to the fact that a significant portion of wind turbines are ending their 20-years life cycle, requiring more maintenance interventions. Moreover, new wind farms are being installed in remote areas, affecting the accessibility and thus amplifying the associated O&M. Fault detection methods play a crucial role in mitigating O&M costs and minimizing WT downtime. By identifying faults before they manifest, these methods enable the implementation of predictive maintenance actions. Moreover, this approach effectively reduces the risks of subsequent damages and contributes to the proper planning of WT operation.

Fault detection methods available in the literature for wind turbines can be categorized into two distinct classes that relates to the way faults are detect: direct approach and indirect approach. In the direct approach, the time to failure (TTF) is calculated using sensor data. For that, a model is trained in both sensor (input) and failure data (output) and learns to map the sensor data pattern to a time to failure for a subsystem. This method has many advantages as it provides a remaining time to failure. On the other hand, to get accurate results lots of failure data is needed.

Indirect approaches rely on models to simulate wind turbine and its subsystems. Instead of calculating the time to failure, the model tries to predict some know variable and measures the error between prediction and real value. If the error starts to increase an anomaly is identified and a possible defect is found. The advantage of this method is that it can built using just SCADA data. Nevertheless, not all anomalies will be associated with failures and it's not a simple task to define which variables will be used

as input and output.

This paper focuses on indirect approaches and proposes a framework to overcome their problems. To demonstrate the usability of the framework, a model was created to predict the gearbox temperature for four wind turbines. To select the features to use as input to the model, a causal estimator was used to map the causal relation between SCADA variables and the predicted variable.

The main contributions of this paper are a framework for creating models for the application of the indirect approach that can be used for detecting failures in many wind turbine subsystems without using any additional data besides SCADA, and an example of application of the framework in wind turbines from a Brazilian company.

2. ESTADO DA ARTE/ FUNDAMENTAÇÃO TEÓRICA

Wind turbines consist of four primary components: the rotor, the nacelle, the tower, and the foundation. The former two components encompass multiple subsystems, which are presented in [Figure 1](#). The rotor comprises the hub, the blades, and the pitch system, which is responsible for controlling the rotation of the blades. The nacelle, on the other hand, is composed of the main shaft, gearbox, and generator. The main shaft's role is to transmit the kinetic energy from the rotor to the gearbox, which, in turn, adjusts the speed to an appropriate level for input into the generator through the high speed shaft (HSS). Another integral component of the nacelle is the yaw system, responsible for the horizontal shift of the wind turbine.

The main objects of study in this paper are the gearbox and the generator, subsystems that belong to the nacelle, whose typical structure is detailed in [Figure 2](#). The principal role of a gearbox lies in the modulation of speed levels to suit the requirements of the generator. As input, it receives low speed and high torque and is responsible for the conversion of this speed into a higher magnitude, making it suitable for the generator. This process is essential to facilitate the subsequent transformation of the mechanical energy into electrical energy, that is performed by the generator ([Bhardwaj et al., 2019](#)).




Fig. 1 Structure of a generic Wind Turbine. From: (Wang et al., 2017)




Fig. 2 Details of the Nacelle Interior Structure. From: (Sonne et al., 2015)

Wind turbines function in harsh external environments and are vulnerable to different types of stresses, including electrical disruptions, corrosion, fatigue, mechanical overloads, lightning strikes, among others. As a result, the subsystems of wind turbines are highly subjected to failures ([Badihi et al., 2022](#); [Teng et al., 2016](#)). In [Badihi et al. \(2022\)](#), the authors establish a classification for potential faults in a wind turbine based on their level of severity, i.e., based on the consequences of each failure. The highest level of severity encompasses situations that lead to a complete shutdown of turbine operations. The intermediate level relates to issues that partially compromise the operational capacity of the wind turbine and require urgent maintenance actions. The least severe category considers faults often associated with sensors.

Among the most severe failures, the authors have highlighted faults linked to the gearbox and the generator. For the gearbox, these faults can manifest as malfunctions in the lubrication system, failed gears, or bearings. On the other hand, for the generator, failures in the generator speed sensor or power sensor can result in control malfunctions, which may subsequently lead to issues such as overheating, overspeed, and generator faults. Moreover, based on this survey study, both gearboxes and generators are identified as subsystems of WT with longer down-times and lower reliability levels ([Badihi et al., 2022](#)).

Several studies can be found in literature regarding gearbox and generator condition monitoring and failure analysis. Most studies rely on the analysis of vibration signals to detect the failures. Another common procedure consists of using signal processing techniques to decompose the measured signals in order to extract patterns and characteristics. Finally, most of the studies apply ML methods in order to analyze the features extracted from the signals. Examples of studies with all or some of the previous characteristics can be found in [Teng et al. \(2016\)](#), [Zhang et al. \(2021\)](#), [Wang et al. \(2019\)](#), [Hu et al. \(2019\)](#), [Chen et al. \(2016\)](#), [Yang et al. \(2013\)](#), [Jin et al. \(2022\)](#).

3. MÉTODO DO ESTUDO

The first step towards building a model for an indirect approach is selecting which subsystem will be modeled. For this study, we selected the gearbox because it is a critical component inside a wind turbine with a high downtime associated with failure (more than 6 months) and a high cost associated.

After selecting the subsystem, we need to select the variables to use as predictors and the target. To achieve this, we will use causal learning to learn a causal graph. A causal graph is an acyclic graph that represents causality between variables and its strength. Many algorithms can calculate causality between variables under certain mathematical assumptions. For our work, we used LiNGAM. LiNGAM (Linear Non-Gaussian Acyclic Model) is a method used in the field of causal discovery from observational data. Unlike traditional correlation or regression analysis, which primarily captures associations between variables, LiNGAM aims to uncover the underlying causal structure among variables. LiNGAM assumes that the relationships between variables can be represented by a linear model. In a linear model, the value of a

dependent variable is a linear combination of independent variables plus an error term. Another mathematical assumption is that the error terms (noise) in the model are non-Gaussian. This assumption is crucial because, under Gaussian noise, it is often impossible to uniquely identify the direction of causal relationships. Non-Gaussianity allows LiNGAM to identify the direction of causality. LiNGAM assumes that the causal structure is a Directed Acyclic Graph (DAG), meaning that there are no cycles in the causal relationships, i.e., a variable cannot cause itself directly or indirectly through a series of other variables.

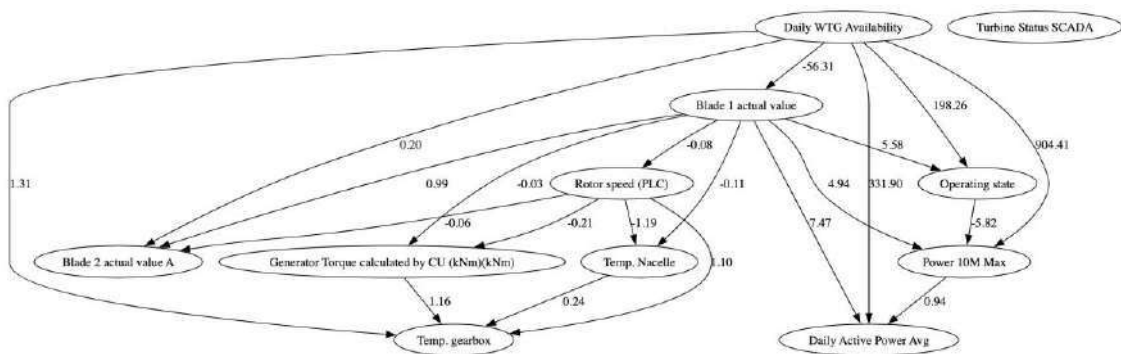
1. **Model Specification:** Specify the linear model for the variables. The model can be written as:

$$X = BX + e$$

where X is a vector of observed variables, B is a matrix of coefficients representing the direct causal effects between variables, and e is a vector of error terms.

2. **Estimation:** Estimate the matrix **B** and the error terms **e** from the observed data. This involves solving for the coefficients that best explain the observed data under the non-Gaussianity and acyclicity assumptions.
3. **Causal Ordering:** Determine the causal ordering of the variables. This involves finding an ordering such that each variable is independent of its predecessors in the order, given its parents in the DAG.
4. **Validation:** Validate the identified causal structure using various statistical tests or **additional domain knowledge** to ensure that the discovered relationships make sense and are robust.

Initially, we apply the LiNGAM algorithm to all variables we have available for the model. After it, we refine it, selecting variables with bigger strength in links. Then we run the process again until we got an acyclic graph that can be validated by domain knowledge. After some runs, we got the graph bellow:



It shows that the temperature of the gearbox is mainly caused by 4 types of variables, that are:

- **Rotor Speed:** the speed of the rotor of the turbine.

- **Blade Actual Value:** the angle of the blade.
- **Generator Torque:** the torque of the generator calculated.
- **Daily WTG availability:** the daily availability of the turbine.

From an engineering perspective, it makes sense. The main factor that causes the temperature in the gearbox is the friction between its components. According to Feng et al. (2013), the kinetic energy delivered by the gearbox to the generator can be physically expressed as:

$$E = P_{GB}T_i + Q_{GB}T_i$$

where P_{GB} represents the output kinetic energy that is delivered to the generator and Q_{GB} represents the heat loss. Both variables are multiplied by the operation duration, represented as T_i . Furthermore, considering that the gearbox efficiency is η_{GB} , the kinetic energy from (1) can also be represented by:

$$E = \frac{1}{\eta_{GB}}P_{GB}T_i$$

Combining both equations results in:

$$Q_{GB}T_i = \left(\frac{1}{\eta_{GB}} - 1\right)P_{GB}T_i$$

that represents the heat loss in function of the equipment's efficiency and the delivered power. However, the heat loss Q_{GB} can also be expressed as:

$$Q_{GB} = U_{GB}\Delta T$$

where U_{GB} is the compound heat transfer coefficient and ΔT represents the temperature change in the gearbox, in relation to the nacelle temperature. Combining equations once again with the previous equation, results in:

$$\Delta T = \frac{1}{U_{GB}}\left(\frac{1}{\eta_{GB}} - 1\right)P_{GB}$$

where the temperature change in the equipment is proportional to the delivered power. Finally, according to Feng2013 the output kinetic energy from the gearbox is approximately equal to the output energy from the generator for a same period of time, therefore, the equation above might also be represented as:

$$\Delta T \approx \frac{1}{U_{GB}}\left(\frac{1}{\eta_{GB}} - 1\right)P_{Gen}$$

Consequently, for a constant level of efficiency, the gearbox and generator power outputs are proportional to the temperature rise of the gearbox. According to Feng2013, a similar relationship can be derived considering the rotational kinetic energy of the gearbox, as:

$$E = \frac{1}{2} I_{GB} \omega_{GB}^2$$


I_{GB} is the gearbox moment of inertia and ω_{GB} represents the WT's rotor velocity. Combining this equation with the previous equations results in:

$$E = \frac{1}{2} I_{GB} \omega_{GB}^2 \approx \frac{1}{\eta_{GB}} P_{GB} T_i = \Delta T \frac{U_{GB}}{1 - \eta_{GB}} T_i$$

$$\Delta T = \frac{I_{GB}}{2 T_i U_{GB}} \omega_{GB}^2 (1 - \eta_{GB})$$

Considering that $\frac{I_{GB}}{2 T_i U_{GB}}$ is a constant, the relation $\Delta T \omega_{GB}$ is proportional to the efficiency reduction $1 - \eta_{GB}$.

This nearly linear relationship between the rotor speed and the temperature was observed in the dataset employed in this paper. We can also verify it using the data, plotting the difference between gearbox temperature and nacelle temperature versus rotor speed squared.

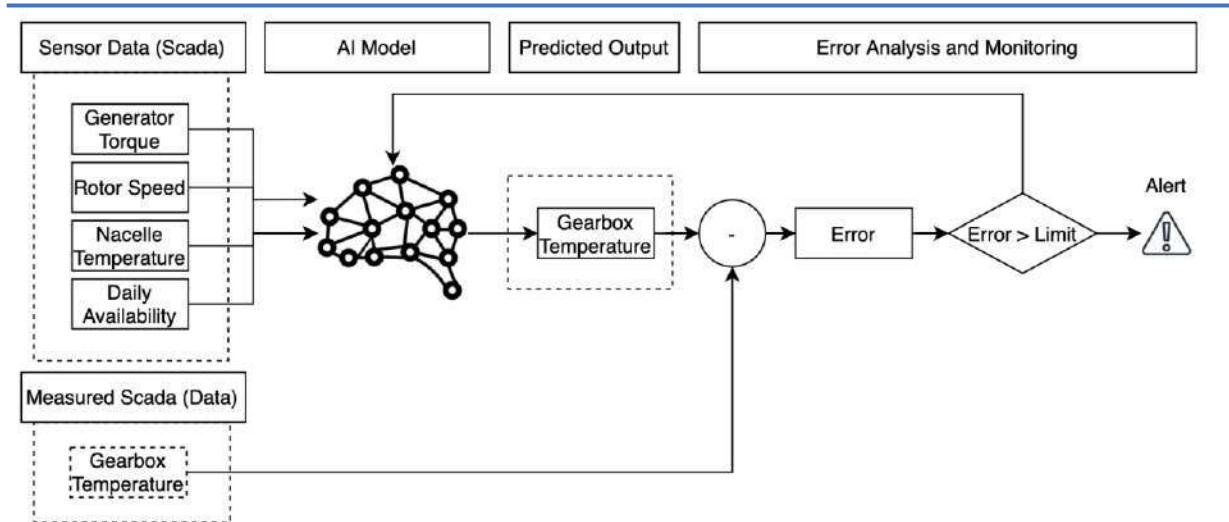


As we can see, the relation is nearly linear, showing that the graph built by LiNGAM and validated by domain knowledge is probably correct.

Considering all of that, now we can define our input vector X and output vector y .

- X = Generator Torque, Rotor Speed, Nacelle Temperature, Daily Availability
- Y = Gearbox Temperature

Figure below represents solution's schema.



Once we have our topology, we will work on data processing and model training.

Data Catalog

The data used for this work is presented in table below:

Number of Turbines	Number of Variables	Initial Date	Final Date	Sampling Frequency
5	162	01-05-2023	24-05-2024	10 min

Data Processing

The data acquired from the SCADA was 10 minute each sampled. For our analysis we can resample it to a lower frequency once we want to detect slow degradation failures in early stage. Therefore, data was resampled to 4 Hours using a mean window.

After it, data was divided into two groups: train and test. 9 months of data were used for training and 3 months of data were used for test.

Outliers from train were removed using the following rule:

$$X'_i = \begin{cases} \text{Lower Bound}_i & \text{if } X_i < \text{Lower Bound}_i \\ X_i & \text{if } \text{Lower Bound}_i \leq X_i \leq \text{Upper Bound}_i \\ \text{Upper Bound}_i & \text{if } X_i > \text{Upper Bound}_i \end{cases}$$

Where X'_i is the new value for sample i and Lower Bound and Upper Bound are calculated as:

$$\text{Lower Bound}_i = Q1_i - 3 \times IQR_i$$

$$\text{Upper Bound}_i = Q3_i + 3 \times IQR_i$$

Where IQR is the interquartile distance. The method was fit and applied in training data and only applied (not fit) in test data in order to avoid data leakage and overfitting.



5 models were applied to select the best one. Table below present the result for them:

Model	Train MAPE	Validation MAPE	Test MAPE
LGBMRegressor	0.012	0.0154	0.036
XGBRegressor	0.012	0.0155	0.039
RandomForestRegressor	0.010	0.0150	0.035
LinearRegression	0.016	0.041	0.046

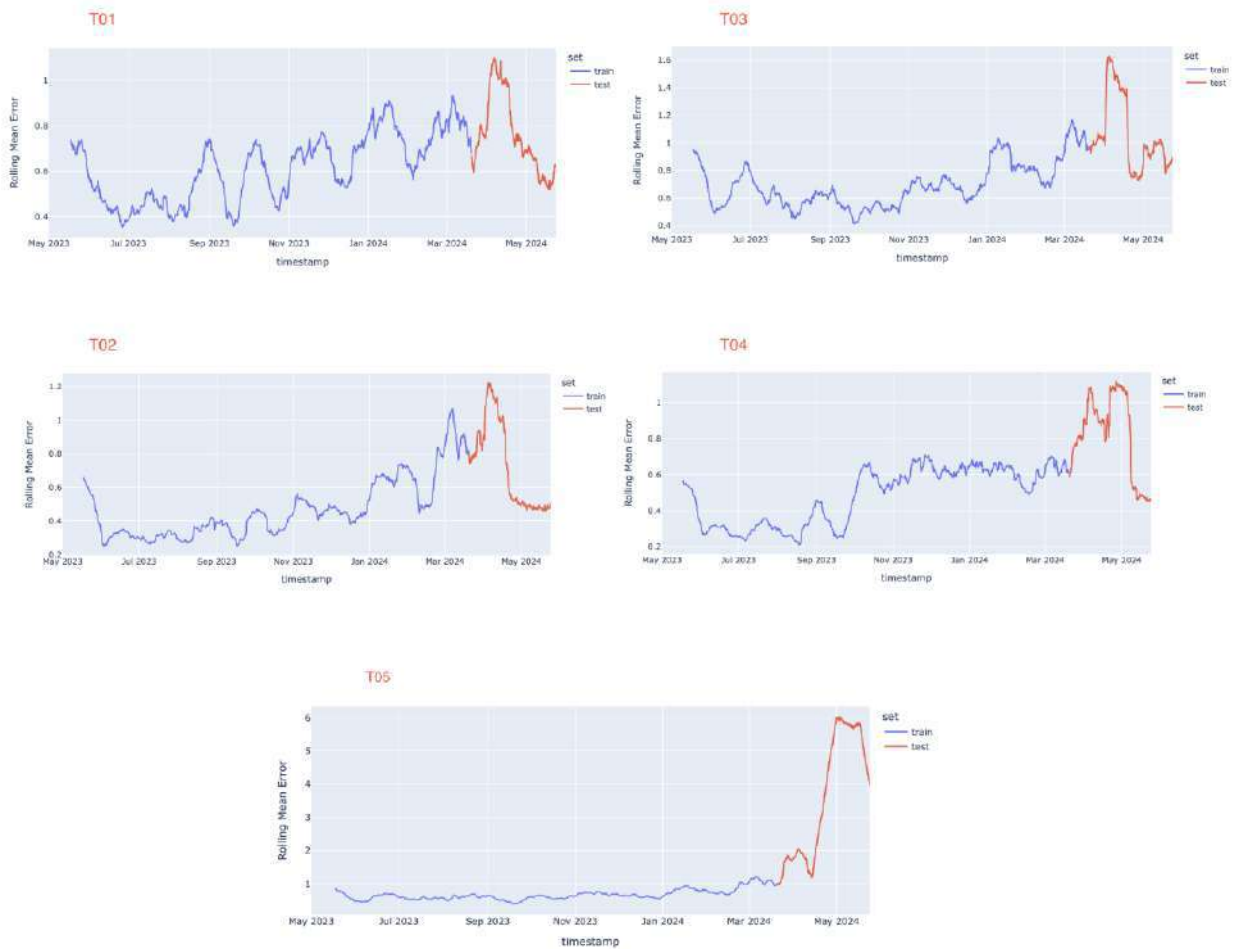
Hyperparameters for the models were tuned using Bayesian search throughout optuna library. Validation data was used for time series cross validation.

Random Forest obtained best MAPE for the data provided.

Selecting Random Forest Regressor as the model for our task, we can plot the error for train and test per entity:



As we can see, some turbines have a bigger test error than others. This can be an indicative that this turbine has a problem. Figure below shows the plots over time.



As can be seen Turbine T05 present an error different than the remaining which can point to a defect. The other turbines have a stable error.

5. ANÁLISE E DISCUSSÃO DOS RESULTADOS

The primary objective of this study was to develop a framework for detecting faults in wind turbine subsystems using an indirect approach with SCADA data. The focus was on predicting the gearbox temperature, a critical parameter linked to the operational health of wind turbines. The results obtained from applying this framework demonstrated its effectiveness and provided valuable insights into the performance and reliability of the turbines under study.

Five different machine learning models were evaluated for their ability to predict gearbox temperature:

- **LGBMRegressor:** Train MAPE: 0.012, Validation MAPE: 0.0154, Test MAPE: 0.036

- **XGBRegressor:** Train MAPE: 0.012, Validation MAPE: 0.0155, Test MAPE: 0.039
- **RandomForestRegressor:** Train MAPE: 0.010, Validation MAPE: 0.0150, Test MAPE: 0.035
- **LinearRegression:** Train MAPE: 0.016, Validation MAPE: 0.041, Test MAPE: 0.046

The Random Forest Regressor exhibited the best performance across all metrics, making it the model of choice for this study. It achieved the lowest Mean Absolute Percentage Error (MAPE) on both the training and test sets, indicating its robustness and accuracy in predicting the gearbox temperature.

The Random Forest Regressor's superior performance can be attributed to its ability to handle complex interactions between variables and its robustness against overfitting. By analyzing the errors for each turbine individually, it was evident that some turbines exhibited higher prediction errors than others. Specifically, Turbine T05 showed a significantly higher test error, suggesting the presence of a potential defect.

The error analysis over time revealed that while most turbines maintained stable prediction errors, Turbine T05 deviated noticeably. This deviation was consistent across various time intervals, indicating an underlying issue that required attention. The stability of errors in other turbines validated the model's reliability and accuracy in normal operational conditions.

A crucial part of the framework involved identifying causal relationships between SCADA variables and gearbox temperature using the LiNGAM algorithm. The key predictors identified were:

- **Rotor Speed**
- **Blade Actual Value**
- **Generator Torque**
- **Daily WTG Availability**

From an engineering perspective, these relationships made sense. The gearbox temperature is primarily influenced by the friction between its components, which in turn is affected by the rotor speed, blade angle, and generator torque. The daily availability of the wind turbine also plays a role, as it reflects the operational status and workload of the turbine. The nearly linear relationship between rotor speed and gearbox temperature observed in the dataset further validated the causal graph generated by LiNGAM. This consistency between the model's findings and engineering principles reinforced the credibility of the framework.

6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

The successful application of the framework in detecting anomalies using only SCADA data has significant practical implications. It provides a cost-effective and efficient method for early fault detection in wind turbines, potentially reducing maintenance costs and minimizing downtime. The ability to detect anomalies

early allows for timely maintenance interventions, thereby extending the operational life of the turbines and ensuring continuous energy production.

While the current framework proved effective, there are several avenues for future research:

1. **Model Refinement:** Further refining the model to enhance its accuracy and robustness across different wind turbine subsystems.
2. **Expanded Application:** Applying the framework to other components such as the nacelle, rotor, and tower to develop a comprehensive fault detection system for wind turbines.
3. **Real-time Implementation:** Integrating the model into real-time monitoring systems to provide continuous fault detection and predictive maintenance alerts.
4. **Advanced Causal Discovery Techniques:** Exploring other causal discovery techniques and incorporating domain-specific knowledge to improve the causal model's accuracy.

In conclusion, this study successfully demonstrated the feasibility and effectiveness of an indirect fault detection framework using SCADA data for wind turbines. The framework's ability to predict gearbox temperature accurately and identify potential defects provides a valuable tool for enhancing predictive maintenance strategies. By reducing operational costs and improving the reliability of wind turbine operations, this framework contributes to the broader goal of increasing the share of renewable energy in the global energy matrix. The findings of this study underscore the importance of leveraging advanced data analytics and causal modeling techniques to drive innovation and efficiency in the renewable energy sector.

The journey towards more reliable and cost-effective wind turbine maintenance is ongoing, and this study represents a significant step forward. Future research and continued collaboration between academia and industry will be crucial in refining and expanding the framework, ultimately contributing to the sustainability and resilience of the global energy system

REFERÊNCIAS

I. E. Agency. Wind. 2023. URL <https://www.iea.org/energy-system/renewables/wind>.

J. An and S. Cho. Variational autoencoder based anomaly detection using reconstruction probability. 2015. URL <https://api.semanticscholar.org/CorpusID:36663713>.

H. Badihi, Y. Zhang, B. Jiang, P. Pillay, and S. Rakheja. A comprehensive review on signal-based and model-based condition monitoring of wind turbines: Fault diagnosis and lifetime prognosis. *Proceedings of the IEEE*, 110(6):754–806, 2022. doi: 10.1109/JPROC.2022.3171691.

U. Bhardwa j, A. Teixeira, and C. G. Soares. Reliability prediction of an offshore wind turbine gearbox. *Renewable Energy*, 141: 693–706, 2019. ISSN 0960-1481. doi: <https://doi.org/10.1016/j.renene.2019.03.136>. URL <https://www.sciencedirect.com/science/article/pii/S0960148119304574>.

J. Chen, J. Pan, Z. Li, Y. Zi, and X. Chen. Generator bearing fault diagnosis for wind turbine via empirical wavelet transform using measured vibration signals. *Renewable Energy*, 89:80–92, 2016. ISSN 0960-1481. doi: <https://doi.org/10.1016/j.renene.2015.12.010>. URL <https://www.sciencedirect.com/science/article/pii/S0960148115305140>.

Y. Feng, Y. Qiu, C. Crabtree, H. Long, and P. Tavner. Monitoring wind turbine gearboxes. *Wind Energy*, 16, 07 2013. doi: 10.1002/we.1521.

M. F. Howland and J. O. Dabiri. Wind farm modeling with interpretable physics-informed machine learning. *Energies*, 12(14), 2019. ISSN 1996-1073. doi: 10.3390/en12142716. URL <https://www.mdpi.com/1996-1073/12/14/2716>.

W. Hu, H. Chang, and X. Gu. A novel fault diagnosis technique for wind turbine gearbox. *Applied Soft Computing*, 82:105556, 2019. ISSN 1568-4946. doi: <https://doi.org/10.1016/j.asoc.2019.105556>. URL <https://www.sciencedirect.com/science/article/pii/S1568494619303369>.

G. Jiang, P. Xie, H. He, and J. Yan. Wind turbine fault detection using a denoising autoencoder with temporal information. *IEEE/ASME Transactions on Mechatronics*, 23(1):89–100, 2018. doi: 10.1109/TMECH.2017.2759301.

X. Jin, H. Pan, C. Ying, Z. Kong, Z. Xu, and B. Zhang. Condition monitoring of wind turbine generator based on transfer learning and one-class classifier. *IEEE Sensors Journal*, 22(24): 24130–24139, 2022. doi: 10.1109/JSEN.2022.3218054.

G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang. Physics-informed machine learning. *Nature Reviews Physics*, 3(6):422–440, 6 2021. doi: 10.1038/s42254-021-00314-5. URL <https://doi.org/10.1038/s42254-021-00314-5>.

K. Kashinath, M. Mustafa, A. Albert, J. L. Wu, C. Jiang, S. Esmaeilzadeh, K. Azizzadenesheli, R. Wang, A. Chattopadhyay, A. Singh, A. Manepalli, D. Chirila, R. Yu, R. Walters, B. White, H. Xiao, H. A. Tchelepi, P. Marcus, A. Anandkumar, P. Hassanzadeh, and Prabhat. Physics-informed machine learning: case studies for weather and climate modelling. *Philosophical Transactions of the Royal Society A*, 379(2194): 20200093, 2021. doi: 10.1098/rsta.2020.0093. URL <http://doi.org/10.1098/rsta.2020.0093>.

S. Learn. sklearn linear model ridge. 2023. URL https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.Ridge.html.

Y. Li, W. Jiang, G. Zhang, and L. Shu. Wind turbine fault diagnosis based on transfer learning and convolutional autoencoder with small-scale data. *Renewable Energy*, 171:103–115, 2021. ISSN 0960-1481. doi: <https://doi.org/10.1016/j.renene.2021.01.143>. URL <https://www.sciencedirect.com/science/article/pii/S0960148121001567>.

G. C. McDonald. Ridge regression. *WIREs Computational Statistics*, 1(1):93–100, 2009. doi: <https://doi.org/10.1002/wics.14>. URL <https://wires.onlinelibrary.wiley.com/doi/abs/10.1002/wics.14>.

F. Perez-Sanjines, C. Peeters, T. Verstraeten, J. Antoni, A. Nowé, and J. Helsen. Fleet-based early fault detection of wind turbine gearboxes using physics-informed deep learning based on cyclic spectral coherence. *Mechanical Systems and Signal Processing*, 185:109760, February 15 2023. ISSN 0888-3270. doi: 10.1016/j.ymssp.2022.109760. URL <https://www.sciencedirect.com/science/article/pii/S0888327022008287>.

B. Scholkopf, R. C. Williamson, A. Smola, J. Shawe-Taylor, and J. Platt. Support vector method for novelty detection. In S. Solla, T. Leen, and K. Müller, editors, *Advances in Neural Information Processing Systems*, volume 12. MIT Press, 1999. URL https://proceedings.neurips.cc/paper_files/paper/1999/file/8725fb777f25776ffa9076e44fcd776-Paper.pdf.

L.Schröder, N.K.Dimitrov, D.R.Verelst, and J. A. Sørensen. Using transfer learning to build physics-informed machine learning models for improved wind farm monitoring. *Energies*, 15(2), 2022. ISSN 1996-1073. doi: 10.3390/en15020558. URL <https://www.mdpi.com/1996-1073/15/2/558>.

M. Sonne, J. Frandsen, and J. Hattel. Comparison of residual stresses in sand and chill casting of ductile cast iron wind turbine main shafts. *IOP Conference Series: Materials Science and Engineering*, 84, 06 2015. doi: 10.1088/1757-899X/84/1/012025.

W. Teng, X. Ding, X. Zhang, Y. Liu, and Z. Ma. Multi-fault detection and failure analysis of wind turbine gearbox using complex wavelet transform. *Renewable Energy*, 93:591–598, 2016. ISSN 0960-1481. doi: <https://doi.org/10.1016/j.renene.2016.03.025>. URL <https://www.sciencedirect.com/science/article/pii/S0960148116302099>.

diagnosis of wind turbine planetary gearbox: A review. *Mechanical Systems and Signal Processing*, 126:662–685, 2019. ISSN 0888-3270. doi: <https://doi.org/10.1016/j.ymssp.2019.02.051>. URL <https://www.sciencedirect.com/science/article/pii/S0888327019301426>.

W. Xu, J. Jang-Jaccard, A. Singh, Y. Wei, and F. Sabrina. Improving performance of autoencoder-based network anomaly detection on nsl-kdd dataset. *IEEE Access*, 9:140136–140146, 2021. doi: 10.1109/ACCESS.2021.3116612.

W. Yang, P. Tavner, and R. Court. An online technique for condition monitoring the induction generators used in wind and marine turbines. *Mechanical Systems and Signal Processing*, 38(1):103–112, 2013. ISSN 0888-3270. doi: <https://doi.org/10.1016/j.ymssp.2012.03.002>. URL <https://www.sciencedirect.com/science/article/pii/S0888327012000799>. Condition monitoring of machines in non-stationary operations.

N. Ye and Q. Chen. An anomaly detection technique based on a chi-square statistic for detecting intrusions into information systems. *Quality and Reliability Engineering International*, 17(2):105–112, 2001. doi: 10.1002/qre.392. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0035271352&doi=10.1002%2fqre.392&partnerID=40&md5=5fe04bca87409b8b0ac9216502dfec04>. Cited by: 182.

S. Yin, G. Wang, and H. R. Karimi. Data-driven design of robust fault detection system for wind turbines. *Mechatronics*, 24(4):298–306, 2014. ISSN 0957-4158. doi: <https://doi.org/10.1016/j.mechatronics.2013.11.009>. URL <https://www.sciencedirect.com/science/article/pii/S0957415813002298>. Vibration control systems.

A. Vidhya. Lasso and Ridge regression a comprehensive guide in python (updated 2023). 2023. URL <https://www.analyticsvidhya.com/blog/2017/06/a-comprehensive-guide-for-linear-ridge-and-lasso-regression/> and generalizability. *PRX Energy*, 2: