



16-17 Agosto / 23
PLATAFORMA DIGITAL BWP

Categoria 3

O&M

Utilização de *Transfer Learning* no Monitoramento de Temperatura de Transformadores de Aeroogeradores

Catarina Gomes, Nathianne Andrade, Osmar Alexandre, Renata Takeshita, Rodrigo Queiroz

Delfos I. M.

catarina.gomes@delfosim.com, nathianne.andrade@delfosim.com, osmar.alexandre@delfosim.com,
renata.takeshita@delfosim.com, rodrigo.queiroz@delfosim.com

RESUMO

A utilização de modelos de aprendizado de máquina aplicados no contexto de previsão de falhas em turbinas eólicas se mostra vantajoso, especialmente em relação a custos de operação e manutenção dos ativos. No entanto, desafios como a baixa qualidade ou a falta de dados para a construção desses modelos podem se tornar obstáculos para a adoção desse método. Nesse sentido, as técnicas de *transfer learning* têm se mostrado eficazes para lidar com essas adversidades. Assim, este estudo apresenta um caso de aprimoramento de um modelo de rede neural artificial destinado ao monitoramento da temperatura do transformador do aerogerador, por meio da aplicação de técnicas de *transfer learning*.

Palavras-chaves:

Aprendizado de máquina, Manutenção de aerogeradores, Transferência de aprendizado

ABSTRACT

Machine learning techniques applied in the context of wind turbine failure prediction proves to yield advantages, specifically in terms of optimizing operational and maintenance costs. Nevertheless, challenges such as inadequate data quality or data scarcity can affect the widespread adoption of these methods. *Transfer learning* techniques have proven effective in mitigating these challenges. This study presents a case where an artificial neural network model intended for monitoring the temperature of the wind turbine transformer is enhanced through the application of *transfer learning* techniques.

Keywords:

Machine Learning, Wind Turbine Maintenance, *Transfer Learning*

1. INTRODUÇÃO

1.1. CONTEXTO GERAL

O uso de modelos de predição na indústria eólica tem impactos positivos na redução de downtimes nos aerogeradores, que por sua vez podem ser causados por falhas mecânicas e eletrônicas não previstas. Segundo Zhang (2018), os modelos de predição de falhas em aerogeradores vêm contribuindo

significativamente na otimização dos custos de operação e manutenção dos parques eólicos, uma vez que permitem aos operadores planejarem melhor as atividades de manutenção.

Modelos de predição em aerogeradores geralmente usam os dados disponíveis nos sistemas SCADA (*Supervisory Control And Data Acquisition*), instalados na maioria dos parques eólicos. Esses sistemas são instalados visando o monitoramento de performance do aerogerador, com potencial de serem utilizados, ainda, na predição de falhas através de uma abordagem baseada em dados históricos e aprendizado de máquina (ZHANG, 2018).

O emprego de técnicas de aprendizado de máquina para monitoramento de condições operacionais de aerogeradores enfrentam as dificuldades práticas de dependerem da qualidade, da diversidade, da natureza dos dados de entrada (*inputs*) e do período de treino selecionado. Atualmente, é um desafio o emprego de tais técnicas em parques eólicos novos, ou mesmo em grandes componentes recém-instalados, devido à ausência de histórico de dados para esses ativos. Contudo, o aprendizado de máquina tem avançado rapidamente nas últimas décadas e novas técnicas têm sido desenvolvidas para superar os desafios anteriormente citados. Dentre essas novas técnicas, há o *transfer learning*, também conhecido como aprendizado por transferência, que permite remover a dependência de dados históricos ao tomar como base modelos já existentes para componentes semelhantes com dados treinados e aprendidos.

O presente artigo se dedica a explorar um caso de estudo nos quais as técnicas de *transfer learning* foram essenciais para lidar com a falta de dados históricos. A partir de modelos-base, treinados para indivíduos com dados suficientes, aplicaram-se técnicas de *transfer learning* para gerar modelos adequados para o monitoramento de indivíduos que não dispunham de dados suficientes para um treinamento tradicional de Redes Neurais Artificiais (RNA). Por fim, o desempenho dos modelos calibrados com *transfer learning* foi comparado com os modelos treinados sem essa técnica.

1.2. REDES NEURAIS ARTIFICIAIS E PREDIÇÃO DE FALHAS

Uma Rede Neural Artificial (RNA) é uma estrutura de dados complexa baseada em computação paralela que simula o comportamento biológico de aprendizagem em uma rede neural humana. As RNAs para monitoramento de séries temporais têm sido uma abordagem amplamente empregada para lidar com problemas não-lineares complexos de forma eficaz, sem necessidade de conhecimento especializado (ZHANG, 2018).

A grande maioria das arquiteturas de redes neurais artificiais consistem em uma camada inicial, na qual há entrada de informação (*variáveis input*); uma camada de normalização (usada para normalização do dado), seguida por uma ou mais camadas intermediárias e, por fim, uma camada de saída onde é obtida a resposta da rede (*variável output*). Cada camada é composta por um conjunto de neurônios artificiais, em que uma conexão entre dois neurônios é estabelecida e caracterizada por um peso, que determina a importância da entrada do neurônio anterior para a saída do neurônio seguinte.

A calibração dos pesos presentes em cada camada de uma RNA é conduzida através de técnicas de aprendizado supervisionado via algoritmos do tipo *backpropagation*, que minimizam, em um processo iterativo, o erro entre o valor predito e o valor esperado para todas as amostras de dados contida nos dados de treino.

No contexto da predição de falhas em aerogeradores, um modelo bem treinado pode ser utilizado para replicar comportamentos considerados saudáveis, aprendidos durante a fase de treino, para uma variável monitorada (*output*) durante diversas situações de operação. As anomalias de comportamento são identificadas quando um desvio entre o valor da variável monitorada e o valor predito pelo modelo de RNA, para as mesmas condições de operação, é detectado. A partir da detecção da anomalia e da intensidade do desvio é possível tomar decisões baseadas em dados e planejar ações preventivas e/ou corretivas

junto à causa raiz da anomalia, sendo possível, em muitos casos, que todo esse processo aconteça antes da ocorrência de uma falha funcional mais grave que leve, por exemplo, à necessidade da troca do componente.

1.3. TRANSFER LEARNING

No contexto da predição de falhas, diversos fatores podem influenciar na performance do modelo da RNA, tais como: a qualidade, a diversidade, a natureza dos dados *inputs* e o período de treino selecionado. No entanto, a necessidade de grandes conjuntos de dados rotulados para treinar modelos de alta qualidade é um desafio, sendo agravado quando há disponibilidade limitada de dados ou quando a rotulagem dos dados requer um esforço humano considerável.

Para superar essa dificuldade, o *transfer learning* tem sido explorado, pois permite aproveitar o conhecimento adquirido em uma tarefa de aprendizado anterior e aplicá-lo a uma tarefa relacionada, mesmo que existam diferenças nos conjuntos de dados, oferecendo vantagens em termos de desempenho e eficiência. O estudo do *transfer learning* é motivado pelo fato de que as pessoas podem aplicar de maneira inteligente o conhecimento aprendido anteriormente para resolver novos problemas mais rapidamente ou com melhores soluções (Pan e Yang, 2010).

Pesquisas recentes na área de geração de energia eólica têm explorado a aplicação do *transfer learning*, oferecendo insights sobre seu potencial e benefícios. Estudos como o de Hu et al. (2016) investigaram a aplicação de redes neurais profundas com *transfer learning* para previsão da velocidade do vento em parques localizados em regiões distintas dos parques empregados durante o treinamento das redes neurais. Já Oh et al. (2022) propuseram um modelo de previsão de geração eólica para um parque recém instalado utilizando uma RNA do tipo *multilayer perceptron* e técnicas de *transfer learning* utilizando como base os dados operacionais de um segundo parque com mais anos em operação.

2. OBJETIVO

O objetivo do presente trabalho é avaliar o desempenho de técnicas de *transfer learning* para superar os desafios no aprendizado de comportamentos não presentes no conjunto de dados de treinamento no contexto de predição de falhas em aerogeradores. Os casos de estudo serão descritos de forma mais extensa na seção 3.1.

Adicionalmente, a execução do trabalho foi estruturado em etapas que podem ser representadas pelas perguntas específicas abaixo:

- Como definir um candidato ao emprego do *transfer learning* e os períodos do treinamento?
- Como decidir a parametrização do *transfer learning*?
- Qual a diferença de desempenho entre o modelo de referência e o modelo com *transfer learning*?

3. MATERIAIS E MÉTODOS

3.1. MATERIAIS

No presente estudo, foram coletados dados brutos provenientes de sistemas do tipo SCADA instalados nos parques eólicos nos quais o estudo foi conduzido. Além disso, foram empregadas linguagens de programação como SQL (*Structured Query Language*) para a extração dos dados e Python para o

tratamento dos dados e treinamento do modelo. Também foi utilizado um dashboard personalizado para visualização e análise do comportamento das variáveis.

3.2. CASO DE ESTUDO

O candidato ao uso de técnicas de *transfer learning* selecionado para o presente estudo é a temperatura do transformador de um aerogerador chamado AEG01. Para este aerogerador, simulou-se um cenário onde existiriam apenas registros operacionais de 3 meses. Nesse período de treinamento, não aconteceram eventos de aquecimento do transformador devido à potência reativa para esse aerogerador e as temperaturas ambiente não foram tão altas quanto os máximos anuais. Portanto, o monitoramento estava sujeito a gerar alarmes positivos quando acontecessem condições de operação com aquecimento devido à potência reativa ou maiores temperaturas ambiente. Dado que ambas condições de operação citadas podem ser consideradas “normais”, a sua identificação como uma anomalia no transformador consiste em um alarme falso positivo.

Outro aerogerador, aqui chamado de AEG02, registrou, em seu período mais extenso de treinamento, eventos de aquecimento do transformador devido à potência reativa e temperaturas ambientes condizentes com as máximas temperaturas anuais. Por isso, durante o período de monitoramento, essa situação não foi apontada como uma anomalia detectada, uma vez que essa situação fez parte do treinamento. Portanto, o caso de estudo consiste em promover a transferência do conhecimento do evento de aquecimento devido à potência reativa do modelo de monitoramento do AEG02 (modelo base) para o modelo de monitoramento do AEG01 (modelo com *transfer learning*). A fim de mensurar as vantagens do emprego de *transfer learning* o desempenho do modelo com *transfer learning* foi comparado com o modelo de referência do AEG01 em períodos com e sem aquecimento devido à potência reativa. Adicionalmente, informa-se que os aerogeradores AEG01 e AEG02 são do mesmo modelo e possuem, aproximadamente, o mesmo tempo em operação.

3.3. METODOLOGIA

3.3.1. MODELO BASE E MODELO DE REFERÊNCIA

Para o treinamento do modelo base e do modelo de referência, o processo preditivo aplicado à temperatura do transformador explorado no estudo de caso deste artigo pode ser sintetizado em 5 etapas, conforme mostrado na Figura 1 abaixo.

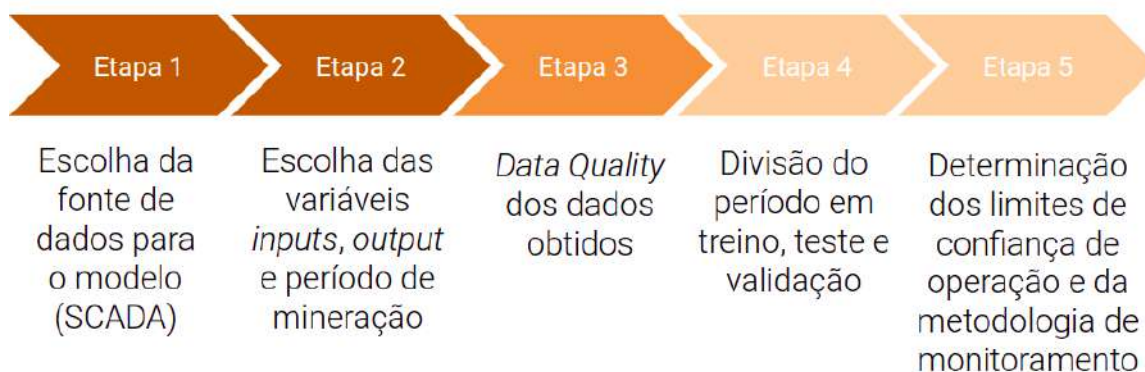


Figura 1 - Etapas do processo de treino do modelo preditivo

Fonte: Os próprios autores, 2023.

Seguindo o processo da Figura 1 acima, a Etapa 1 envolve a definição de que os dados das séries temporais são provenientes dos sistemas SCADA instalados nos parques monitorados. Na Etapa 2, são escolhidas séries temporais 10-minutais da temperatura do transformador (*output*) e das variáveis de entrada (*inputs*) definidas por estudos prévios especificamente para o monitoramento dessa temperatura estudada. O *Data Quality* (Etapa 3) envolve a limpeza dos dados, que inclui a eliminação de dados espúrios e filtros de momentos de indisponibilidade do aerogerador e de momentos de aquecimento transiente. Na Etapa 4 é feita a divisão do *dataset* em treino, teste e validação: são selecionados aproximadamente 64% de dados para treino da RNA e 16% para validação. Os 20% restantes dos dados são separados para teste, etapa na qual é feito o treino e calculado o Erro Quadrático Médio (EQM) para mensurar a performance do modelo.

Finalmente, na Etapa 5, é estabelecido o *threshold* ou limite de operação aprendido, que é definido como o erro máximo permitido da predição, calculada a partir de um percentil pré-estabelecido da distribuição do erro (obtido na etapa do teste do modelo). O critério para identificação de anomalia, considerada uma operação não saudável, é quando o desvio entre o valor da variável monitorada e o valor predito para aquela condição operacional é maior do que o *threshold*. Utilizou-se a mediana diária do erro de predição para cálculo do percentual de pontos acima do *threshold*. Por fim, foi estipulado como critério para geração de alarme um percentual de 50% pontos acima do *threshold* nos últimos 7 dias.

3.3.2. MODELO COM *TRANSFER LEARNING*

Na execução do modelo com *transfer learning*, seguiu-se um processo semelhante aos outros modelos. No entanto, inicialmente reaproveitou-se a mesma arquitetura (número de camadas, número de neurônios artificiais e funções de ativação) do modelo base. Os pesos obtidos no modelo base foram utilizados como critério de inicialização dos pesos da nova rede neural. Após isso, segue-se com a classificação das camadas em camadas flexíveis e camadas rígidas, onde as primeiras podem ser re-otimizadas em uma etapa posterior, e as segundas, não. Essa escolha foi conduzida interativamente através de uma abordagem *data-driven* e considerando ainda o conhecimento técnico acumulado da arquitetura de rede neural supracitada. O número de épocas empregadas nesta etapa é cerca de 30% do total de épocas necessárias para o treinamento do modelo base ou do modelo de referência, consistindo, portanto, numa etapa muito mais rápida em termos computacionais.

Após a inicialização da estrutura base da nova rede neural, uma segunda etapa de otimização foi conduzida nas camadas pré-selecionadas (camadas flexíveis) para se ajustarem aos novos dados.

4. RESULTADOS E DISCUSSÕES

4.1. SELEÇÃO DO CANDIDATO A *TRANSFER LEARNING*

A Figura 2 expõe a distribuição dos conjuntos de dados de todas as variáveis de entrada (*inputs*) utilizadas para treinar o modelo base do AEG02 (12 meses de dados) e o modelo de referência do AEG01 (3 meses de dados). Nota-se que o conjunto de dados do AEG01 não possui amostras de temperatura ambiente abaixo de 25°C nem de potência reativa acima de 0,1 kVAR, o que fundamenta a hipótese de que o modelo de referência do AEG01 deve gerar alarmes positivos falsos caso essas condições ocorram.

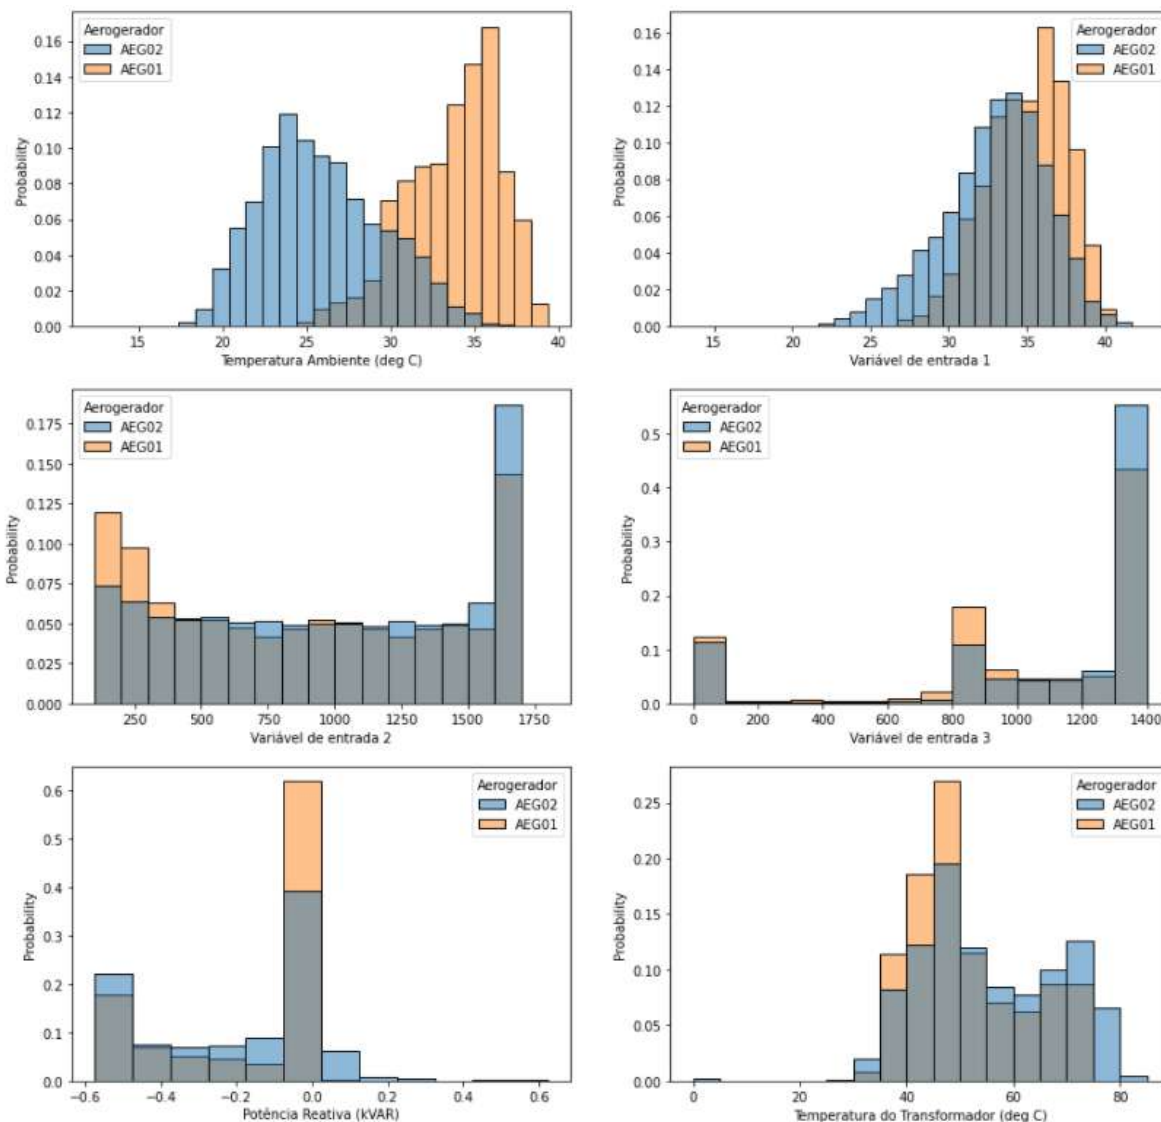


Figura 2 - Comparação entre as distribuições das variáveis de entrada para treinamento dos aerogeradores AEG01 e AEG02

Fonte: Os próprios autores, 2023.

4.2. PARAMETRIZAÇÃO DO *TRANSFER LEARNING*

Conforme descrito no item 3.1 do caso de estudo, foram selecionados dois aerogeradores do mesmo fabricante, localizados na mesma região, para a realização dos experimentos e geração dos resultados. Foram desenvolvidos três modelos distintos para a previsão de falhas: um modelo base para o *transfer learning*, um modelo de referência e um modelo com aplicação do *transfer learning*, tendo a temperatura do transformador como variável de saída. É importante ressaltar que o modelo base foi desenvolvido para o aerogerador AEG02, enquanto os demais modelos foram desenvolvidos para o aerogerador AEG01.

O modelo base de RNA foi treinado por um período de um ano, abrangendo os meses M0 a M12, utilizando o conjunto de dados do aerogerador AEG02, a fim de capturar as variações sazonais das variáveis de entrada. Esse treinamento resultou em um modelo mais preciso e serviu como base para o modelo de *transfer learning*. Para o modelo de referência, também foi utilizado um modelo de RNA, porém o conjunto de dados disponível para o treinamento abrange apenas os meses M12, M13 e M14. Por fim, o modelo de

transfer learning partiu do modelo base e realizou a transferência de conhecimento usando os dados do AEG01 nos meses M12, M13 e M14, ou seja, no mesmo período de treinamento do modelo de referência.

4.3. COMPARAÇÃO DE DESEMPENHO DO MODELO COM *TRANSFER LEARNING* E DO MODELO DE REFERÊNCIA

A partir da figura 3, que ilustra o modelo base, pode-se observar o cálculo do erro (em preto) entre as temperaturas medidas (em vermelho) e as temperaturas calculadas pelo modelo de predição (em verde). Também é apresentado o limite aceitável de operação da turbina (*threshold*) em laranja, o qual indica a detecção de possíveis falhas quando o erro entre as temperaturas excede esse limite, de acordo com as regras de detecção estabelecidas no item 3.3.1. Ao avaliar o modelo base ao longo de um ano e meio, abrangendo os meses M12 a M30, pode-se concluir que o modelo obteve sucesso em aprender o comportamento de operação da turbina AEG02, uma vez que apresenta um erro mínimo abaixo do limite aceitável durante o período de avaliação, compreendido entre os meses M15 e M30.

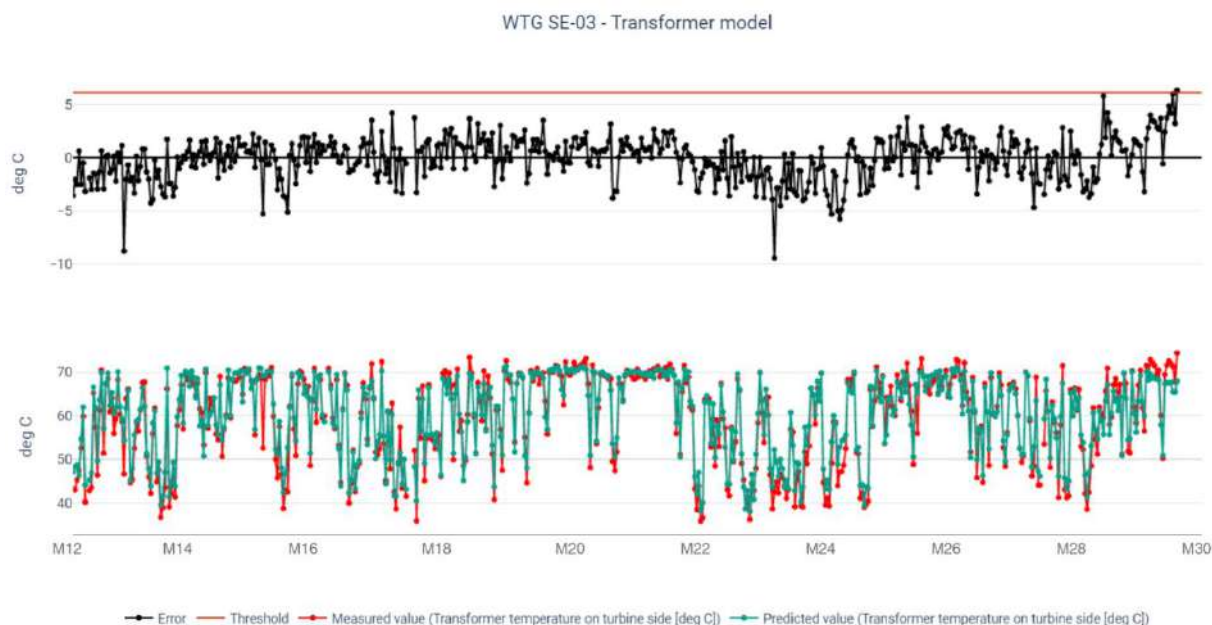


Figura 3 - Linha do tempo de avaliação do modelo base da AEG02

Fonte: Os próprios autores, 2023.

Ao analisar o modelo de referência (sem *transfer learning*) para a temperatura do transformador do aerogerador AEG01, durante o mesmo intervalo de tempo, observou-se uma maior incerteza. Isso ocorreu devido ao fato de que o erro entre as temperaturas ultrapassou o limite aceitável em várias ocasiões, resultando em falsos positivos, como apresentado na Figura 4.

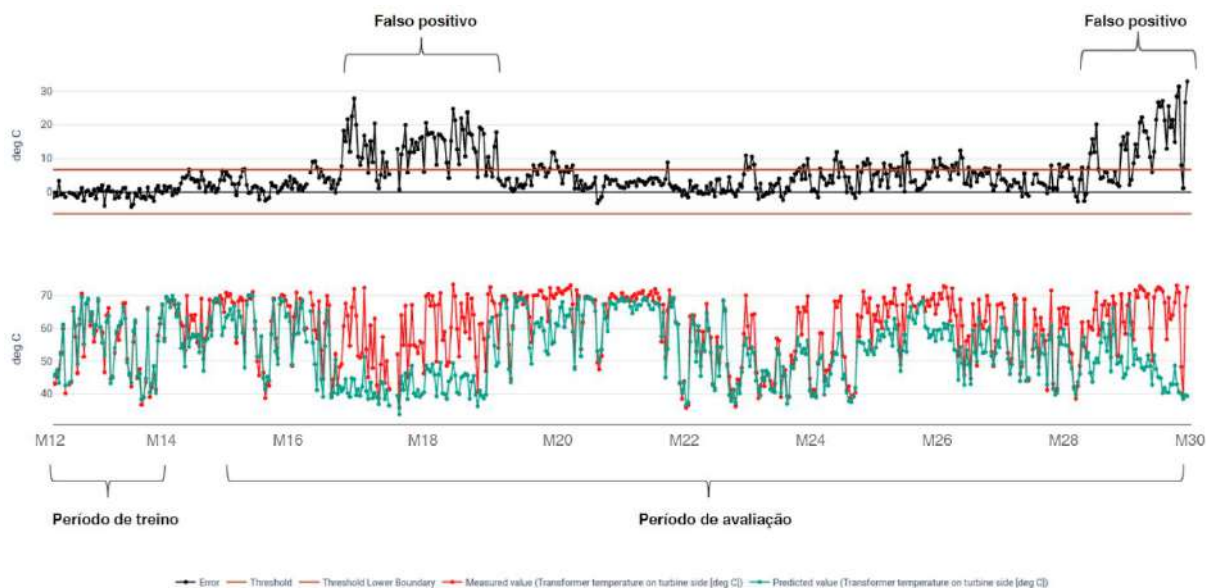


Figura 4 - Linha do tempo de avaliação do modelo de referência (sem *transfer learning*) da AEG01

Fonte: Os próprios autores, 2023.

Ao analisar as variáveis de entrada (*inputs*) do modelo de referência, foi observada uma alteração nas condições das variáveis de entrada de potência reativa e temperatura ambiente durante o período de avaliação, o que resultou em baixa precisão. A Figura 5 apresenta uma comparação entre a distribuição dos dados de entrada no treinamento do modelo de referência (em laranja) e a distribuição dos dados de entrada durante o primeiro período de falsos positivos, que ocorreu entre os meses M16 e M19. Nesse período, foram observadas temperaturas ambiente mais baixas e potências reativas mais altas do que as observadas durante o treinamento.

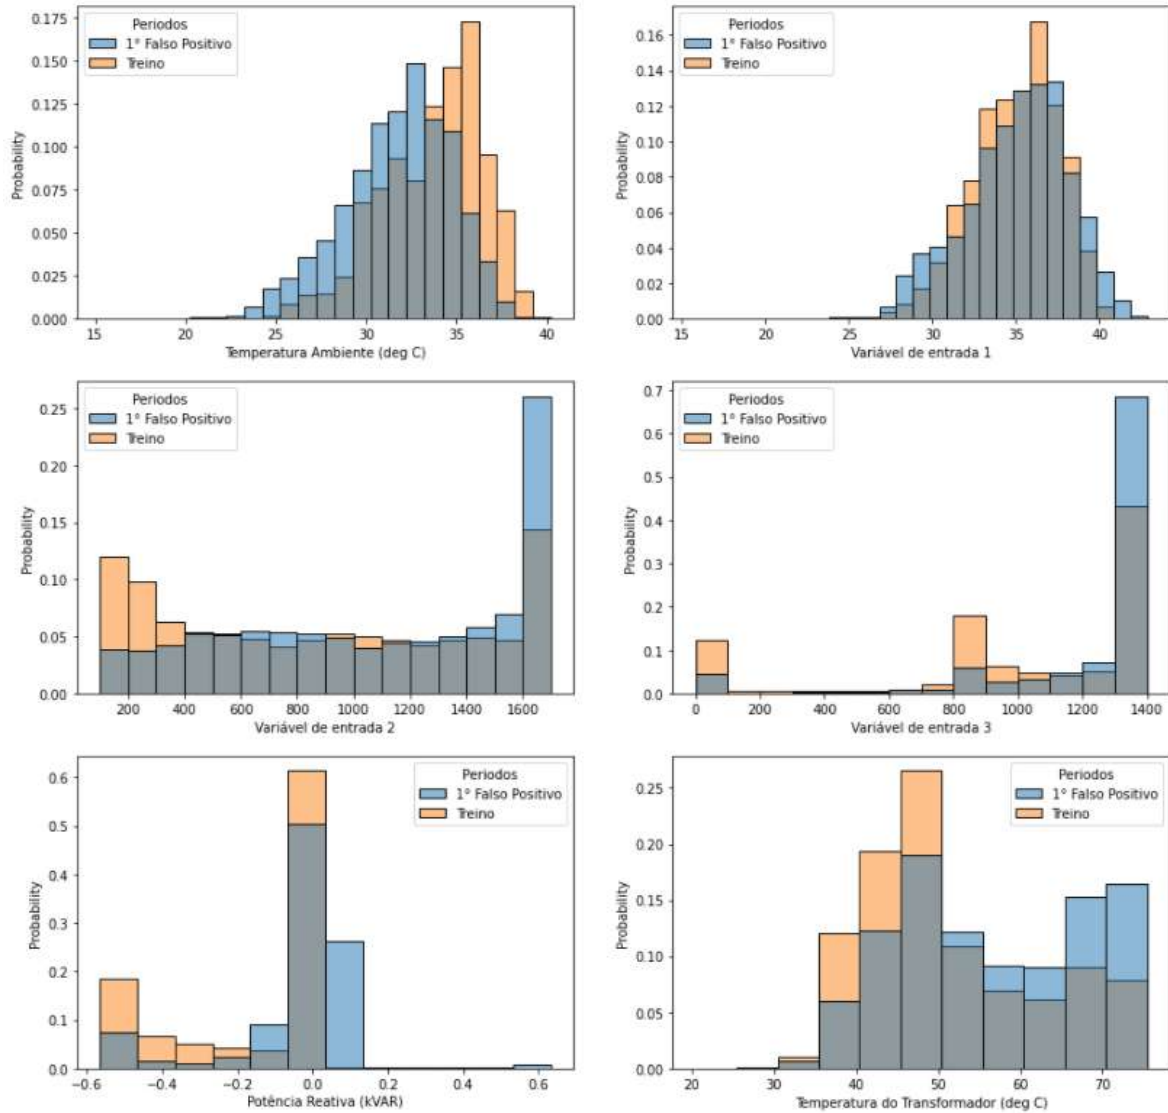


Figura 5 - Comparação entre as distribuições das variáveis de entrada das redes neurais nos períodos do treinamento e no período de alarme falso-positivo entre os meses M16 e M19 (1º período de falso-positivo)

Fonte: Os próprios autores, 2023.

Na Figura 6, nota-se que o segundo período de falso-positivo, compreendido entre os meses M28 e M30, apresenta potências reativas mais altas do que foi visto no treinamento.

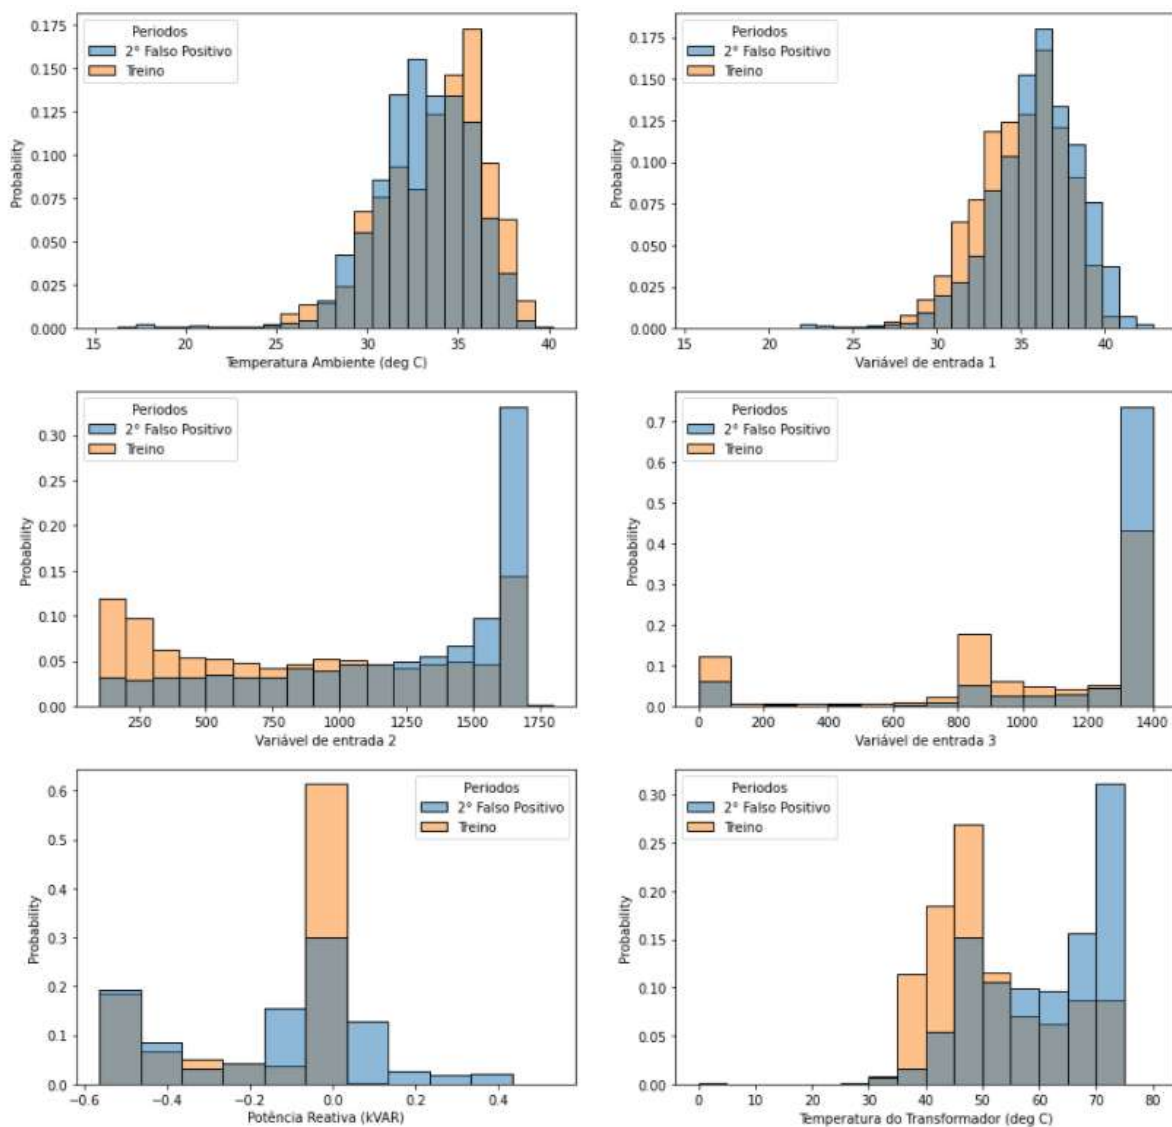


Figura 6 - Comparação entre as distribuições das variáveis de entrada das redes neurais nos períodos do treinamento e no período de alarme falso-positivo entre os meses M28 e M30 (2º período de falso-positivo)

Fonte: Os próprios autores, 2023.

Já na Figura 7, é possível observar que o modelo de *transfer learning* conseguiu reproduzir, para o aerogerador AEG01, os valores esperados nas situações de temperatura ambiente e potência reativa mais altas, sem gerar alarmes falso-positivo, de acordo com os critérios de geração de alarme explicados no item 3.3.1.

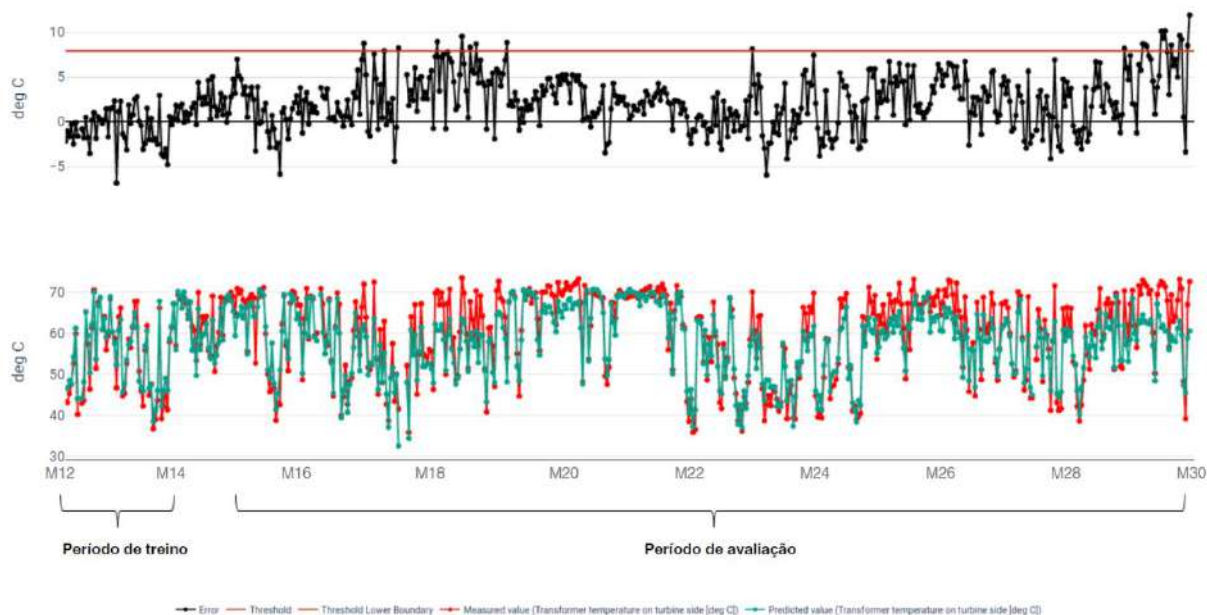


Figura 7 - Linha do tempo de avaliação do modelo com *transfer learning* para a AEG01

Fonte: Os próprios autores, 2023.

5. CONSIDERAÇÕES FINAIS E CONCLUSÕES

Os resultados do estudo indicam que a utilização de técnicas de *transfer learning* podem acelerar a obtenção de modelos de monitoramento em casos onde o conjunto de dados históricos ainda não contém todas as situações normais de operação e, conseqüentemente, abreviar o tempo entre o início da coleta de dados e o estabelecimento de um monitoramento preditivo que forneça informações para o planejamento adequado de ações paliativas e/ou corretivas sem falsos positivos.

As principais conclusões do trabalho podem ser resumidas nos seguintes tópicos:

- Indivíduos candidatos ao processo de transferência de conhecimento podem ser identificados comparando os histogramas do conjuntos de variáveis de entrada do modelo de RNA em questão e identificando conjuntos de dados mais diversos, usado para fazer o modelo base, e conjunto de dados menos diversos, usado para fazer o modelo de referência;
- As informações contidas em cada camada de uma rede neural puderam ser reaproveitadas e calibradas à medida que novos dados representativos do fenômeno foram adicionados, mantendo-se a arquitetura original.
- A manutenção da arquitetura original e da inicialização dos pesos herdados do modelo base resultaram em um processo de treinamento rápido e com melhor desempenho do que o modelo de referência.
- O desempenho do modelo com *transfer learning* deve ser comparado com o modelo de referência nas condições existentes e inexistentes no conjunto de dados menos diverso.
- A utilização da técnica de *transfer learning* abordada neste trabalho permitiu o desenvolvimento de uma RNA capaz de monitorar a temperatura do transformador de um aerogerador (AEG01) e estimar os efeitos na temperatura do transformador devido aos valores de potência reativa e temperatura ambiente, mesmo que esse indivíduo em questão nunca tivesse passado por essa situação durante as fase de treinamento.

Trabalhos futuros devem investigar a possibilidade de transferência de conhecimento entre aerogeradores de modelos diferentes ou instalados em regiões distintas.

REFERÊNCIAS

PAN, S. J., & YANG, Q. (2010). A survey on *transfer learning*. IEEE Transactions on Knowledge and Data Engineering, 22(10), 1345-1359.

HU, Q.; ZHANG, R.; ZHOU, Y. *Transfer learning* for short-term wind speed prediction with deep neural networks. Renew. Energy 2016, 85, 83–95.

OH, J.; PARK, J.; OK, C.; HA, C.; JUN, H.-B. A Study on the Wind Power Forecasting Model Using *Transfer learning* Approach. Electronics 2022, 11, 4125. Disponível em: <<https://doi.org/10.3390/electronics11244125>>. Acesso em 03 jul. 2023.

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.

Otimizador de limitação de geração em Centros de Operação de plantas eólicas

Bruno Pires de Campos¹, Waldemar Alvares Rezende²

Automalógica, AWR Energia

bruno.campos@automalogica.com.br, waldemar@awrenergia.com.br

RESUMO

Este trabalho apresenta o otimizador de limitação da Automalógica aplicado em um COG de planta eólica para atender restrições de geração impostas pelo ONS. A solução é desenvolvida em plataforma SCADA Elipse, visando a diminuição de perdas energéticas e a agilidade na definição dos limites de geração em cada PPC de um ou mais complexos eólicos.

Palavras-chaves:

Geração eólica; SCADA; Centro de operação; Otimizador de limitação; PPC.

ABSTRACT

This paper presents the Automalógica limiting optimizer applied in a wind plant COG to meet generation constraints imposed by ONS. The solution is developed in SCADA Elipse platform, aiming to reduce energy losses and to define generation limits in each PPC of one or more wind complexes.

Keywords:

Wind power Generation; SCADA; Operation center; Limitation optimizer; PPC.

1. INTRODUÇÃO

Com a crescente inclusão de geração eólica e solar na matriz energética brasileira, está cada vez mais comum a imposição de cortes de geração por parte do Operador Nacional do Sistema (ONS). Esses cortes são necessários em momentos de picos de geração que acabam sobrecarregando o Sistema Interligado Nacional (SIN). A sobrecarga prolongada de potência ativa pode comprometer a qualidade da energia da rede [6], elevando a tensão fora dos limites aceitáveis. Se o pico for prolongado pode resultar no aumento da temperatura do cabeamento e possível rompimento, em danos a equipamentos conectados na rede etc.

Nos períodos de restrição, quem sai perdendo são os agentes que tem sua geração limitada e em muitos casos zerada. O único modo de diminuir as perdas é gerar o mais próximo possível do limite imposto pelo ONS. E essa tarefa geralmente fica sob responsabilidade dos operadores das usinas, que enviam os limites necessários aos equipamentos PPC (do inglês Power Plant Controller) através de *setpoints* no sistema SCADA (Supervisory Control and Data Acquisition). O ONS pede uma limitação em pontos de conexão específicos da rede. A questão é que em um ponto de conexão podem estar conectados vários parques eólicos, e coordenar a limitação nesses parques para atender à limitação total necessária é uma

tarefa desafiadora por vários motivos. Os operadores de um COG (Centro de Operação da Geração) normalmente operam várias usinas simultaneamente. Com a entrada de usinas solares e eólicas, a quantidade de pontos monitorados no sistema SCADA aumenta significativamente, principalmente porque uma única planta pode conter centenas de aerogeradores e cada gerador tem outras centenas de pontos de monitoramento. Quantidades bem maiores quando comparadas a supervisão da tradicional geração hídrica, com no máximo dezenas de unidades geradoras por planta. Isso tudo leva a um aumento da carga de trabalho sobre os operadores, que devem monitorar muito mais informação para garantir uma operação segura e eficiente dos ativos sob sua responsabilidade.

Outro ponto que dificulta o trabalho da operação durante restrições de geração é que um complexo eólico muitas vezes possui mais de um ponto de controle. Cada ponto de controle é um parque eólico com um PPC que deverá receber um *setpoint* de potência ativa, representando maior número de interações do operador com o sistema SCADA.

Considerando-se que a velocidade de vento varia constantemente entre os parques de um complexo e conseqüentemente a capacidade de geração de cada parque, é impraticável que o operador consiga restringir a produção energética refletindo essas variações na limitação escolhida para cada parque eólico, de modo que cada parque fosse limitado de acordo com sua capacidade de geração no momento da limitação. Seria ainda mais desafiador caso o operador precisasse levar em conta que o preço da energia (PLD) pode ser diferente entre os parques em restrição e que esse preço pode variar hora a hora e isso também tem influência na limitação ótima.

É por tudo isso que se faz necessário uma solução que gerencie de maneira ótima a limitação imposta pelo ONS. A ferramenta apresentada é o Otimizador de limitação desenvolvido pela empresa Automalógica. O objetivo da ferramenta é oferecer um controle de potência ativa ágil e eficiente nos períodos de restrição de geração, de modo a limitar a geração o mais próximo possível do limite imposto pelo ONS e assim diminuir as perdas decorrentes dessas restrições.

2. ESTADO DA ARTE/ FUNDAMENTAÇÃO TEÓRICA

COG

O COG tem como principal responsabilidade supervisionar e controlar as usinas sob sua responsabilidade. O objetivo é operar as plantas da maneira mais segura e eficiente possível, rentabilizando ao máximo os recursos de geração. Quem executa essa função são os operadores através de sistemas SCADA.

O termo SCADA vem do inglês Supervisory Control and Data Acquisition. É um software de controle supervisão e aquisição de dados que fornece medições de tempo real do sistema através da aquisição de dados de concentradores como IEDs (do inglês intelligent electronic device), CLP (controlador lógico programável) ou relés. Os dados adquiridos são exibidos graficamente em telas de supervisão que representam o funcionamento da planta real [1].

As principais funções do sistema SCADA são [2]:

- 1) Aquisição de dados: Os IEDs concentram informações sobre o estado de equipamentos (como abertura ou fechamento de disjuntores), medição de sensores (temperaturas, potência, tensões, correntes etc.) e enviam esses dados ao SCADA através de protocolos de comunicação;
- 2) Gerenciamento de eventos e alarmes: Através da comparação de medições reais com faixas de valores consideradas normais, são gerados alarmes de medições analógicas. Alarmes ou eventos digitais são ativados em função de atuações nos próprios equipamentos de campo, como a abertura de um disjuntor ou indisponibilidade de um aerogerador;
- 3) Controle: Através do SCADA são enviados comandos e *setpoints* para controlar os equipamentos de campo como partida/parada de um aerogerador, abertura/fechamento de chave e disjuntores da subestação, limitação de potência em um PPC etc.;
- 4) Armazenamento: Cada variável analógica, alarme, evento, comando ou *setpoint* podem ser armazenados em ordem cronológica em banco de dados, possibilitando posterior análise sequencial de

ocorrências. Ou estudos mais sofisticados como previsão de falhas em equipamentos ou previsão de demanda de energia, por exemplo [5].

A aplicação SCADA COG é comumente conhecida como N3 (nível 3). O termo denota que abaixo do N3, existem o N2 (nível 2) e o N1 (nível 1). O N2 é uma aplicação SCADA local destinada à equipe de mantenedores da planta. O N1 é composto pelos equipamentos de campo (sensores, geradores, concentradores etc.). O N2 adquire informações do N1. Essa aquisição se dá através da comunicação entre N2 e N1 por protocolos de comunicação como Modbus, DNP3, IEC61850 etc. O COG é a integração de várias aplicações N2 em uma aplicação N3. Através do COG é possível operar remotamente várias plantas em uma única aplicação SCADA. Cada N2 é responsável por concentrar as informações da planta monitorada e enviar ao COG também através de protocolos de comunicação como IEC-104, DNP3 etc.

Existe ainda um quarto nível de supervisão responsável por garantir o equilíbrio do SIN (Sistema Interligado Nacional), balanceando geração e demanda. É o nível do ONS (Operador Nacional do Sistema) que é o maior e mais complexo centro de operação do Brasil e coordena os vários centros de operação. Quando a geração começa a exceder a demanda, o sistema pode ficar desequilibrado levando ao aumento de tensão em picos de geração. Isso pode causar desligamentos e prejudicar o funcionamento de equipamentos ligados à rede. Por isso, nesses momentos, o ONS pode exigir a restrição de geração ou mesmo o desligamento de fontes de geração. O ONS comunica as restrições aos COGs, que serão responsáveis por limitar suas fontes. Caso a concessionária não respeite o limite imposto pelo ONS, penalidades serão aplicadas, que podem variar desde multas até a proibição de geração.

No caso de plantas eólicas, a limitação de geração é feita através do envio de *setpoints* de potência aos PPCs que por fim controlam a potência de grupos de aerogeradores sob seu controle.

PPC

O PPC é responsável por controlar a potência total de um grupo de aerogeradores em um patamar pré-definido. O PPC consiste em um CLP que roda algoritmos de loop fechado para controlar medições elétricas do ponto de conexão da planta com a rede elétrica. Um PPC deve ser capaz de controlar a potência ativa, potência reativa, tensão e/ou fator de potência da usina eólica. O controle de potência ativa será o foco deste trabalho. O PPC age como um mestre que define a potência em cada aerogerador do parque. O aerogerador, por sua vez, tem seu próprio loop de controle para obedecer ao que lhe foi definido pelo PPC. O somatório da potência de todos os aerogeradores é mensurado por um medidor de potência no ponto de conexão, essa medição é o feedback para o algoritmo do PPC que avalia se deve aumentar, diminuir ou manter a potência dos aerogeradores controlados [3].

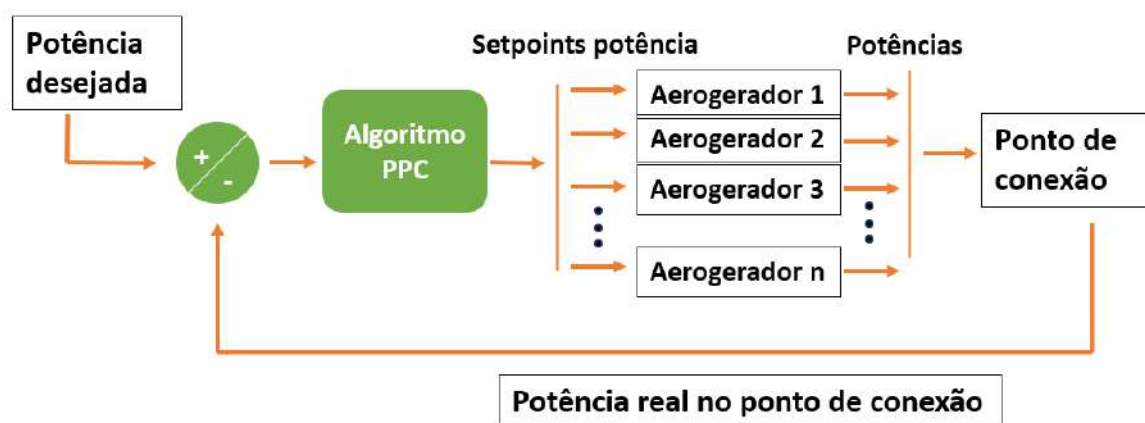


Figura 1. Fluxograma PPC

Por definição do ONS, toda planta eólica deve possuir um PPC [4]. Para a concessionária, o ideal seria gerar sempre o máximo de potência possível, porém o ONS pode impor limitações de potência buscando o equilíbrio do SIN.

A sequência da ação de limitação se resume assim:

1. ONS liga para o operador COG exigindo a limitação em uma ou várias plantas;
2. O operador do COG decide qual o limite de potência em cada um dos parques sob seu controle para atender à requisição do ONS;
3. Através do SCADA do COG, o operador envia os *setpoints* de potência ativa para cada parque para o SCADA da planta;
4. O SCADA local da planta eólica repassa o *setpoint* recebido para os PPCs dos parques eólicos;
5. Os PPCs controlam a potência dos aerogeradores para atingir o limite de geração imposto.

3. MÉTODO DO ESTUDO

A solução proposta funciona em arquitetura mestre/escravo. O mestre recebe o limite inserido pelo operador do sistema, executa o cálculo de limitação ótima para cada escravo e faz a distribuição do *setpoint* calculado em cada escravo. O escravo, por sua vez é o responsável por receber a limitação calculada pelo mestre e enviar ao PPC que controla a potência dos aerogeradores do parque eólico. Cada PPC representa um escravo no otimizador de limitação.

Essa arquitetura pode ser expandida em quantos níveis forem necessários. Na base estão os escravos, os mestres ficam nos níveis superiores. Dependendo da necessidade, é possível existir vários níveis de mestre. De maneira que o mestre em um nível inferior se torna um escravo do mestre de nível acima.

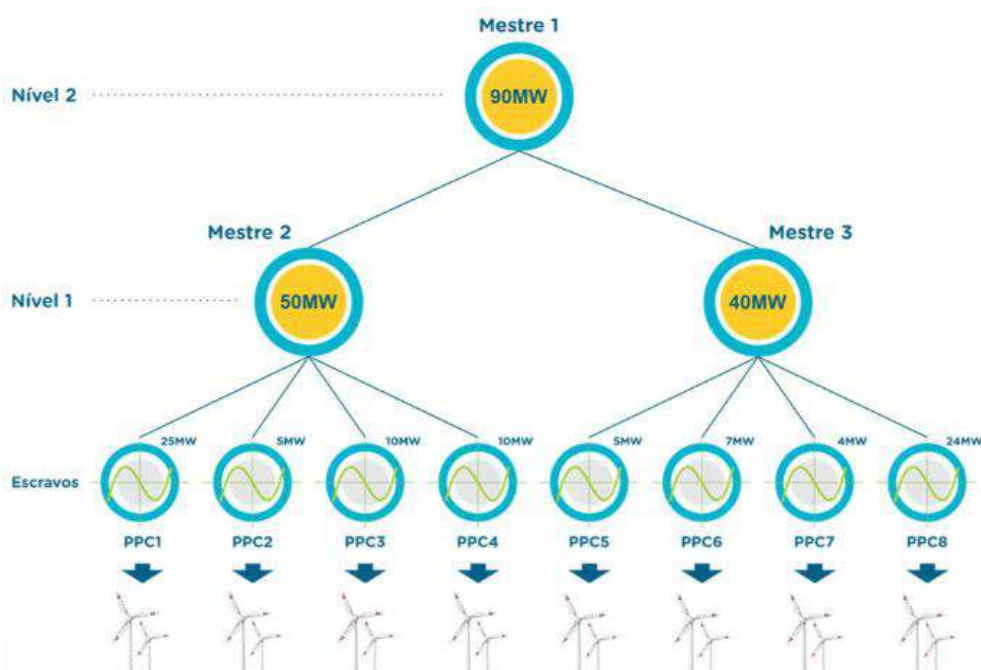


Figura 2. Arquitetura do otimizador de limitação [7]

Algoritmo

O algoritmo é baseado primeiramente na potência esperada de cada PPC. A potência esperada vem da curva de potência do aerogerador, para cada velocidade do vento e densidade se tem uma potência ativa correspondente. Normalmente essa informação é exibida na especificação do aerogerador. Essa é a medida de capacidade de geração de cada PPC e é com base nela que o algoritmo do otimizador calcula a limitação ótima em cada parque eólico. De modo que parques que tem maior potência esperada, com

maiores velocidades de vento, receberão limites mais altos (e por isso irão gerar mais) em comparação com os parques com menores potências esperadas. O cálculo de distribuição é feito de maneira cíclica para que se leve em conta as variações de vento em cada período.

Outro fator que pode ser levado em consideração na distribuição de limitação em cada parque é o Preço de Liquidação das Diferenças (PLD), ou seja, o preço da energia. Nesse caso é possível atribuir uma prioridade em cada parque considerando o retorno monetário. Parques que tem PLD mais alta serão menos limitados (terão limites mais altos) em comparação com parque que tem PLD mais baixa.

Método manual vs Otimizador de limitação

Apresenta-se aqui uma simulação didática comparando-se o método manual em que o operador decide a limitação em cada parque e o método do otimizador de geração desenvolvido pela Automalógica. Também será comparado os dois modos de operação do otimizador de limitação, o modo de distribuição equilibrado e o modo de distribuição por prioridade. Nessa simulação está sendo considerado um complexo eólico com 3 parques com mesma potência nominal.

Cenário I

É um cenário sem limitação em que cada parque está gerando o máximo possível de acordo com a velocidade de vento presente em cada um. Nessa situação a geração atual é a mesma da geração esperada, pois a limitação está zerada em todos os parques. Nesse cenário o complexo eólico está gerando um total de 100 MW.

	Parque 1	Parque 2	Parque 3	Total
Geração atual (MW)	50	30	20	100
Geração esperada (MW)	50	30	20	100
Limitação (MW)	0	0	0	0

Tabela 1. Geração e limitação de potência Cenário I

Cenário II

É o cenário em que o ONS faz uma requisição de limitação para 90 MW e a distribuição será feita manualmente pelo operador do sistema SCADA. Nesse caso a prática comumente adotada é a distribuição média entre os parques. Ou seja, a limitação de 90 MW será dividida igualmente entre os 3 parques, resultando em uma limitação de 30 MW em cada parque.

	Parque 1	Parque 2	Parque 3	Total
Geração atual (MW)	30	30	20	80
Geração esperada (MW)	50	30	20	100
Limitação (MW)	30	30	30	90

Tabela 2. Geração e limitação de potência Cenário II

Nesse cenário, o parque 1 que era capaz de gerar 50 MW foi limitado em 30 MW e passou a gerar os 30 MW. O parque 2 que estava gerando 30 MW, foi limitado em 30 MW, continuou gerando 30 MW. O parque 3 que estava gerando 20 MW, foi limitado em 30 MW, continuou gerando 20 MW. Ao final da limitação manual a soma das limitações ficou em 90 MW, porém a soma da geração real ficou em 80 MW, ou seja, 10 MW de perda em relação aos 90 MW imposto pelo ONS.

Cenário III

Nesse cenário o otimizador fará a distribuição no modo equilibrado. O objetivo desse modo é deixar os parques na geração mais próxima possível um do outro, porém respeitando a geração esperada em cada parque.

	Parque 1	Parque 2	Parque 3	Total
Geração atual (MW)	40	30	20	90
Geração esperada (MW)	50	30	20	100
Limitação (MW)	40	30	20	90

Tabela 3. Geração e limitação de potência Cenário III

Nesse modo o algoritmo primeiramente distribui a média de 30 MW de limitação entre os parques, porém entende que o parque 3 não é capaz de gerar 30 MW, somente pode gerar 20 MW de acordo com sua geração esperada. Os 10 MW que sobram do parque 3 são distribuídos para os parques com maiores capacidades de geração, nesse caso o parque 1.

Desse modo a geração final ficaria exatamente no mesmo patamar de 90 MW imposto pelo ONS.

Cenário IV

Nesse cenário o otimizador fará a distribuição no modo por prioridade. Nesse modo cada um dos parques tem um valor de prioridade que pode ser definido manualmente ou seguir o valor de PLD em cada parque. Quanto maior for a prioridade, menor será a limitação naquele parque.

	Prioridade 3	Prioridade 2	Prioridade 1	Total
	Parque 1	Parque 2	Parque 3	
Geração atual (MW)	50	30	10	90
Geração esperada (MW)	50	30	20	100
Limitação (MW)	50	30	10	90

Tabela 4. Geração e limitação de potência Cenário IV

O parque 1 tem a maior prioridade, 3 no caso, e recebe como limitação tudo o que ele é capaz de gerar. De modo que do limite imposto de 90 MW, 50 MW foram distribuídos para o parque 1. Sobrando 40 MW para ser distribuídos entre os parques 2 e 3. O parque 2 tem a segunda maior prioridade e recebe como limitação tudo o que ele é capaz de gerar, 30 MW. Desse modo restam apenas 10 MW a serem distribuídos para o parque 3, que tem a menor prioridade.

Neste cenário a geração final também fica exatamente no mesmo patamar de 90 MW de limite imposto.

5. ANÁLISE E DISCUSSÃO DOS RESULTADOS

O Otimizador de limitação é uma ferramenta desenvolvida pela empresa Automalógica em plataforma Elipse e vem sendo aplicada em SCADA de Centros de operação de complexos eólicos.

Essa solução foi aplicada em um complexo eólico que possui 10 parques, cada parque com seu próprio PPC. Os parques têm a potência nominal exibida na Tabela 5.

Parque	Potência nominal (MW)
1	22,4
2	22,4
3	22,4
4	11,2
5	24,0
6	12,8
7	14,4
8	14,4
9	11,2
10	14,4

Tabela 5. Potência nominal por parque

O nome da empresa fornecedora dos dados será omitido por exigência da mesma. O período de análise se dá no mês de junho de 2023.

O gráfico de perda acumulada de energia por restrições de geração é apresentado na Figura 3. Cada degrau do gráfico representa uma contabilização de perda. Percebe-se que nesse mês ocorreram várias restrições de geração.




Figura 3. Perda total acumulada (MWh) em junho de 2023

A potência perdida acumulada saiu de um patamar de 1413 MWh no início do mês, para um patamar de 2451 MWh. Totalizando uma perda acumulada de 1038 MWh, demonstrando que a ferramenta foi ativamente utilizada durante esse mês.

Pela Figura 4 percebe-se que todos os 10 parques sofreram limitações ao longo de junho de 2023.




Figura 4. Perda acumulada (MWh) por parque em junho de 2023

Porém alguns parques sofreram mais perdas do que outros. Nesse caso otimizador foi configurado para operar no modo de distribuição equilibrada, onde o objetivo é deixar os parques controlados na potência mais próxima possível um do outro.

Comparando-se, por exemplo, as perdas do parque 4 com as perdas do parque 5, percebe-se que o parque de maior potência nominal sofreu maiores perdas.

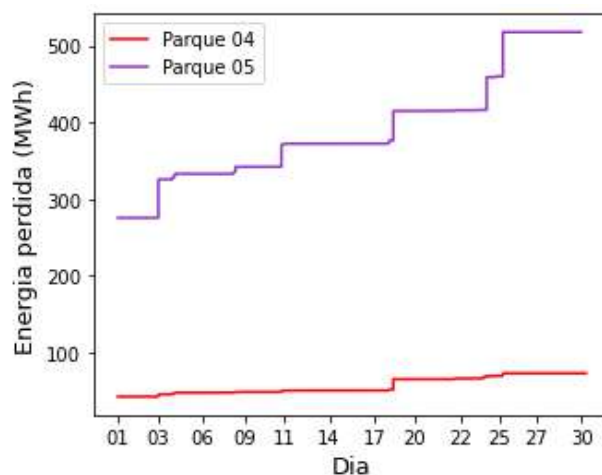


Figura 5. Perda acumulada (MWh) no parque 4 e parque 5 em junho de 2023

Nesse modo, o parque de menor potência nominal acaba sofrendo menos perdas porque gerou próximo de sua capacidade máxima para ficar com a geração o mais próxima possível dos parques de maior capacidade. O contrário ocorre com os parques de maior potência nominal. A Tabela 6 exibe a totalização das perdas do mês de junho em cada parque.

Parque	Energia perdida (MWh)
1	173,74
2	140,98
3	213,14
4	30,46
5	242,25
6	58,41
7	61,65
8	46,07
9	45,68
10	25,96

Tabela 6. Totalização de perdas (MWh) por parque em junho de 2023

A Figura 6 concentra a análise da totalização de perdas no dia 25/06/2023. Observa-se que houve perda acumulada considerável, saindo de 2230 MWh para 2450 MWh, totalizando 220 MWh de perdas de geração somente em 1 dia.




Figura 6. Perda total acumulada (MWh) em junho de 25/06/2023

Neste dia o limite imposto foi de 77 MW de potência e a limitação durou entre 9:00h até as 16:00h. Observando-se o comportamento da curva de potência nesse dia na Figura 7, percebe-se que o controle foi efetivo ao manter a geração total sempre próxima do limite imposto durante o período de restrição.




Figura 7. Potência ativa total em 25/06/2023

A título de demonstração, apresenta-se na Tabela 7 o histórico de *setpoints* do parque 10 no dia 25/06/2023 das 13:56 h até 15:56 h. Através da constante variação do *setpoint* de potência do parque 10, é possível observar que o algoritmo procura se adequar às oscilações de vento para otimizar a limitação a cada ciclo de cálculo, 10 minutos nesse caso.

Data	Setpoint Parque 10 (MW)
25/06/2023 15:56:36.864	7,76
25/06/2023 15:46:36.516	7,68
25/06/2023 15:36:36.640	8,05
25/06/2023 15:26:36.315	7,66
25/06/2023 15:16:36.472	7,65
25/06/2023 15:06:37.258	6,66
25/06/2023 14:56:35.371	8,06
25/06/2023 14:46:34.792	7,70
25/06/2023 14:36:34.577	7,78
25/06/2023 14:26:34.616	5,55
25/06/2023 14:16:35.017	4,92
25/06/2023 14:06:36.501	6,01
25/06/2023 13:56:34.009	6,44

Tabela 7. Histórico de *setpoints* do Parque 10 das 13:56h até 15:56h do dia 25/06/2023

6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

Pelo exposto, é possível concluir que o otimizador de limitação funciona adequadamente, controlando a potência do complexo no limite desejado. Além de trazer alguns benefícios para a operação:

Otimização e confiabilidade no controle de potência

O limite imposto é seguido à risca pelo otimizador, evitando maiores perdas com restrições abaixo do limite imposto e evitando penalidades por ultrapassagem desse mesmo limite.

Agilidade

Pela comparação entre o método manual e o otimizado é possível concluir que é muito difícil um operador realizar a distribuição ótima manualmente e ainda adequar periodicamente a limitação em cada parque considerando as flutuações de capacidade de geração em função da constante variação de velocidade de vento. Com o otimizador o operador precisa apenas ligar o otimizador e inserir o *setpoint* requerido pelo ONS. Depois desse passo, o otimizador faz a limitação em cada parque e recalcula essa distribuição periodicamente para considerar as flutuações de velocidade de vento e potência esperada. Enquanto manualmente o operador teria que definir individualmente a potência em cada parque, um *setpoint* para cada PPC existente na planta a ser limitada. Além disso um único *setpoint* no otimizador, diminui as chances de erro humano em comparação com a necessidade de vários *setpoints* no caso do controle manual por parque.

Diminuição da carga de trabalho da operação

Com o otimizador fazendo a limitação de geração automaticamente, o operador do COG fica livre para dar atenção a eventos mais críticos do dia a dia de um centro de controle de geração eólica.

REFERÊNCIAS

- [1] Ekanayake, J.; Liyanage, K.; Jlanzhong Wu; Yokoyama, A.; Jenkins, N. "Smart grid - technology and applications." WILEY, 2012.
- [2] Campos, B. P.; Ribeiro P. F.; Edival, L. S., "Integração de informações para o monitoramento de métricas de desempenho de uma microgrid" XII CBQE, 2017.
- [3] M. Steinbuch; W.W. de Boer; O.H. Bosgra; S.A.W.M. Peters J. Ploeg; " Optimal control of wind power plants" Journal of Wind Engineering and Industrial Aerodynamics, 1988.
- [4] Submódulo ONS 3.6; "Requisitos técnicos mínimos para a conexão às instalações de transmissão", 2016
- [5] Campos, B. P.; Silva, M. R. "Demand Forecasting in Residential Distribution Feeders in the Context of Smart Grids." In: International Conference on Industry Applications, 2016.
- [6] Torquato, R.; Trindade, F. C. L.; Freitas, W. "Analysis of the harmonic distortion impact of photovoltaic generation in Brazilian residential networks." Proceedings of International Conference on Harmonics and Quality of Power, ICHQP, p. 239–243, 2014.
- [7] <https://automalogica.com.br/otimizador-de-limitacao-de-potencia>

CONDITION MONITORING OF WIND TURBINE DRIVETRAINS FOR FAILURE DIAGNOSIS USING DEEP LEARNING WITH AUTOENCODER

Eduardo J.N. Menezes^{1,2,*}

¹Diretor Técnico, Evoluce Tecnologia em Monitoramento e PHM

²Centro de Estudos e Ensaios em Risco e Modelagem Ambiental, Universidade Federal de Pernambuco (CEERMA-UFPE)

*Correspondence: eduardo.menezes@evolucetecnologia.com.br

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 diagnosis solution, based on deep learning and direct time-domain feature extraction. The developed tool enables identification of time-series anomalies, indicating the failure warning by surpassing specific thresholds over the reconstruction error of an autoencoder network. Many advantages are demonstrated, including the failure diagnosis long before the traditional FFT and Envelope methods. Effectiveness of the method is proven on a WT's CMS vibration database.


Keywords:

condition monitoring; deep learning; vibration analysis; WT diagnostics; autoencoder.

1. INTRODUCTION

Wind energy has increasingly been incorporated as a major power source in supplying worldwide energy demand, becoming one of the most important and profitable renewable energy sources. Indeed, the world has seen its installed wind power capacity passes from 198 GW in 2010 to 906 GW towards the end of 2022, consisting in a nearly exponential growth of power capacity, as illustrated in Figure 1. On the other hand, the urgent need for energy transition is expected to motivate even more the employ of wind power over many countries of the globe. According to the Intergovernmental Panel on Climate Change (IPCC), organ of the United Nations (UN) for climate changes matters, the limitation of global temperature increase to 2°C in 2100 is pointed as the superior threshold to ensure tolerable impacts for the ecosystems. This was the limit adopted by the Paris Agreement, in the end of 2015, signed by 192 countries.

Figure 1: Installed wind power capacity approaching an exponential growth trend, onshore and offshore numbers. Source: Adapted by the author from GWEC (2023).




In Brazil, the growth of wind power in the last two decades has proven the potential of including wind energy in the Brazilian energy matrix. The national capacity has increased from the incipient number of 0.22 GW in 2005 to the current 21 GW of wind power production. Brazil is today the 7th country in wind power installed capacity and the projections are of constant increase over the next years (EPBR, 2022). On the other hand, in order to sustain this impulse in wind energy employment, several challenges remain. One of the main reside in the operation and maintenance (O&M) costs, which can attain 30% of the overall wind project cost (NREL, 2020). In fact, wind turbines (WTs) designed for a 20-year lifetime often suffer varied premature failures due to the harsh operational conditions, especially regarding the variable mechanical load (Meng et al., 2019).

Analyzing the failure breakdown, it is clearly demonstrated in many studies that the gearbox and generator failures are the responsible for causing the longest downtime and thus are associated with the highest cost per failure (Dao et al., 2019; Liu & Zhang, 2020). Further, it is noteworthy that bearings are by far the primarily responsible for inducing these drivetrain failures, accounting for, e.g., 76% of the gearbox failures. For the sake of comparison, only 17% of gearbox failures comes from gears and the other 7% from miscellaneous causes (Peeters et al., 2018). It remains evident the importance of avoiding bearing failures, given the high downtimes and costs of drivetrain replacements. The most relevant method to prevent the financial and production losses caused by undesired bearing failures is based on condition monitoring systems (CMS). Although different monitoring variables could be used, the solution largely implemented in the commercial WTs relies on vibration monitoring. Compared to other possible CMSs, such as oil analysis and temperature monitoring, vibration signals are simpler to acquire, provide earlier failure detections and

enable analysis in time, frequency or time-frequency domains (Wymore et al., 2015). Acoustic emissions are comparable to vibration measurement in ability of failure observation, but are harsh to gather and preprocess, especially in noisy environments (Scheeren et al., 2022). However, regardless of vibration CMS being present in the majority of 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 order to overcome these issues and improve WT diagnosis, we have been developing several failure detection algorithms, mainly based on machine learning methods. Machine learning (ML) is an artificial intelligence (AI) branch that provides computers with the ability to learn complex relations from data, capturing non-linear and unmodeled dynamics between any number of variables. Thus, ML algorithms are a natural choice for WT diagnosis. Deep learning (DL) is a subfield of machine learning specifically dedicated to algorithms emulating the human brain structure, i.e., neural networks (NNs). Usually, deep learning refers to NNs composed of three or more hidden layers (Deisenroth et al., 2020). The subfields of artificial intelligence are shown in Figure 2.

Figure 2: Artificial Intelligence classification. Source: IBM (2023).



Machine and deep learning have been increasingly studied to execute diagnostics and prognostics of machinery, including WTs, and have shown promising potential. However, very few papers have addressed their application in real turbine data. Therefore, this paper has the following objectives: present one of our diagnostic solutions based on deep learning, using a type of NNs known as autoencoders; apply

the solution in commercial WTs; compare our solution with traditional diagnostic of drivetrain failures, showing it can forecast premature failures in advance to conventional approaches.

2. ML AND DL IN DIAGNOSIS AND PROGNOSIS USING VIBRATION DATA

A large amount of research has been executed in AI for evaluating the health of machines, systems or structures (Berghout & Benbouzid, 2022). This is commonly termed as Prognostics and Health Management (PHM). Various PHM papers rely on laboratory test data which not necessarily corresponds to real field conditions. Nevertheless, they present useful methods that worth consideration and that can be combined and adapted for use in WTs on the field. 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.

PHM techniques for WTs are essentially derived from methods applied to gears and bearing 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 ML and DL approaches fit so well in WTs analysis, since they are nonlinear by nature. With the increase in computational power and the advent of big data, the last decade has seen an impressive increase in ML and DL research, including using collected vibration data (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 ML for WTs is first presented by Chen et al. (2013), 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 (L. 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 the 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 ML and 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 autoencoder and time-signal feature processing, without the need of spectral or envelope analysis, and not depending on direct human intervention.


3. METHODOLOGY

3.1 UTILIZED WT CMS DATASET

The applied dataset corresponds to vibration data collected from WT CMSs installed in 18 WTs of 2.5 MW rated capacity over a 5-year period. Data has been provided by Luleå University of Technology (LTU) and is referenced in the work of Strömbergsson et al. (2020). Each gearbox of the WTs is instrumented with 4 accelerometers, mounted in different positions. The gearboxes have three gear stages and two planetary stages, followed by a helical gear stage. The accelerometers are located as follows: one accelerometer at the ring gear of the 1st planetary stage; one accelerometer at the gearbox housing just

beside the ring gear of the 2nd planetary stage; and two accelerometers (radial and axial) at the housing near to the output shaft. Figure 3 illustrates a WT gearbox with the installed accelerometers.

Figure 3: Vibration monitored gearbox with installed accelerometers. Source: (Strömbergsson et al., 2020).




The vibration data has been collected every 24 hours. The accelerometers mounted on the planetary stage had a sample rate of 2.56 kHz and a sample duration of 6.4 s. For the accelerometers mounted on the output shaft, these values were of 12.8 kHz and 1.28 s, where the highest sample frequency is needed due to the higher rotational speed in the output of gearboxes.

3.2 ANOMALY DETECTION USING AUTOENCODERS

Autoencoders (AEs) are a special type of ANNs, whose objective is to reconstruct in the output the same data of the input. In this sense, autoencoders are considered an unsupervised DL method, since the training labels are the input data. The AE is the result of two sequential networks: an encoder, which learns a compressed representation of input data, codifying information to what is called latent space; and a decoder, which obtains the output from the latent space. An example of autoencoder structure is shown in Figure 4.

Figure 4: Autoencoder with sequential encoder and decoder. Source: (Y. Song et al., 2021)



Mathematically, each encoder layer takes the input x and transforms it to a hidden representation h as:

$$h = \phi(W \cdot x + b) \quad (1)$$

where ϕ represents a nonlinear activation function, and W and b are the layer weight and bias, respectively. In this paper, ReLU function will be used as activation for both encoder and decoder layers (see Sec. 3.3.1). The procedure in Eq. 1 generates the latent space and the coded representation. After that, the decoder generates the output x' by passing the data through its several layers, with the same mathematical process, this time acting over the hidden variables:

$$x' = \phi(W' \cdot h + b') \quad (2)$$

where W' and b' are the decoder layer weight and bias. The mean squared error L_{MSE} is normally used as the loss function, as in Eq. 3:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (x_i - x'_i)^2 \quad (3)$$

where x_i and x'_i are generic samples and N is the total number of samples. In the present paper, the samples consist in vibration time-series collected in each logged measurement of the CMS.

One of the possible uses of AEs is to detect anomalies, based on their reconstruction error (Finke et al., 2021). This process happens when the AEs are trained exclusively with vibration data from healthy machine conditions. In this case, if a non-healthy or anomalous time-series is passed through the network, the AEs will present a large reconstruction error, indicating the anomaly. The procedure has a lot of advantages: it does not require the definition of the defect frequencies for each specific component and failure mode; it does not require feature extraction in the frequency domain; it does not require searching

for specific frequencies or sidebands, which is subjected to human errors. The next section details our AE-based failure diagnosis.

3.3 DEVELOPED TOOL FOR DRIVETRAIN FAILURE DIAGNOSIS

3.3.1 Proposed architecture of the autoencoder

The autoencoder used in our diagnosis tool is composed by 11 layers in the encoder and by the same number of layers in the decoder, since both networks must be symmetric. It is designed to process the vibration signal in time-domain, i.e., employing 1-D sequence data. Indeed, the input of the AE receives sequences of length 4, corresponding to the set of selected time-series features, which are shown in the next section. The AE-network begins with the encoder part, using a Bidirectional long short-term memory (BiLSTM) layer as the first processing step, which allows to capture dependencies between time-steps in both temporal directions, making it useful for complex time-series. BiLSTM is followed by the ReLU activation layer. Afterwards, the AE continues with convolutional 1-D layers, constructed with ReLU activation and dropout layers to prevent overfitting. The latent space, the layer between encoder and decoder, is composed by a single fully-connected layer. After this, a symmetric structure is built for the decoder part, composed by transposed convolutional 1-D and BiLSTMs. At the output, a regression layer based on MSE loss function is utilized. Table 1 shows AE detailed parameters.

Table 1: AE architecture. Source: the Author.

Layer	Architecture
Input	4 time-series features
Encoder	Layer 1: BiLSTM layer (16 hidden units, tanh and sigmoid (state/gate activation functions) Layer 2: ReLU Layer 3: Convolution 1-D layer (16 filters, filter size = 3, stride = 2) Layer 4: ReLU Layer 5: Dropout layer (Probability = 0.2) Layer 6: Convolution 1-D layer (32 filters, filter size = 3, stride = 2) Layer 7: ReLU Layer 8: Dropout layer (Probability = 0.2) Layer 9: Convolution 1-D layer (64 filters, filter size = 3, stride = 1) Layer 10: ReLU Layer 11: Dropout layer (Probability = 0.2)
Latent space	Layer 12: Fully-connected layer (Input size = 64, output size = 1)


Decoder	Layer 13: Transposed Convolution 1-D layer (64 filters, filter size = 3, stride = 1) Layer 13: ReLU Layer 14: Dropout layer (Probability = 0.2) Layer 15: Transposed Convolution 1-D layer (32 filters, filter size = 3, stride = 2) Layer 16: ReLU Layer 17: Dropout layer (Probability = 0.2) Layer 18: Transposed Convolution 1-D layer (16 filters, filter size = 3, stride = 2) Layer 19: ReLU Layer 20: Dropout layer (Probability = 0.2) Layer 21: BiLSTM layer (16 hidden units, tanh and sigmoid (state/gate activation functions)) Layer 22: ReLU Layer 23: Fully-connected (Input size = 32, output size = 1) Layer 24: Regression layer (MSE loss)
----------------	--

3.3.2 Input data to the AE

The designed AE should use the vibration data directly in time-domain, as collected by the WTs CMS, which was detailed in Sec. 3.1.

Data sequences in the input of the designed AE should correspond to the most meaningful time-series features, in terms of carried information. This allows to represent well the whole time-series, which is composed by 16384 data points, since the CMS has 12.8 kHz of sampling frequency and 1.28-sec time window. For doing that, we execute a procedure of time-features ranking, according to their monotonicity. The ranking makes possible that only a few classical time domain features be enough to run our diagnosis. Therefore, the four top features of higher monotonicity are selected here, in order to better express the degradation in the time domain. The features with evaluated monotonicity were: mean, standard deviation, root mean square, shape factor, kurtosis, skewness, crest factor, impulse factor, peak value, signal-to-noise ratio and total harmonic distortion. The ranking is executed for the diagnosed WT (herein called WT5) and is shown in Figure 6. Upon the features ranking, it is decided that the features input to the AE should be the crest factor, the clearance, the impulse factor and the skewness.

Figure 5: Example of a ranking of time-features (WT5). Source: the Author.



Feature	Monotonicity
Matrix_sigstats/CrestFactor	0.0684
Matrix_sigstats/ClearanceF...	0.0518
Matrix_sigstats/ImpulseFactor	0.0484
Matrix_sigstats/Skewness	0.0417
Matrix_sigstats/Mean	0.0217
Matrix_sigstats/PeakValue	0.0217
Matrix_sigstats/RMS	0.0150
Matrix_sigstats/SNR	0.0150
Matrix_sigstats/Std	0.0150
Matrix_sigstats/ShapeFactor	0.0050
Matrix_sigstats/THD	0.0050
Matrix_sigstats/Kurtosis	0.0017

3.3.3 Drivetrain failure diagnosis using the reconstruction error

Given the chosen input variables, they should be reconstructed when passing through the trained AE network with minimum loss. Further, by executing AE training only on vibration data of healthy WT, the output of AE 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, as well as a metric that captures the local differences in each sample. The former is the cumulative sum of the mean absolute errors (MAEs) over the last 5 samples (last 5 days) and the latter is the MAE itself within each sample (the daily value). The calculation of both metrics are shown in Eqs. 4 and 5:

$$cMAE = \sum_{i=N-5}^N MAE_i \quad (4)$$

$$MAE = \frac{1}{n} \sum_{j=1}^n \|x_{ji} - x'_{ji}\| \quad (5)$$

Where N is the day of analysis, n is the number of features in each sample, and x, x' are the encoder inputs and outputs, respectively. Further, $cMAE$ stands for cumulative MAE . Therefore, the anomaly will be detected from both a global and local time-series analysis. The thresholds of failure condition must be obtained by using the $MAEs$ from the healthy data. As we will see in Sec. 4.2, the extreme MAE and $cMAE$ values found for healthy time-series are employed to this. It is important to observe that the obtained thresholds are specific for each wind farm (WF) and should be calculated by training the AE in the healthy data from its WTs. Indeed, the failure limits will be established through the histograms of $MAEs$ from healthy WTs, without recent failure occurrence (Jonas et al., 2022).

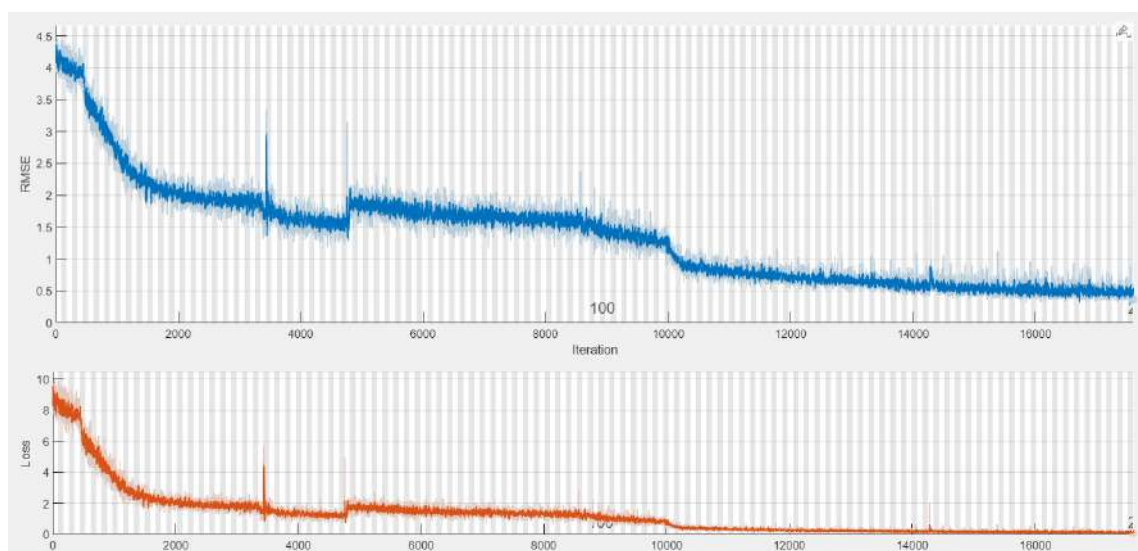
4. RESULTS OF THE DEVELOPED DIAGNOSIS TOOL

It is worth to note the 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 as a proof-of-concept (PoC). This was the chosen accelerometer because it is related to the failure registered in one of the analyzed WTs. Indeed, it is known from operation logs that the fifth WT (herein called WT5), presented a failure in its output shaft bearing. Operator relates the need for bearing replacement at the measurement number 265 of the used WT5 vibration dataset.

4.1 TRAINING THE AE USING HEALTHY DATA

From the used database, it is known that WT3 and WT4 have not presented any drivetrain failures during the monitoring. Their data are employed for AE training on healthy data and consist in 2837 samples of 16384 data points. The dataset must be split in the training, validation and test datasets, where the latter will be used for comparison with the failure WT5 data. Thus, 70% of WT3 and WT4 data were reserved for train and validation (consisting in 1986 samples), and 30% (851) was reserved for testing. In this way, the AE could be tested in these 851 unseen healthy samples and compared to WT5 failure data. The evolution of training process is illustrated by the RMSE and the AE loss function, as illustrated in Figure 6.

Figure 6: Training metrics of AE expressed in number of iterations (horizontal axis) and RMSE and loss function (vertical axis). Source: the Author.



Note that these error metrics refer to the training phase in the entire healthy dataset and not refer to the failure diagnosis. Backpropagation is used to update the network weights, with Adam optimization algorithm running over the mini-batches. Training occurs in 200 epochs and the complete set of training parameters is described in Table 2.

Table 2: AE training main parameters. Source: the Author.

Autoencoder Training Parameters	
Optimizer	Adam
Initial learn rate	0.001
Learn rate drop factor	0.1
Epsilon	1e-8
Batch size	64
Number of epochs	200

4.2 FAILURE DIAGNOSIS

To test the effectiveness of the designed AE in failure diagnosis and realize our PoC, we submit the data of WT5 output shaft bearing to the trained network. Results for the MAE are shown in Figure 7, compared with healthy data coming from the test set of WT3 and WT4. It can be seen that after the 200th measurement there is the persistence of reconstruction error peaks, with increasing values, indicating a possible anomaly. It is noteworthy that previous error peaks are not persistent or growing, consisting in 1-day higher reconstruction errors, which does not characterize a reconstruction anomaly. A similar situation of peak persistence happens around the 300th measurement. However, the warning regions shown in Figure 7 are the result of pure visual inspection. Failure thresholds must be precise and carefully defined. In order to do this, we use the histograms for MAE and cMAE of healthy data, as shown in Figure 8. We establish the larger values of reconstruction error for the healthy data as failure thresholds. For MAE, we define inferior and superior attention limits, corresponding to the regions where the healthy data histograms present almost no occurrences. Indeed, the immense majority of healthy data locates below $MAE < 0.6$ and an even larger quantity of data points below $MAE < 0.8$. Ultimately, beyond the attention limits, the extreme value of healthy data is used as failure threshold at $MAE=1.3$. For the cMAE, which captures the global effect along 5 consecutive days, we use the same procedure to define attention limits between $cMAE=1.4$ and $cMAE=1.6$, while the extreme $cMAE=1.9$ for healthy data is used as failure threshold. Further, cMAE should be analyzed in conjoint with the MAE to get a complete failure diagnosis. After the analysis to define failure limits in terms of reconstruction error metrics, one can utilize the defined thresholds to run the diagnosis. This is carried out in Figures 9 and 10, where the MAE and cMAE values for the analyzed WT5 drivetrain are presented with the respective limits plotted in horizontal lines.

Figure 7: Comparison between reconstruction errors, showing WT5 potential failure regions. Source: the Author.





Figure 8: Distribution of occurrences for MAE and cMAE, healthy data. Source: the Author.



In Figure 9, it is possible to note the presence of several measurement regions within the defined attention limits, which consist in potential failure regions. These occur between samples 84-92, 105-116, 195-232 and 309-338. Note that the regions between 84-92 and 105-116 have smaller extension with large discrepancy of subsequent peaks. Regions between measurements 195-232 and 309-338, on the other hand, present a much larger extension and consistency of peaks, with smaller temporal distance between

them and less variation in their amplitude. Additionally, peaks in region 195-232 even present a clear increasing trend, probably associated with the rise of bearing failure. The trend line goes until surpassing the extreme failure threshold (MAE=1.35) at MAE=1.4. Based on this analysis, we could already suppose the measurement 232 as the first failure diagnosis. Nevertheless, we should corroborate this by analyzing the behavior of the cMAE. As shown in Figure 10, a large range of samples within cMAE attention limits are located over the measurements number 195 to 232, confirming the consistent presence of increased reconstruction errors in this region. Further, at measurement 232, the cMAE practically surpasses the extreme value found in the histogram of the right side of Figure 8. After a little intermittency, the cMAE values continues to rise and reaches once again the cMAE threshold at the sample number 274. In addition, observe that from measurements 190-232 and afterwards, there is a trend of increasing in the peak maximum values, attaining cMAE=2.9 in the measurement 381. Combining the results of MAE (representing local error effect) and cMAE (global error effect), we can state confidently that the 232th measurement is the first failure diagnosis, when the operator must cautiously begin the planning of maintenance activities. It is remarkable that in the 232th sample, both failure thresholds are reached and the growing in reconstruction errors have already been set for a long time (since day 190). The day number 232 is the final result of our AE diagnosis tool.

Figure 9: Failure diagnosis chart based on our autoencoder diagnosis tool, MAE analysis. Source: the Author.





Figure 10: Failure diagnosis chart based on our autoencoder diagnosis tool, cMAE analysis. Source: the Author.



4.3 COMPARISON WITH TRADITIONAL DIAGNOSTIC OF DRIVETRAIN FAILURES

In order to compare the AE-diagnostic with the traditional diagnostic, we analyze WT5 dataset using FFT and envelope analysis. In the present work, the Hilbert transform is executed to obtain the signal envelope. It is well known that the signals of initial bearing degradation are usually encapsulated in high-frequency resonances. The absolute value of Hilbert transform allows to obtain signal demodulation, revealing the bearing defect frequencies, which can be verified by further extracting the FFT of the envelope. More details can be found in, e.g., (Randall, 2014).

The location of the bearing failure in WT5 output shaft was established in the inner race. The calculation for the defect frequency of this specific failure mode has been carried out in the usual way,

$$BPF_I = \frac{nf_s}{2} \left\{ 1 - \frac{d}{D} \cos\alpha \right\} \quad (5)$$

Where BPF_I is the Ball Pass Frequency Inner race and D , d , α , n and f_s are the pitch diameter, ball diameter, contact angle between the ball and the cage, number of rolling elements, and the rotating speed of bearing (Hz), respectively. For the faulty WT5 bearing, this value was calculated in each rotational speed and monitored carefully. It is important to emphasize that the information of what type of failure is developing is not known a priori. Therefore, in a general case, all the bearing failure frequencies would

need to be monitored (and not only the BPF), which makes the failure diagnosis even more difficult. This is another advantage of our AE diagnosis tool, which is independent of the failure type.

In Figure 10, we can see the FFT of the envelope fat the beginning of WT5 operation, with the indicated BPF amplitude. Executing the WT5 monitoring, it is observed that the failure is not evident until approximately the measurement of number 260. The FFT of the envelope for the faulty bearing is shown in Figure 11. As the designed AE indicated the beginning of failure at measurement of number 232, this represents a 28-days advance in drivetrain warning.

Figure 11: FFT of WT5 envelope, measurement number 50. Source: the Author.





Figure 12: FFT of WT5 envelope, measurement number 260. Source: the Author.



5. CONCLUSIONS

In the present paper, we have presented a diagnostic solution for WT drivetrains considering vibration CMS. Our tool is based on the design of a deep learning AE, composed by 24 layers, which

processes the signal directly in the time domain. This eliminates the need for tracking the specific frequency of drivetrain defects, sometimes hard to obtain and distinguish in the complex vibration environment of a WT. Further, the procedure also issues warnings of possible drivetrain problems long before the traditional vibration analysis. This happens due to the ability of the deep AE to learn the non-linear and intricate relations within the time-series, providing means of identification of what is a healthy and what is an anomaly condition. To sum up, the herein presented tool achieves the following outcomes:

- Identification of failures direct from time-series, not relying on frequency feature extraction and specific frequency defects.
- Independence of traditional FFT-envelope monitoring of each sample.
- Being an unsupervised learning method, the designed AE does not depend on the availability of previous failure data. This allows the use of the method since the start of WF operation.
- Identification of failures much earlier (approximately 28-days before) than the traditional diagnosis methods.
- Possibility of detecting failures in other components or sub-systems, by the re-training of the AE on corresponding data.

Future works comprise the application of the developed tool in other WT databases. Also, the use of other CMSs, such as temperature monitoring, is envisaged, as well as the inclusion of several SCADA data as part of the diagnosis procedures. At last, we plan to continue our work over the prognostic of WT components, estimating the RUL with especially designed DL-networks.

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.ress.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.

Pecht, M., Zhao, M., Tang, B., & Deng, L. (2020). Multiple wavelet regularized deep residual networks for fault diagnosis. *Measurement: Journal of the International Measurement Confederation*, 152. <https://doi.org/10.1016/j.measurement.2019.107331>

- Peeters, C., Guillaume, P., & Helsen, J. (2018). Vibration-based bearing fault detection for operations and maintenance cost reduction in wind energy. *Renewable Energy*, 116, 74–87. <https://doi.org/10.1016/j.renene.2017.01.056>
- Randall, E. R. B. (2014). *Machine Diagnostics using Advanced Signal Processing*.
- Rezamand, M., Kordestani, M., Carriveau, R., Ting, D. S. K., Orchard, M. E., & Saif, M. (2020). Critical Wind Turbine Components Prognostics: A Comprehensive Review. In *IEEE Transactions on Instrumentation and Measurement* (Vol. 69, Issue 12, pp. 9306–9328). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/TIM.2020.3030165>
- Scheeren, B., Kaminski, M. L., & Pahlavan, L. (2022). Evaluation of Ultrasonic Stress Wave Transmission in Cylindrical Roller Bearings for Acoustic Emission Condition Monitoring. *Sensors*, 22(4). <https://doi.org/10.3390/s22041500>
- 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>

Wind Farm Wake Influence Analysis Based on Actual Engineering

Xianyang Wang^{1,*}, Jing Zhang¹, Jingwen Yang¹

¹. Beijing RETEC New Energy Technology Co., Ltd., Beijing 100079,

wangxianyang@bjretec.com (X.W), zhangjing@bjretec.com (J.Z), yangjingwen@bjretec.com (J.Y)

* Correspondence: wangxianyang@bjretec.com (X.W),

ABSTRACT

Wake is a significant factor influencing wind power generation, and it is a risk factor that must be addressed early in the development of wind power projects. A more accurate assessment of wake can reduce the risk of wind energy project construction. This paper conducts research using data from the production met mast of a wind farm in Tianjin. The data of met mast truly records the wind speed attenuation caused by the wind turbine's wake. The free wind speed time series at the height of the hub is created using model-based data reconstruction and Markov chain restoration using wind data at a height of 30m, where the met mast is not affected by the wake. Using the free wind speed as input data and various wake models for simulation, it is discovered that the coupled wake model has a relatively higher accuracy.

Keywords:

Wind-turbine wakes, wake model, met mast, Eddy Viscosity wake model, ASM-EV wake model

INTRODUCTION

Wind energy, as a renewable energy, has attracted the attention and promotion of all countries around the world due to the rapid growth of energy demand and the rapid consumption of fossil fuels. China stated in 2020 that it would be carbon neutral by 2060[1]. In order to achieve this goal, China has implemented a number of policies. China's total installed wind power capacity will reach 328.48GW by 2021[2], according to the National Energy Administration of China. According to studies, the carbon dioxide emission intensity of wind energy in China is more than 98% lower than that of traditional fossil fuels, and the emission reduction effect can reach 84-98%[3].

Regarding the driving factors for wind power installation, the main positive factors for wind power installation were technological factors and environmental factors, while economic factors and resource endowments showed positive spatial spillover effects. In terms of carbon emission reduction potentials, the carbon emission reduction potentials of China's wind power installation have increased year after year[4].

Wake is a major cause of wind farm power loss. Accurate evaluation of wind farm wake effect is critical for optimal arrangement, unit selection, and wind farm design, among other things. As a result, the influence of wake between units has become increasingly important in preliminary development and design work such as wind turbine layout. The wind energy field currently has a large number of mature wake models, such as the Park wake model[5] and Fuga wake model[6] in the WAsP (Wind Atlas Analysis and Application Software)[7][8], the EV wake model (Eddy Viscosity Wake Model)[9] in the WindPRO[10]. With the rapid development of wind power projects in recent years, researchers have not stopped researching and developing wake models, shifting from a single wake model to a coupled wake model[11]. Such as DAWM (Deep Array Wake Model) [12] and ASM-EV (Area Slowdown Eddy-Viscosity wake model) [13] in the Openwind[14], LWF (Large wind farm wake model)[15] in the Meteodyn WT[16]. Philippe Beaucage et al. (2012) validated six wake models in two offshore wind farms, with the DAMW wake model providing the

most accurate assessment of wind turbine wake[17]. Beatriz Caadillas et al. (2023), the extended strategies are compared with large-eddy simulations of the flow through a cluster of three wind farms located in the German sector of the North Sea, as well as real measurements of wind power within these wind farms, to test the rationality of the DAWM model in capturing additional blocking and wake losses in real wind farm clusters[18]. Zhang J et al. (2023) used the EV wake model, DAWM wake model, and ASM-EV wake model to validate the power generation of mountain wind farms. The results showed that the coupled model outperformed the traditional wake model in terms of simulation accuracy [19].

In this paper, wind measure data from a met mast in a wind farm are processed and analyzed using Windographer, in accordance with the industry standard GB/T 18710-2002 "Methodology of wind energy resource assessment for wind farm"[20] and the requirements of the wind data processing part of IEC61400-1 Wind energy generation systems 2019[21]. The free-flow wind speed at 105m height of met mast is first restored by analyzing the correlation of wind speed in different height layers of the same met mast. The wind speed results under different wake models are then calculated in four typical time periods using the Modified Park wake model, the EV wake model, and the ASM-EV. This paper investigates the evaluation effect of the three wake models on the influence degree of the wake by comparing the wind speed affected by the wake with the free flow wind speed after reduction in the same period.

WAKE MODEL

MODIFIED PARK WAKE MODEL

Park wake model is a linear wake model suitable for flat terrain based on the one-dimensional momentum conservation principle of ideal wind turbine proposed by Katic and N.O.Jensen of Ris laboratory in Denmark[22]. It is a one-dimensional linear wake model that does not account for turbulence. The model assumes that:

- (1) the initial diameter of the wake area is the diameter of the wind turbine from behind the wind wheel;
- (2) the wake rate increases linearly; and
- (3) the distribution of wake velocity on the cross section is uniform.

The power coefficient of the wind turbine in the actual project cannot reach the value of the ideal model, so it extends the improved Park wake model, namely the Modified Park wake model, which is more in line with the actual project. The model is widely used in software such as WAsP, WindPRO, WindFarmer, WindSim, WT, and others. The model assumes the wake boundary expands linearly with a width of $D+2kx$. The expression formula is as follow:

$$V_{down} = V_{up} \left[1 - (\sqrt{1 - C_t}) \left(\frac{D}{D + 2kx} \right)^2 \right]$$

Where, V_{down} is the downwind wind speed, unit [m/s], V_{up} is the upwind wind speed, unit [m/s], C_t is the wind turbine thrust coefficient; D is the wind turbine impeller diameter, unit [m], x is the distance from the wind turbine, and k is the wake attenuation coefficient which formula is:

$$k = 1/2 \ln \left(\frac{Z}{Z_0} \right)$$

Where Z is the hub height of the wind turbine and Z_0 is the surface roughness.

Eddy Viscosity Wake Model

Ainslie's two-dimensional axisymmetric eddy current theoretical model (EVM wake model) assumes

that the wake region is two-dimensional axisymmetric and that the coordinate system is cylindrical. To calculate the wake of an axisymmetric wind turbine, the eddy current viscosity constraint and time-averaged RANS formula are used. The model considers fluid turbulence in the flow field, the wind speed is non-linear in the cross-section direction, and the air flow is assumed to be incompressible. The wake region is divided into three sections in the model: the near wake region, the transition region, and the far wake region. The expression formula is as follow[9]:

$$1 - \frac{U}{U_0} = D_M \exp \left\{ -3.56 \left(\frac{r}{b} \right)^2 \right\}$$

Where, U_0 is the average wind speed of free flow, U is the wind speed at the distance r from the wake centerline, D_M is the initial wind speed attenuation at the wake centerline, b is the wake width parameter, the formula is as follows:

$$b = \sqrt{\frac{3.56 C_T}{8 D_M (1 - 0.5 D_M)}}$$

Where, D_M is related to thrust coefficient C_T and turbulence intensity, and the expression formula is as follows:

$$D_M = C_T - 0.05 - (16 C_T - 0.5) \frac{I}{1000}$$

Where I is the ambient turbulence intensity.

AREA SLOWDOWN EDDY-VISCOSITY WAKE MODEL

The Area Slowdown Eddy-Viscosity wake model (ASM-EV) considers the wind farm as a whole. The wind farm is related to the inversion layer at the top of the atmospheric boundary layer as an additional surface roughness and as a gravity wave generator, which means that even though the wind speed of the atmospheric boundary layer above the wind field is uniform, it is very sensitive to the decrease of the lower wind speed and the decrease of energy, so there will be changes in the pressure gradient and the generation of gravity waves. The model calculates the interaction force between atmosphere and wind farm based on the conservation of kinetic energy and the above influencing factors, which is a top-down simulation method of fluid kinetic energy. The basic equation is[13]:

$$\frac{v(t)}{v_0} = 1 + \left(\frac{v}{v_0} - 1 \right) \exp(-at)$$

Where v_0 is the free wind speed of upstream wind turbine at hub height, v is the wind speed of downstream wind turbine at hub height.

$$at = ku * z / \Delta z^2$$

Where z is PBL's height, h is wind turbine hub height, $\Delta z = z - h$, u^* is the friction velocity.

TEST CASES

The research project chosen for this paper is located in Tianjin's Dagang District. The G132-5.0MW units have a blade length of 64.5m, a scavenging surface diameter of 132m, and a hub height of 105m.

Figure 1 depicts the relative position of the unit and the met mast (the recorder is NRG): the turbine unit is 50 ° (230 °) 190 m south of the met mast, and the turbine unit is 15 ° (105 °) 570m south-east of the met mast.



Figure 1 Relative position of met mast and wind turbine

The met mast is located in the plain area. The height of the mast is 105m and the sampling interval is 1s. The wind measuring equipment is NRG wind speed sensor. At present, the 10-minute wind data of the met mast in 2018 are collected. the equipment information and structure of the met mast are shown in Table 1 and Figure 2.

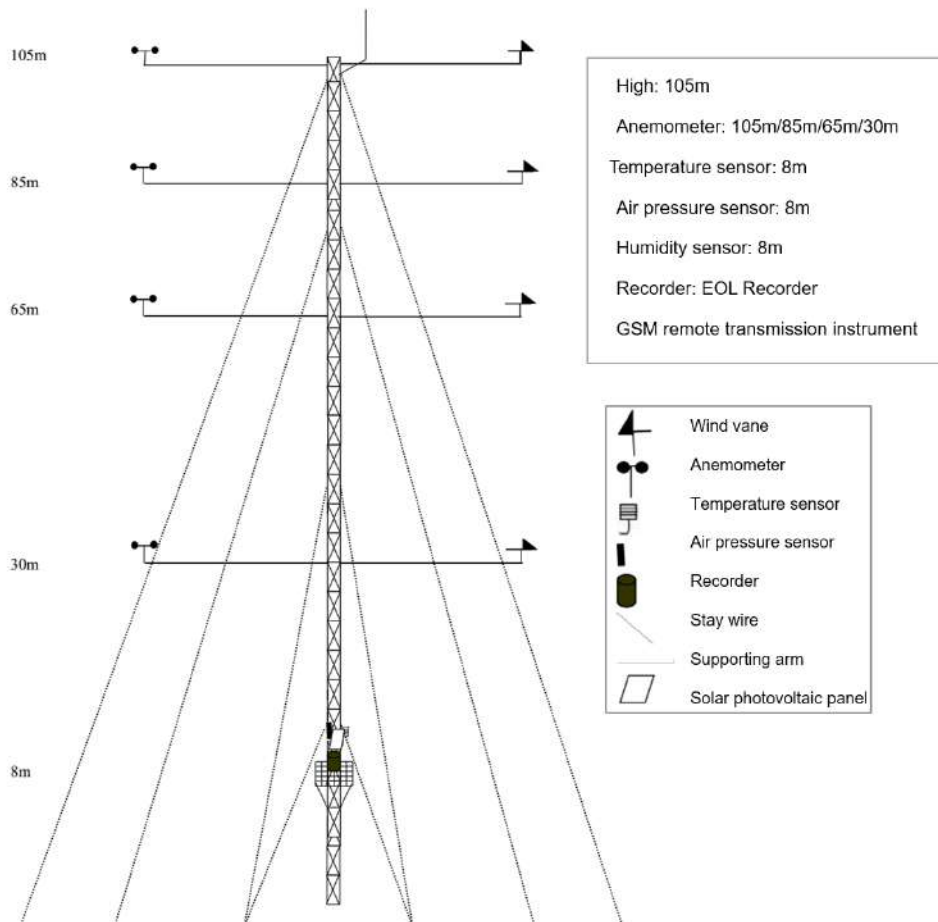


Figure 2 Schematic diagram of met mast structure

As shown in Figure 2, the met mast is equipped with anemometers and wind vanes at 105m, 85m, 65m, 50m and 30m, and thermometers, barometers and data recorders are installed at the height of 8m.

TEST METHODOLOGY

First, determine the effect of the wake on the mast height and angle, as well as the plausibility of the measured data at 30m and 105m heights. After removing invalid data, two valid data time series are gathered. Then, using the pattern-based data reconstruction[23] and Markov chain[24], a set of free-stream wind speeds at a height of 105m is created, which is used as a comparative data source to validate the wake model in this paper.

DETERMINATION OF THE INFLUENCE ANGLE OF WAKE

The range of the influence sector of the wind turbine on the met mast is determined using the calculation formula given in the IEC 61400-12-1: 2017 standard[25], which is:

$$\theta = 1.3 \arctan\left(\frac{2.5D_n}{L_n} + 0.15\right) + 10$$

where D_n is the diameter of the wind turbine and L_n is the linear distance between the unit and the met mast.

The influence angle is calculated using the actual distance between the met mast and the wind turbine in the project example: the met mast is 50 degrees (230 degrees) west of the met mast, and the wind turbine is 15 degrees (105 degrees) south of the met mast. The wake influence area of the turbine to the met mast is 90.70 degrees, that is, the wake area is 184.2 ° 275.0 °, and the wake area is 56.92 degrees, that is, the wake area is 76.5 ° 133.5 °.

Filter the experimental wind data time step, that is, the time step in which the wind turbine's wake affects the met mast, using the method described above (Table 2).

Table 1 The period when the met mast is influenced by the wake

Period	Actual waked wind speed at 105m [m/s]	Wind turbines affecting met mast
2018/09/16 15:20 ~ 22:00	3.25	1#
2018/12/12 12:00 ~ 22:50	3.62	1#
2018/08/27 14:00 ~ 21:00	4.10	2#
2018/10/15 14:40 ~ 19:40	3.19	2#

DETERMINATION OF WAKE INFLUENCE HEIGHT

Both sets' hub height and blade length are 105m and 64.5m, respectively, implying that the lowest point from the tip to the ground is 40.5m and the highest point is 169.5m from the ground.

When the wind is blowing from the southwest, it passes through the 1# wind turbine and reaches the meteorological mast. The meteorological mast is currently located in the wake area of the 1# wind turbine. When the wind is blowing from the southeast, it passes through the 2# wind turbine and reaches the meteorological mast. The meteorological mast is currently located in the wake area of the 2# wind turbine.

On August 27, the wind direction is southeast, with gusts ranging from 105 to 125 degrees. The met mast is located in the wind turbine's wake influence area. At this time, the wind speed at 30m is clearly greater than that at other height layers of the met mast.




Figure 3 The influence of 2# Wind Turbine on Met Mast

As shown in figure 5, the wind direction is southwest from 11:00 to 22:00 on December 12, and the met mast is located in the wake influence area of the wind turbine. At this time, the wind speed at the height of 30m is obviously higher than that in other height layers of the met mast.



Figure 4 The influence of 2# Wind Turbine on Met Mast

The wind speed at the heights of 65m, 85m, and 105m has a significant downward trend when the

meteorological mast is in the wake influence area, according to the results of the measured data analysis, while the wind speed at the height of 30m is less affected. The wind turbine blade sweep area's lowest point is 40.5m from the ground, which is 30m higher than the anemometer installed on the meteorological mast. Wake affects wind data at heights of 65m, 85m, and 105m.

RESULTS AND ANALYSIS

In this paper, the actual wind measurement data at the wind measurement mast's height of 30m is used as the reference value for calculating the degree of influence on the wake. The free wind speed at 105m is restored using pattern-based data reconstruction and Markov data reconstruction methods.

Import the time-series data of the free wind speed at 105m from the restoration above into Openwind software, and use each wake model to calculate the wind speed at 105m of the met mast, and compare it to the wind speed measured by the met mast to verify the wake model's applicability.

Figure 5 depicts a selection of data from 15:20 to 22:00 on September 16, 2018. The wind direction is currently between 230° and 267°, and the met mast is located in the wake area of the 1# wind turbine. When compared to the PARK model fitting data, the EV model and ASM-EV model fitting data fit the actual data better, but the fluctuations are more noticeable.




Figure 5 Comparison of calculation results of wake model (2018/09/16 15:20 - 22:00)

Figure 6 shows the wind speed and direction data for nearly 11 hours on December 12, 2018, from 12:00 to 22:50. The wind direction is currently between 240° ~ 260°, and the met mast is located in the wake of the 1# wind turbine. The wake model's fitting data is significantly higher than the actual data, while the ASM-EV model's fitting data is the closest to the actual data.

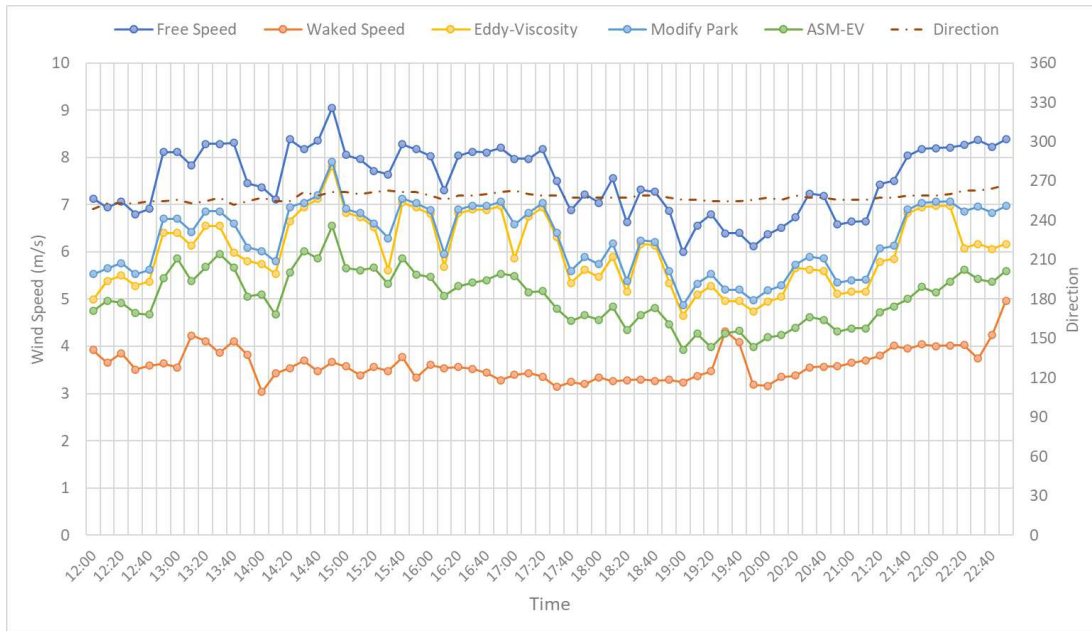


Figure 6 Comparison of calculation results of wake model (2018/12/12 12:00 - 22:50)

Figure 7 shows wind speed and direction data for nearly 7 hours on August 27, 2018, from 14:00 to 21:00, when the wind direction is between 105° ~ 130°. The met mastis located in the wind turbine's wake. In a situation where the wind speed fluctuates little, the EV model is very close to the ASM-EV model fitting data trend. When the wind belt varies greatly, the EV model is overly sensitive to changes in wind speed, resulting in large fluctuations.




Figure 7 Comparison of calculation results of wake model (2018/08/27 14:00 - 21:00)

Figure 8 depicts 5-hour wind speed and direction data collected between 14:40 and 19:40 on October 15, 2018, when the wind direction is between 108° ~ 125°. The met mastis located in the wind turbine's wake. There are significant differences between the wake model's fit data and the actual data in the trend.




Figure 8 Comparison of calculation results of wake model (2018/10/15 14:40 - 19:40)

According to the statistical data in the Table.2, the wake models all underestimate the wake to varying degrees, with the ASM-EV model calculating the wind speed after the wake closest to the actual value. The wind speed after the wake calculated by the Modified Park wake model has a maximum deviation of 2.65m/s and a minimum deviation of 0.83m/s. The EV wake model calculates the wind speed after the wake with a maximum deviation of 2.39m/s and a minimum deviation of 0.37m/s. The ASM-EV model calculates the wind speed after the wake with a maximum deviation of 1.52m/s and a minimum deviation of 0.01m/s. The ASM-EV wake model's accuracy has increased by 10.17% when compared to the Modified Park wake model, and the EV wake model's accuracy has increased by 5.91%.

Table 2 Data statistics summary

Period	2018/09/16	2018/12/12	2018/08/27	2018/10/15
	15:20- 22:00	12:00-22:50	14:00- 21:00	14:40- 19:40
Free wind speed [m/s]	5.44	7.52	6.05	5.97
Actual waked wind speed[m/s]	3.25	3.62	4.10	3.19
Wake Efficiency [%]	40.26%	51.86%	32.19%	46.57%
Waked speed by Modified Park	4.08	6.27	5.12	4.98
Wake Efficiency [%]	25.05%	16.67%	15.35%	16.52%
Waked speed by EV	3.62	6.01	5.02	4.77
Wake Efficiency [%]	33.43%	20.06%	16.96%	20.18%
Waked speed by ASM-EV	3.24	5.03	4.86	4.71
Wake Efficiency [%]	40.52%	33.06%	19.60%	21.11%

The 1# wind turbine is only 190 meters away from the met mast, and its wake has a 40.26% and 51.86% influence on the wind speed of the met mast. The 2# wind turbine is 570 meters away, and the influence of the 2# wind turbine's wake on the wind speed of the met mast is 32.19% and 46.57%, respectively.

CONCLUSION

This paper discusses the wake model by analyzing how much the wind turbine wake affects the met mast in the actual project.

1. When the wake calculation results of the time series are compared, each wake model underestimates the wind turbine's wake effect, with the deviation reaching 35.19%.
2. The ASM-EV wake model calculates wind speed that is closer to the measured wind speed than the Park wake model and the EV wake model. The accuracy of the ASM-EV wake model has increased by 10.17% when compared to the Modified Park wake model, and the accuracy of the EV wake model has increased by 5.91%.
3. The 1# wind turbine is closer to the met mast than the 2# wind turbine, and its wake has a greater impact on the met mast.
4. To facilitate quantitative analysis of the degree of wake influence, the measured data at 30m of the met mast is regarded as the value unaffected by wake, which has certain errors and uncertainties.

The research in this paper focuses on the short-term time window, as opposed to the full-year analysis. Wake analysis based on meteorological masts lacks the universality of large-scale wind farm wakes. We hope that the research in this paper can serve as a reference for peers, and we will continue to analyze more cases to improve the research's guiding significance for practical engineering.

REFERENCE

- [1]. National Energy Administration Releases 2021 National Electric Power Industry Statistics. Jan 26,2022
- [2]. Wind power capacity in China 2014-2021.Published by Statista Research Department, Jun 17, 2022
- [3]. Xu, K., Chang, J., Zhou, W., Li, S., Shi, Z., Zhu, H., .& Guo, K. (2022). A comprehensive estimate of life cycle greenhouse gas emissions from onshore wind energy in China. *Journal of Cleaner Production*, 338, 130683. 2022
- [4]. Han, M., Sun, R., Feng, P., & Hua, E. (2023). Unveiling characteristics and determinants of China's wind power geographies towards low-carbon transition. *Journal of Environmental Management*, 331, 117215.
- [5]. Jensen, N.O. A Note on Wind Generator Interaction; Risø National Laboratory: Roskilde, Denmark, 1983.
- [6]. Ott, S., Berg, J., & Nielsen, M. (2011). Linearised CFD models for wakes.
- [7]. Jackson, P.S.; Hunt, J.C.R. Turbulent wind flow over a low hill. *Q. J. R. Meteorol. Soc.* **1975**, *101*, 929–955.
- [8]. WAsP- the Wind Atlas Analysis and Application Program. <http://www.wasp.dk/>.
- [9]. Ainslie, J.F. (1988). Calculating the flow field in the wake of wind turbines. *Journal of Wind Engineering and Industrial Aerodynamics*, 27 (1988), 213-224.
- [10]. Per Nielsen, et.al. (2006). The WindPRO manual edition 2.5, EMD International A/S. 2006,7-12.
- [11]. Stevens, R. J., Gayme, D. F., & Meneveau, C. (2015). Coupled wake boundary layer model of wind-farms. *Journal of renewable and sustainable energy*, 7(2), 023115.

- [12]. Brower, M. C., & Robinson, N. M. (2012). The openWind deep-array wake model: development and validation. AWS Truepower.
- [13]. Emeis, S. (2018). Wind energy meteorology: atmospheric physics for wind power generation. Springer.
- [14]. OpenWind (2010). OpenWind – theoretical basis and validation[R]. Technical report from AWS Truepower, Albany(NY), USA.26.
- [15]. TROMEUR, E., PUYGRENIER, S., & SANQUER, S. Investigation and validation of wake model combinations for large wind farm modelling in neutral boundary layers.
- [16]. Li, R., Delaunay, D., & Jiang, Z. (2015). A new turbulence model for the Stable Boundary Layer with application to CFD in wind resource assessment. EWEA Proceedings, 9.
- [17]. Beaucage, P., Brower, M., Robinson, N., & Alonge, C. (2012). Overview of six commercial and research wake models for large offshore wind farms. Proceedings of the European Wind Energy Associate (EWEA), 18.
- [18]. Cañadillas, B., Foreman, R., Steinfeld, G., & Robinson, N. (2023). Cumulative interactions between the global blockage and wake effects as observed by an engineering model and large-eddy simulations. *Energies*, 16(7), 2949.
- [19]. Zhang, J., Chen, J., Liu, H., Chen, Y., Yang, J., Yuan, Z., & Li, Q. (2023). Applicability of WorldCover in Wind Power Engineering: Application Research of Coupled Wake Model Based on Practical Project. *Energies*, 16(5), 2193.
- [20]. GB/T 18710-2002 Methodology of wind energy resource assessment for wind farm. China Standard Press, 2002, GB/T187102002 (in Chinese)
- [21]. Madsen, P. H., & Risø, D. T. U. (2008). Introduction to the IEC 61400-1 standard. Risø National Laboratory, Technical University of Denmark.
- [22]. Katic, I.; Højstrup, J.; Jensen, N.O. A simple model for cluster efficiency. In Proceedings of the European Wind Energy Association Conference and Exhibition, Rome, Italy, 7–9 October 1986; Volume 1, pp. 407–410.
- [23]. King C, Hurley B (2004) 'The Moulded Site Data (MSD) wind correlation method; description and assessment', *Wind Engineering*, **28**, 6, 649-666
- [24]. Ching, W. K., & Ng, M. K. (2006). Markov chains. Models, algorithms and applications.
- [25]. International Electrotechnical Commission. (2005). Wind turbines-Part 12-1: Power performance measurements of electricity producing wind turbines. IEC 61400-12-1.

Rotina de Manutenção Preditiva em Aerogeradores Utilizando Análise de Dados

Breno Carvalho, Lucas Colares, Henrique Diógenes, Raphael Costa

Engenharia de Desempenho e Confiabilidade - O&M

Casa dos Ventos

Av. Desembargador Moreira, 1300, SC-1501 - Fortaleza | CE

breno.carvalho@casadosventos.com.br, lucas.colares@casadosventos.com.br,
henrique.diogenes@casadosventos.com.br, raphael.costa@casadosventos.com.br

RESUMO

A complexidade da operação de um parque eólico exige um monitoramento minucioso dos sinais dos sensores e das medições. A previsão de falhas e, conseqüentemente, a otimização do desempenho exigem monitoramento avançado de turbinas eólicas usando ciência de dados e estatística. Foi desenvolvido um processo de controle para monitorar sinais com tendências de anormalidade em seu comportamento, a fim de abordar a correção em janelas ótimas de manutenção e verificar sua eficácia. O estudo consistiu em comparar o comportamento geral de todo o parque eólico para priorizar aerogeradores com tendência de anomalia em suas variáveis medidas. Como metodologia, adotou-se uma análise estatística; seguido de regressão de aprendizado de máquina e modelos de *clustering* para classificar *outliers*; em seguida, foi realizada uma normalização das variáveis para priorizar as medidas mais críticas. Por fim, foi criada uma funcionalidade em um sistema proprietário, desenvolvido em um *framework web Python*, para melhorar o monitoramento da execução da manutenção e sua eficácia sobre os parâmetros indicados. Com a implementação desta ferramenta e processo, uma melhor compreensão do comportamento da turbina eólica permitiu a detecção preditiva de anomalias, otimização aprimorada do planejamento de manutenção e maximização da disponibilidade baseada em energia, realizando intervenções em conjunto com outras manutenções preventivas ou durante oportunidades de poucos recursos eólicos, conforme estimado por modelos de previsão de energia.

Palavras-chave: monitoramento por condição, manutenção preditiva, análise estatística, aprendizado de máquina, estruturação *web*.

ABSTRACT

The complexity of operating a wind farm requires a fine monitoring of signals from sensors and measurements. Failures prediction and, consequently, performance optimization demands advanced wind turbine monitoring by using data science and statistics. A control process was developed to monitor signals with abnormality tendencies in their behavior in order to address the correction in optimal maintenance windows and check its effectiveness. The study consisted of comparing general behavior of the entire wind farm to prioritize wind turbines with anomaly trends in their measured variables. As a methodology, a statistical analysis was adopted; followed by machine learning regression and clustering models in order to classify outliers; afterwards, a normalization of variables was carried out to prioritize the most critical measurements. Finally, a functionality was created in a proprietary system, developed in a Python web framework, to improve monitoring of maintenance execution and its effectiveness over the indicated parameters. With the implementation of this tool and process, a better understanding of the wind turbine behavior allowed predictive detection of anomalies, enhanced maintenance planning optimization and maximized energy based availability, by carrying out interventions together with other preventive maintenance, or during low wind resource opportunities, as estimated by power forecast models.

Keywords: condition monitoring, predictive maintenance, statistical analysis, machine learning, web framework.

1. INTRODUÇÃO

Um aerogerador é um sistema complexo composto por diversos subsistemas interconectados que possuem interfaces extensamente monitoradas por sensoriamento [1]. Cada subsistema contribui de forma única para o funcionamento adequado da máquina e por isso deve ser constantemente monitorado. Como visão geral do desafio do monitoramento de uma turbina, a ordem de grandeza da quantidade de variáveis existentes em um aerogerador pode chegar a algumas centenas, e em uma usina com dezenas de aerogeradores, a milhares.

Para que exista a possibilidade de se acompanhar com qualidade uma grande quantidade de aerogeradores em operação, é necessária a implementação de um processo robusto, inteligente e automatizado de coleta, tratamento e análise de dados [2].

A negligência no acompanhamento da evolução dos aerogeradores torna a manutenção puramente corretiva, o que pode ser muito oneroso principalmente nos casos de falhas em grandes componentes. Uma alternativa a essa abordagem é o desenvolvimento de análises preditivas que auxiliem no planejamento da manutenção a fim de que sejam aproveitados os momentos de baixo recurso eólico e, assim, as perdas de geração sejam mínimas [3,4].

Realizar comparação contínua de cada máquina em relação ao complexo como um todo é uma forma eficiente de acompanhar o comportamento dos subsistemas dos aerogeradores. Visto que se espera que cada máquina do complexo evolua de forma similar, torna-se possível a detecção de eventuais tendências de anormalidade [5].

Como forma de quantificar o quanto uma série temporal apresenta tendências no tempo em comparação a um referencial de controle, pode-se utilizar análises estatísticas e *machine learning*. Após realizar uma primeira classificação individual, a quantidade de variáveis anômalas pode ser ainda numerosa, devendo-se levar em consideração que algumas das variáveis com desvio em relação às demais não implicam necessariamente em uma parada futura do aerogerador. Para garantir melhor sensibilidade na percepção dos desvios, a priorização pode ocorrer a partir da normalização dos resultados.

No presente trabalho, é apresentada uma metodologia para seleção e acompanhamento de variáveis críticas em complexos eólicos, com interferência no planejamento da manutenção, permitindo que determinadas manutenções preditivas nos aerogeradores sejam executadas em momentos ótimos de manutenção, seja por aproveitamento a manutenções já previamente programadas, seja por seleção de janelas de baixo recurso eólico.

2. MÉTODO DO ESTUDO

Os eventos de indisponibilidade e subperformance em aerogeradores podem estar atrelados à progressão de comportamentos anômalos nas medidas de seus subsistemas. A observação de tendências de ultrapassagem de valores limites de temperaturas, pressões, níveis de fluidos e outras variáveis é uma das melhores formas de capturar precocemente irregularidades na turbina.

A detecção de desvios por si só, no entanto, é insuficiente para garantir que os defeitos sejam sanados. A ferramenta desenvolvida neste trabalho mescla a análise das variáveis desviadas com o gerenciamento da manutenção, a ocorrer em janelas otimizadas de recurso eólico, e com a checagem da efetividade da intervenção a partir da validação da mudança de tendência da variável em análise.

A metodologia adotada para a concepção desta ferramenta, sequencialmente, foi: coleta de dados das variáveis analógicas dos aerogeradores, tratamento estatístico seguido da aplicação de modelos de *machine learning* de regressão e clusterização para classificar outliers, ordenamento de criticidade das medidas a partir da normalização das variáveis e, por fim, o desenvolvimento de plataforma própria em *Python*, utilizando um *web framework* para permitir a visualização das tendências anômalas, das atividades programadas e executadas pela manutenção para cada aerogerador e possibilitar a indicação seguida da correção de medidas de turbinas com anomalias.

2.1 Tratamento de Dados Provenientes de Variáveis Analógicas dos Aerogeradores

Os dados de variáveis analógicas dos aerogeradores podem ser adquiridos do sistema SCADA (*Supervisory Control and Data Acquisition*) em alta granularidade para conduzir análises. Para o escopo do presente trabalho, as medidas analógicas foram agrupadas em médias de 10 minutos, bem como coletados valores mínimos e máximos do mesmo período de análise.

A partir dos dados obtidos, assume-se que os aerogeradores devem comportar-se de maneira similar com relação aos seus pares sob influência do mesmo recurso eólico, caso estejam sob regime de produção [5].

Para garantir que as condições acima sejam atendidas, exclui-se da análise pontos em que explicitamente seja conhecido que a turbina não opera em condições normais, como situações nas quais:

- alarmes ativos que anunciam alguma falha estejam contidos nos períodos agregados em 10 minutos;
- existe indisponibilidade do BoP (*Balance of Plant*).

2.2 Detecção de Anomalias a partir das Variáveis Analógicas dos Aerogeradores

O estágio preliminar da detecção de anomalias é a análise estatística de cada variável em cada estampa de tempo. São calculadas as medianas, quartis superiores (Q75) e quartis inferiores (Q25). Os limites inferiores e superiores são estabelecidos a partir dos seguintes cálculos:

$$\text{Limite superior} = Q75 + 1.5 * IQR$$

$$\text{Limite inferior} = Q25 - 1.5 * IQR$$

Onde IQR (*Interquartile Range*, ou intervalo entre quartis) calcula-se por:

$$IQR = Q75 - Q25$$

Por fim, as variáveis anômalas são classificadas em dois casos, apresentadas a seguir.

2.2.1 Classificação de anomalias: percentual de pontos outliers elevado

É classificada como variável anômala quando o percentual de pontos outliers superar 50% para os últimos 15 dias, considerando as exclusões de máquina parada.

Classifica-se também como variável anômala quando o percentual de outliers superar 95% nas últimas 6 horas.

2.2.2 Classificação de anomalias: tendência de saída da normalidade

As linhas de tendência das variáveis dos aerogeradores são calculadas, bem como linhas de tendência para os limites superiores e inferiores das mesmas variáveis. A mudança de comportamento no recurso eólico pode alterar a tendência natural dos limites da variável em análise.

$$v = slope * time + offset$$

Onde v é o valor da variável, $slope$ é a inclinação da reta fitada, $offset$ é onde a reta corta o eixo das ordenadas e $time$ é o tempo medido, em minutos, a frente do momento inicial da análise.

A partir das linhas de tendência, calcula-se em qual momento cada variável cruzará as linhas de tendências dos limites calculados. Se o cruzamento ocorrer nas próximas 24 horas, a variável é classificada como tendendo a virar anômala. O mesmo acontece quando a variável já tiver ultrapassado os limites calculados, porém continuar se afastando da banda.

2.2.3 Classificação de anomalias segundo modelos de *Machine Learning*

Como forma de aprimorar a predição dos valores de cada variável em cada aerogerador, utilizou-se a seguinte abordagem: primeiramente, para uma mesma variável, cria-se um modelo único de regressão; a partir desse resultado, aplica-se um modelo de clusterização a fim de separar as máquinas em grupos de comportamento similar; finalmente, novos modelos de regressão podem ser criados de forma a aumentar a precisão do tratamento de cada conjunto de aerogeradores e variáveis. Os resultados obtidos pelos modelos de *Machine Learning* auxiliam na previsão temporal de quando os valores analisados devem atingir limites críticos para cada subsistema de cada respectiva máquina.

2.3 Priorização das Variáveis Anômalas

Superada a etapa de classificação de variáveis anômalas de determinados aerogeradores em determinados *timestamps*, faz-se necessária uma etapa de priorização, a fim de se obter aquelas em que eventuais tendências estejam mais críticas.

A abordagem aqui adotada foi a de normalização das médias dos valores levando-se em consideração os limites estatísticos *lower* e *upper* para classificação de outliers. Uma vez realizada a normalização, pode-se priorizar as análises pelos maiores valores de razão obtidos.

2.4 Desenvolvimento de Software Proprietário de Análise

A etapa final do processo de desenvolvimento consistiu na criação de uma funcionalidade em uma plataforma proprietária de monitoramento de ativos do time de performance e confiabilidade da Casa dos Ventos.

Para isso, desenvolveu-se um conjunto de scripts com o auxílio do *framework* Django de desenvolvimento web em *Python*. Por meio das bibliotecas de acesso à *Google Cloud Platform* para coleta de informações dos bancos de informações dos aerogeradores e de programações de manutenção, da biblioteca *Pandas* para análise e tratamento de dados e da biblioteca *Matplotlib* para geração de gráficos, criou-se a watchlist de variáveis dos aerogeradores.

Na seção watchlist, é possível visualizar, para cada variável e para um período previamente definido, um gráfico contendo a tendência deste período confrontado com comportamento geral do complexo eólico, o que representa a etapa de avaliação de determinada variável. Dos relatórios de execução da manutenção, são importadas as informações da última parada e, dos relatórios de planejamento da manutenção, a próxima intervenção programada do referido aerogerador.

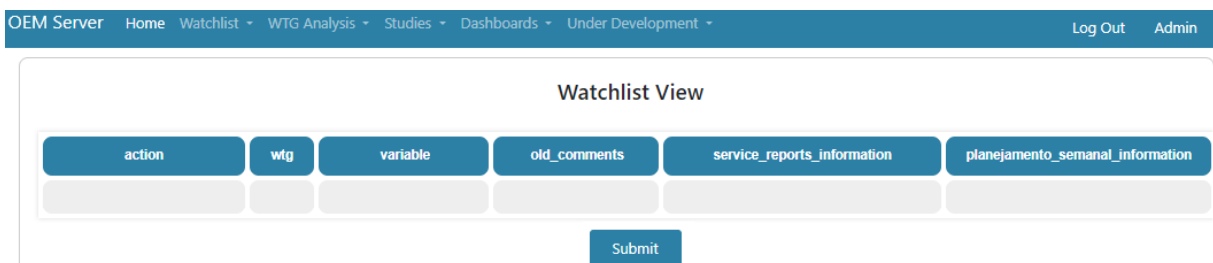


Figura 1 - Funcionalidade de visualização de variáveis consideradas importantes para acompanhamento em software proprietário desenvolvido. Na imagem, são mostrados os campos *service_reports_information*, no qual é informado a respeito de eventuais manutenções passadas ocorridas no respectivo aerogerador, e *planejamento_semanal_information*, no qual programações futuras para a máquina são denotadas.

2.5 Rotina de controle semanal

Para garantir a efetividade da ferramenta desenvolvida, foram estabelecidas rotinas de controle semanal para i) marcar eventuais novas variáveis anômalas e ii) checar se o tratamento em campo à anomalia foi de fato efetiva para a normalização das tendências.

Durante a consulta semanal à ferramenta, é feita uma avaliação conjunta com as equipes de campo em busca de novas variáveis anômalas, com o intuito de julgar sua criticidade e a possibilidade de agregá-las ao planejamento da manutenção vindoura. Deste modo, é possível usufruir do caráter preditivo da análise, aproveitando paradas já programadas para corrigir algum subsistema do aerogerador ou ainda escolhendo as janelas ótimas de baixo recurso para minimizar a perda energética.

Em um segundo momento, são checadadas as variáveis previamente adicionadas à watchlist, confrontando a manutenção realizada com a correção da tendência anômala que fora observada. A partir daí, é decidido sobre a retirada de determinada variável da watchlist, caso a manutenção tenha surtido efeito em sua tendência.

3. ANÁLISE E DISCUSSÃO DOS RESULTADOS

3.1 Casos Práticos

A implementação da ferramenta possibilita intervenção antecipada nos aerogeradores para comportamentos anômalos que não necessariamente geram alarmes indicativos, assinalando a devida prioridade à manutenção dependendo da criticidade. Como contra exemplos, se houver vazamento no sistema de arrefecimento do gerador/gearbox, não seria possível, a partir dos sistemas nativos do aerogerador, prever quando a máquina atingiria os valores críticos. Em caso de elevação de temperatura da cabine de conversão do aerogerador, somente seria observada a anomalia quando ocorresse a parada automática da turbina associada ao alarme de sobretemperatura.

3.1.1 Correção antecipada de vazamento de líquido de arrefecimento do gerador/gearbox

O nível do líquido de arrefecimento do gerador/gearbox é uma variável que, ao atingir determinado limite inferior, provoca a parada do aerogerador. Dependendo da intensidade do vazamento, é inevitável que a turbina pare após alarmar o nível baixo. Dependendo do tempo de mobilização para intervir no aerogerador, o custo da parada pode ser alto.

A ferramenta permitiu ter melhor visualização do status da grandeza e proveu melhor suporte à decisão do momento de parada do aerogerador para correção do defeito, visto que, além do gráfico de tendência ao longo do tempo, há disponível também a data da próxima parada programada, bem como a data da última parada realizada.




Figura 2 - Exemplo de medida em observação a ser incluída em manutenção programada.

No caso explicitado na figura 2, para os últimos 30 dias, os valores decaíram de 24 para 22 litros. Nesta tendência, é suportável aguardar até a próxima janela de manutenção preventiva programada, que ocorrerá cerca de 60 dias após a data marcada na imagem.

3.1.2 Detecção de falha de ventilação no sistema de conversão

O sistema de conversão do aerogerador possui diversos sensores que permitem acompanhar a temperatura de algumas partes específicas do sistema. Através da rotina implementada de verificação de anomalias em variáveis, pode-se observar que diversos valores do referido subsistema estavam apresentando-se fora da normalidade. Tal percepção exclui a possibilidade de defeito em sensor, e leva a crer que algum componente do sistema de ventilação esteja anômalo. Uma vez que o conversor do

aerogerador é um dos componentes essenciais, e que altas temperaturas podem ocasionar a parada da máquina para evitar desgaste de seus componentes, o acompanhamento priorizou o atendimento ao aerogerador a fim de sanar o problema em boa oportunidade de baixo recurso eólico. Após intervenção, foi constatado que a ventoinha da entrada de ar dedicada ao arrefecimento do conversor estava de fato danificada.




Figura 3 - Variáveis referentes a temperaturas de diferentes componentes do sistema de conversão de determinado aerogerador a serem incluídas em manutenção programada.




Figura 4 - Variável referente a temperatura de um componente do sistema de conversão de determinado aerogerador a ser incluída em manutenção programada.

3.1.3 Correção de sensor de temperatura em transformador de potência do aerogerador




Figura 5 - Variável exemplo de defeito em ventilador da sala do transformador do aerogerador.

A Figura 5 representa um caso já corrigido de medida de temperatura no transformador cuja ventilação estava danificada. A variável foi percebida pela rotina de identificação de anomalias nas variáveis e foi tratada em intervenção dedicada emergencial, visto que tal grandeza potencialmente provoca subdesempenho na turbina. Pelo gráfico, é possível confirmar que o trabalho de substituição do ventilador danificado foi efetivo, trazendo novamente os valores de temperatura do transformador para patamares normais.

3.1.4 Correção no sensor de direção de vento do aerogerador




Figura 6 - Variável exemplo de possível defeito em sensor de direção de vento: adicionando à watchlist.

No exemplo da Figura 6, foi detectado que as medidas de direção de vento para o referido aerogerador divergem constantemente do restante do complexo eólico. Tendo em vista que a próxima programação prevista deverá ocorrer somente no ano seguinte, e considerando que o desalinhamento da nacelle com relação à direção de vento pode provocar subdesempenho, tal variável será adicionada à watchlist e sua correção será direcionada para inclusão na programação em janela de baixos ventos. Ao término da intervenção, além de checar o comportamento na curva de potência do aerogerador, a variável em questão será checada para validar se as medidas retornaram ao patamar de seus pares.

4. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

De forma a otimizar a operação de um complexo eólico, é de grande valor realizar o acompanhamento e o desenvolvimento de modelos preditivos de variáveis analógicas. Isso pode ser realizado mediante comparação estatística dos valores das variáveis dos aerogeradores do complexo juntamente com estimativas de tendência realizadas por modelos de *machine learning* de clusterização e regressão.

Mesmo com esse primeiro tratamento, a quantidade de variáveis assinaladas com determinada anomalia pode ser inviável de se gerenciar. A fim de priorizar corretamente os subsistemas mais críticos, pode-se realizar uma normalização com os dados obtidos até então. O objetivo de toda essa estrutura é poder otimizar a manutenção realizada nos aerogeradores de forma a aproveitar os momentos de baixo recurso eólico e, assim, alcançar baixos índices de indisponibilidade.

Nesse trabalho, desenvolveu-se uma funcionalidade dentro de uma plataforma proprietária que permite realizar o gerenciamento de variáveis consideradas críticas dentro da operação de um complexo eólico. O desenvolvimento aconteceu mediante utilização de linguagem de programação *Python* e estrutura em *cloud*, mostrando-se de grande eficiência conforme casos práticos assinalados.

5. REFERÊNCIAS

- [1] Tchakoua P, Wamkeue R, Ouhrouche M, Slaoui-Hasnaoui F, Tameghe TA, Ekemb G. Wind turbine condition monitoring: state-of-the-art review, new trends, and future challenges. *Energies* 2014;7(4):2595–630.
- [2] Hossain, M. L., Abu-Siada, Muyeen, S.M. (2018). Methods for Advanced Wind Turbine Condition Monitoring and Early Diagnosis: A Literature Review.
- [3] Tian Z, Zhang H. Wind farm predictive maintenance considering component level repairs and economic dependency. *Renewable Energy* 2022, Pages 495-506.
- [4] Tian Z, Jin T, Wu B, Ding F. Condition based maintenance optimization for wind power generation systems under continuous monitoring. *Renewable Energy* 2011, Pages 1502-1509.
- [5] Seo S. (2002). A Review and Comparison of Methods for Detecting Outliers in Univariate Data Sets.

Diagnóstico On-Line de Aerogeradores com Uso de Técnicas de Data Science e Inteligência Artificial

Autores: Daniel Carrijo Polonio Araujo, Murilo Marques Pinto, Guilherme Toyoshima, Marcos Alves, Gabriel de Souza Pereira Gomes, Rafael Prux Fehlberg, Rogério Andrade Flauzino, Renan Ferreira Santa Rosa, Iony Patriota Siqueira, Bruno Sardinha, Catia Pedrosa, Daniel Pedrosa Santos, Dara Mendes, Gilberto Amorim Moura, Heber Pedrosa, Márcio Costa

Treetech Tecnologia, Radice Tecnologia, Ibitu Energia, Radice Tecnologia, Radice Tecnologia, Treetech Tecnologia, Radice Tecnologia, Treetech Tecnologia, Radice Tecnologia, Radice Tecnologia, Radice Tecnologia, Radice Tecnologia, Radice Tecnologia, Radice Tecnologia, Radice Tecnologia, Radice Tecnologia, Radice Tecnologia

daniel.carrijo@treetech.com.br

RESUMO

Este trabalho apresenta o desenvolvimento de uma metodologia para monitorar e diagnosticar os principais modos de falha de turbinas eólicas por meio do uso do histórico de manutenção e de dados dos sensores das máquinas, muitas vezes já existentes e conectados no sistema SCADA da usina, associados a técnicas estatísticas avançadas e inteligência artificial. A metodologia foi desenvolvida em uma plataforma de gestão de ativos, um ambiente que permite a integração nativa de algoritmos inteligentes com dados de ordem de manutenção, registro de avarias, dados de cadastros dos equipamentos e dados de sensores em tempo real. A metodologia visa apoiar as equipes de engenharia de manutenção e gestão de ativos no aumento da segurança e confiabilidade dos parques, na otimização dos recursos de manutenção e na redução da perda de receita por indisponibilidade das máquinas. Para avaliar a eficácia do sistema desenvolvido, está sendo realizada uma aplicação piloto da metodologia e do software inteligente em 210 aerogeradores de dois fabricantes diferentes.

PALAVRAS-CHAVE

Aprendizado de Máquina, Turbinas Eólicas, Detecção de Falhas, Diagnóstico de Falhas, Inteligência Artificial

ABSTRACT

This work presents the development of a methodology to monitor and diagnose the primary failure modes of wind turbines through the use of maintenance history and machine sensor data, often already existing and connected to the SCADA system of the plant, associated with advanced statistical techniques and artificial intelligence. The methodology was developed on an asset management platform, an environment that allows native integration of intelligent algorithms with maintenance order data, fault records, equipment registration data, and real-time sensor data. The methodology aims to support maintenance engineering teams and asset management in increasing the safety and reliability of the parks, optimizing maintenance resources, and reducing revenue loss due to machine unavailability. To evaluate the effectiveness of the developed system, a pilot application of the methodology and the intelligent software is being carried out on 210 wind turbines from two different manufacturers.

KEYWORDS

Machine Learning - Wind Turbines - Fault Detection - Fault Diagnosis - Artificial Intelligence

1. INTRODUÇÃO

De acordo com o Relatório Internacional de Energias Renováveis da IRENA, em 2020, as turbinas eólicas foram a terceira tecnologia renovável em capacidade instalada e a segunda em geração de energia, sendo responsáveis por quase 20% de toda a produção de energia renovável no mundo [1], conforme [Figura 1](#).




Figura 1: Tecnologias de Energia Renovável, adaptado de [1]

O aumento da geração de energia eólica na matriz energética mundial está relacionado às preocupações ambientais que se concentram na substituição de fontes de energia tradicionais, baseadas em combustíveis fósseis, por fontes de energia renovável e limpa [2].

As turbinas eólicas terrestres e marítimas operam em ambientes extremos, sujeitas a condições climáticas adversas, como luz solar excessiva, areia, chuva, vento e descargas atmosféricas. Essas condições ambientais podem levar a falhas operacionais devido a tensões mecânicas ou elétricas. Em condições críticas, essa situação pode evoluir para interrupção no fornecimento de energia, causando perdas financeiras [3]. A [Figura 2](#) mostra exemplo de aerogeradores terrestres (*onshore*) e marítimos (*offshore*).

Esses problemas aumentam os custos de operação e manutenção (O&M) de parques eólicos, o que pode torná-los menos atraentes financeiramente. Outras partes da usina, como a SE Elevadora, contribuem para esse custo e vem sendo objeto intenso de estudos [4]. Especificamente para as turbinas terrestres, o O&M é responsável por quase 15% do custo de energia, enquanto para as turbinas marítimas, esses valores podem chegar a quase 25% [5]. Além disso, a manutenção dessas turbinas, que muitas vezes estão localizadas em áreas remotas e de difícil acesso, envolve a coordenação complexa de mão de obra e transporte de peças de reposição, com o objetivo de minimizar o tempo de inatividade das turbinas.

Dessa forma, garantir o bom funcionamento desses equipamentos é fundamental para o setor elétrico. Portanto, é cada vez mais necessário o desenvolvimento de novas técnicas e ferramentas para apoiar as equipes de manutenção e gestão de ativos na identificação de defeitos em máquinas rotativas, que ainda se encontram em estágio incipiente, capacitando essas equipes para um melhor suporte à tomada de decisão, de forma a atender aos objetivos organizacionais da concessionária de forma mais eficiente.

A fim de atender a esses desafios e necessidades, este trabalho desenvolveu uma metodologia para monitorar e diagnosticar os principais modos de falha de turbinas eólicas por meio do uso do histórico de manutenção e de dados dos sensores das máquinas, muitas vezes já existentes e conectados no sistema SCADA da usina, associados a técnicas estatísticas avançadas e inteligência artificial. A metodologia foi

desenvolvida em uma plataforma de gestão de ativos, um ambiente que permite a integração nativa de algoritmos inteligentes com dados de ordem de manutenção, registro de avarias, informações de cadastros dos equipamentos e dados de sensores em tempo real.



Figura 2: Aplicações de Aerogeradores em terra e mar

A metodologia visa apoiar as equipes de engenharia de manutenção e gestão de ativos da concessionária de geração no aumento da segurança e confiabilidade dos parques, na otimização dos recursos de manutenção e na redução da perda de receita por indisponibilidade das máquinas.

Para avaliar a eficácia do sistema desenvolvido, está sendo realizada uma aplicação piloto da metodologia e do software inteligente em 210 aerogeradores de dois fabricantes diferentes.

O trabalho foi desenvolvido no âmbito do Projeto de P&D 0119 da ANEEL, intitulado Sistema Inteligente para Gestão Otimizada de Aerogeradores e Hidrogeradores.

2. DESCRIÇÃO DOS DADOS

O conjunto de dados usado neste trabalho foi coletado nos anos de 2017 e 2018 em duas usinas de energia eólica (usina A e usina B). As informações utilizadas para compor o conjunto de dados foram dados do sistema SCADA e dados do histórico de manutenção. Em relação às informações coletadas do sistema SCADA, inicialmente foram consideradas 609 características para cada turbina.

As informações presentes no sistema SCADA foram obtidas por vários sensores instalados nas turbinas eólicas. Esses sensores transmitem informações para o sistema SCADA, que registra esses dados usando um intervalo de tempo de 10 minutos. Para cada medição coletada pelos sensores, considerando o intervalo de 10 minutos, quatro parâmetros são calculados: valor máximo e mínimo, valor médio e desvio padrão. Considerando uma abordagem de aprendizado supervisionado, os dados do sistema SCADA foram usados para compor a entrada para o método.

Os dados históricos contendo informações sobre falhas nas turbinas e eventos de indisponibilidade foram usados para construir o conjunto de dados de destino (saída desejada) para a fase de treinamento. Os dados históricos de manutenção indicam a máquina que sofreu o defeito, a data da interrupção, a duração da interrupção e o sistema afetado. Apenas as falhas que causaram períodos de interrupção de fornecimento superiores a um dia foram consideradas, pois interrupções mais curtas foram resolvidas reiniciando a máquina, não exigindo intervenção da equipe de manutenção. A [Figura 3](#) apresenta um histograma com a quantidade de falhas em relação ao local.

Para compor esses dados históricos, foram consideradas as seguintes informações: identificação do parque eólico, índice da turbina eólica, dados de manutenção (tipo de manutenção, ou seja, corretiva não programada, corretiva programada, solicitada pelo cliente, inspeção com restrição, preditiva e preventiva), tipo de falha, tempo de parada, tempo de retorno, duração da falha, atividades de manutenção e sistemas afetados.

A partir dos dados do histórico de manutenção, verificou-se que a maioria das falhas estava relacionada a eventos de manutenção não programados. A porcentagem de cada tipo de manutenção é apresentada na [Tabela 1](#).




Figura 3: Quantidade de Falhas por Tipo de Sistema

Tabela 1: Tipo de Manutenção

Tipo de Manutenção	Frequência
Corretiva não programada	80,1%
Preventiva	13,7%
Solicitada pelo cliente	3,0%
Corretiva programada	2,87%
Inspeção com restrição	0,235%
Preditiva	0,0281%

O método proposto neste artigo tem como objetivo evitar a ocorrência de eventos de manutenção não programados, que estão relacionados à maioria das falhas e representam os maiores custos de manutenção. Portanto, apenas as amostras relacionadas aos eventos de manutenção não programados foram utilizadas.

Considerando apenas esse tipo de dados, verificou-se que a usina B foi responsável por 79,7% das ocorrências de falhas, enquanto a usina A foi responsável por 20,3%. Essas diferenças podem estar relacionadas a vários fatores, como condições ambientais e diferentes protocolos de manutenção para cada usina. É necessária uma investigação adicional para identificar o motivo dessa discrepância. Essa investigação está fora do escopo deste artigo.

Considerando a porcentagem de falhas por subsistema, a [Tabela 2](#) mostra os resultados para cada usina.

A proporção de falhas por sistema é equivalente para ambas as usinas, por exemplo, o sistema do rotor é responsável pela maioria das falhas, seguido pelo sistema de transmissão e pelo sistema do gerador.

O tempo de inatividade por falha apresenta um comportamento diferente, como mostrado nas duas últimas colunas da [Tabela 2](#). Para a usina A, o sistema do conversor é responsável pelo período mais longo de tempo de inatividade, seguido pelo sistema do rotor. Enquanto na usina B, a classe da turbina é responsável

Tabela 2: Porcentagem de falhas e tempo de inatividade por subsistema

Subsistema	Percentual de falhas		Tempo de inatividade	
	Usina A	Usina B	Usina A	Usina B
Rotor	28,4%	35%	31,7%	20,9%
Transmissão	23,1%	19,2%	5,99%	17,5%
Gerador	17,2%	17,1%	13,3%	14,6%
Conversor	17,1%	12,9%	36,2%	13,2%
Turbina	8,1%	10,4%	10,1%	31,7%
Giro	6,04%	4,19%	2,72%	1,64%
Caixa de engrenagens	-	0,0164%	-	0,257%
Turbina elétrica	-	0,0491%	-	0,0401%
Sistema de controle	-	0,0819%	-	0,03%
Sistema do gerador	-	0,0982%	-	0,0114%
Sistema de azimute	-	0,115%	-	0,0101%
Kabelbruch	-	0,18%	-	0,00563%

A classe definida como falhas "turbina" está relacionada a falhas que não puderam ser identificadas pela equipe de manutenção.

Como pode ser visto na [Tabela 2](#), o rotor foi o sistema mais propenso a falhas e estava entre os sistemas que levaram a um maior tempo de inatividade operacional. Essas características foram consideradas ao selecionar o sistema como foco deste artigo. No entanto, o modelo pode ser generalizado e adaptado a outros sistemas em turbinas eólicas.

2.1. CONJUNTO DE DADOS DE SAÍDA DESEJADO

Como mencionado anteriormente, os dados históricos de manutenção foram utilizados para construir o conjunto de dados de saída desejado. Os dados históricos de manutenção apresentam a data em que a falha ocorreu e essa informação foi usada para criar um conjunto de dados no qual a saída desejada era o tempo restante até a falha.

Considerando que os dados do SCADA apresentam uma resolução de 10 minutos, o conjunto de dados de entrada também terá amostras com resolução de 10 minutos. Portanto, o tempo restante até a falha foi obtido para cada uma das amostras.

Por exemplo, se uma falha ocorreu no instante t , para cada amostra, o tempo restante até o instante t foi utilizado como saída desejada.

3. PIPELINE DE DETECÇÃO DE FALHAS

O pipeline de detecção de falhas é descrito na [Figura 4](#) e consiste no estágio de processamento dos dados, seguido de engenharia de features, seleção de modelo e avaliação dos resultados.

3.1. PROCESSAMENTO DOS DADOS

O primeiro passo para implementar um *framework* de aprendizado de máquina é pré-processar o conjunto de dados, removendo erros e analisando se há alguma transformação necessária nos dados. O conjunto de dados foi dividido em três partes: conjunto de treinamento, conjunto de teste e conjunto de validação. Essa divisão é essencial para abordagens de aprendizado de máquina.

O conjunto de treinamento geralmente é o maior e é apresentado ao modelo na fase de aprendizado. Portanto, o modelo aprenderá a generalizar com base nesses dados. O conjunto de validação é usado para verificar o desempenho do modelo em novos dados que ainda não foram apresentados a ele. Se o modelo tiver um desempenho ruim na fase de validação, seus parâmetros devem ser ajustados por meio de um

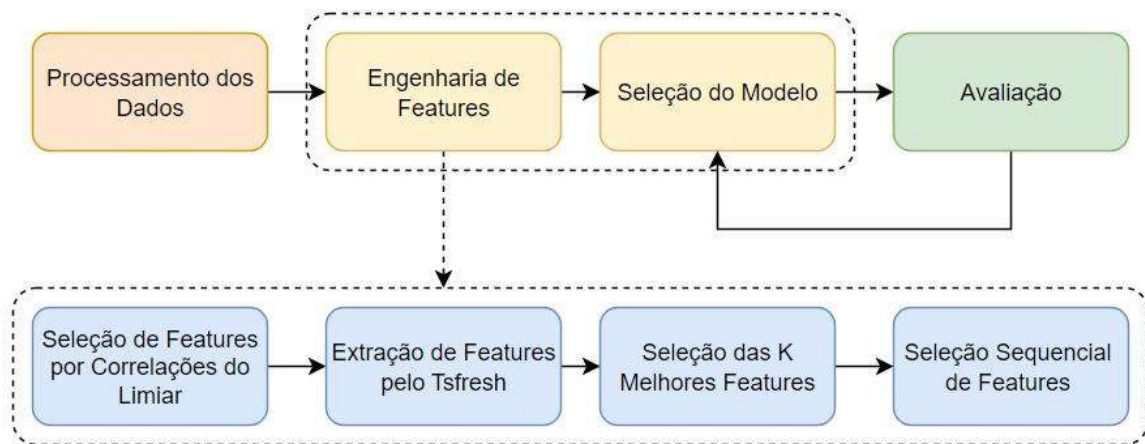


Figura 4: Pipeline de Detecção de Falhas

novo processo de treinamento. O conjunto de teste é usado após o término do processo de treinamento e validação, e os parâmetros do modelo são ajustados. Este conjunto também é novo para o modelo, e o desempenho do modelo nesse conjunto de dados descreverá seu desempenho para dados práticos.

É importante enfatizar que um ano inteiro de dados foi usado para compor o conjunto de treinamento, para que o modelo pudesse aprender o comportamento sazonal das falhas. A razão entre os dados de treino e teste foi de 90%/10%.




Figura 5: LCA do Modelo de Regressão

3.2. ENGENHARIA DE FEATURES

A Engenharia de Features (características relevantes) é realizada, inicialmente, através de uma seleção de Features com base na correlação. Em seguida, é realizada a extração de Features temporais como lag e trend utilizando a biblioteca tsfresh [6]. O próximo passo é realizar uma seleção das melhores Features para diagnóstico do tempo de falha dos ativos. Por fim, é realizado um processo de Seleção Sequencial de

Features.

3.3. SELEÇÃO DO MODELO

Embora outros modelos tenham sido testados, este trabalho apresenta os resultados obtidos com uma Regressão Ridge otimizada [7]. A avaliação consistiu na análise da curva de aprendizado (LCA), R-quadrado, erro absoluto médio e gráficos de predição. A [Figura 5](#) mostra a curva de aprendizado do modelo.

4. RESULTADOS

Para as métricas de treinamento, o R-quadrado foi de 0,98, o que significa que apenas 2% dos dados não puderam ser explicados pelo modelo.

Na [Figura 6](#), são mostrados o tempo real para uma falha ocorrida (azul) e o tempo previsto nos testes do modelo (vermelho). O comportamento observado nos gráficos nos dá a certeza de que as métricas apresentadas são reais e que os valores previstos seguem o padrão dos reais.




Figura 6: Predição do modelo para os dados de treinamento

Quanto às métricas de teste, foi obtido um valor de R-quadrado acima de 1, que significa um caso anormal, não tem significado lógico e pode ser resultado do pequeno tamanho da amostra. Por outro lado, a [Figura 7](#) mostra que os valores previstos seguem o valor real.

5. DASHBOARD

Os resultados dos algoritmos são disponibilizados em um dashboard apresentado na [Figura 8](#), onde é possível acompanhar o estado geral do parque, a evolução das falhas nos diferentes equipamentos e as variáveis que mais impactaram no diagnóstico da máquina. Além disso, o dashboard possui filtros que ajudam a estudar o comportamento do parque em datas, equipamentos, subsistemas e/ou predições específicas.

6. CONCLUSÃO

Este trabalho apresentou uma metodologia para diagnóstico da condição em aerogeradores. Os resultados mostraram que a metodologia foi capaz de aprender a identificar o período de falha da turbina. Os resultados dos testes mostraram-se promissores, demonstrando que o modelo entendeu o mecanismo de falha da turbina eólica. Porém, quando se aproximava o momento da ocorrência do defeito, o erro do modelo predito aumentava. Esta é uma indicação de que um modelo de curto prazo poderia ajudar a resolver este




Figura 7: Predição do modelo para os dados de teste



Figura 8: Dashboard de acompanhamento do estado dos Aerogeradores

problema.

O modelo desenvolvido pode ser estendido para qualquer tipo de defeito ou falha. Além disso, este trabalho demonstrou a possibilidade de criar sistemas preditivos de falhas com resultados satisfatórios.

A aplicação dos sistemas desenvolvidos nas rotinas de manutenção e gestão de ativos nos parques de aerogeradores possibilitam a obtenção de diversos benefícios tanto econômicos quanto socioambientais, tais como:

- Redução dos custos indiretos das falhas dos ativos, com a indicação do defeito apresentado pelo equipamento;

- Redução dos custos diretos e indiretos de manutenção, como insumos de manutenção e homem-hora;
- Redução dos riscos de acidentes de trabalho e dos custos diretos e indiretos associados;
- Redução dos riscos de impactos ambientais por falhas de equipamentos e dos custos diretos e indiretos associados;
- Redução da indisponibilidade dos parques e consequentes aumentos na confiabilidade na geração;
- Aumento de confiabilidade do parque gerador brasileiro e do SIN;
- Aumento da vida útil dos ativos.

7. AGRADECIMENTOS

O trabalho foi desenvolvido no âmbito do Projeto de P&D 0119 da ANEEL, intitulado Sistema Inteligente de Gestão Otimizada de Aerogeradores e Hidrogeradores.

REFERÊNCIAS

- [1] IRENA, *Renewable Energy Technologies*, Online; acessado em 6 de julho de 2023. endereço: <https://www.irena.org/Data/View-data-by-topic/Capacity-and-Generation/Technologies>.
- [2] X. Jin, Y. Chen, L. Wang, H. Han e P. Chen, "Failure prediction, monitoring and diagnosis methods for slewing bearings of large-scale wind turbine: A review," *Measurement*, v. 172, p. 108855, 2021, ISSN: 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2020.108855>. endereço: <https://www.sciencedirect.com/science/article/pii/S0263224120313464>.
- [3] M. Tang, Z. Kuang, Q. Zhao, H. Wu e X. Yang, "Fault detection of wind turbine pitch system based on multiclass optimal margin distribution machine," *Mathematical Problems in Engineering*, v. 2020, pp. 1–10, 2020.
- [4] A. C. Tavares, C. Justi, D. Carrijo e L. P. Fritoli, "Ferramentas Contra Falhas Incipientes de Buchas de Alta Tensão com Cargas Não Lineares," em *XIX ERIAC - Décimo Nono Encontro Regional Ibero-Americano do Cigre*, Cigre, ISBN: 978-65-00-63038-1, 2023.
- [5] L. Williams, C. Phillips, S. Sheng, A. Dobos e X. Wei, "Scalable wind turbine generator bearing fault prediction using machine learning: A case study," em *2020 IEEE International Conference on Prognostics and Health Management (ICPHM)*, IEEE, 2020, pp. 1–9.
- [6] M. Christ, N. Braun, J. Neuffer e A. W. Kempa-Liehr, "Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package)," *Neurocomputing*, v. 307, pp. 72–77, 2018, ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2018.03.067>. endereço: <https://www.sciencedirect.com/science/article/pii/S0925231218304843>.
- [7] G. C. McDonald, "Ridge regression," *Wiley Interdisciplinary Reviews: Computational Statistics*, v. 1, n. 1, pp. 93–100, 2009.

ESTUDO DE CASO – RESOLUÇÃO DE FALHAS EM AEROGERADORES ADVINDAS DE DISTORÇÕES HARMÔNICAS DE ALTA FREQUÊNCIA

Arthur Fernando Bonelli¹, Pedro Augustho Biasuz Block¹, Ivan Nunes Santos²

¹ MAB Engenharia, ² Universidade Federal de Uberlândia

arthur.bonelli@mab-engenharia.com, pedro.block@mab-engenharia.com, ivan@ufu.br

RESUMO

A necessidade da mudança da matriz energética mundial para uma matriz com baixa emissão de carbono já representa um paradigma inquestionável para a comunidade científica, para o setor produtivo, para a comunidade civil e para os governantes de uma forma geral. A geração eólica e a solar são as principais engrenagens desta transição energética, juntamente com sistemas de armazenamento de energia. Todavia, do ponto de vista de interfaceamento com a rede elétrica, muitos desafios ainda se fazem presentes, tais como questões vinculadas à intermitência e à qualidade da energia elétrica. No tocante à qualidade da energia elétrica, as distorções harmônicas têm sido o principal problema investigado na atualidade. E neste contexto, o presente trabalho pretende apresentar um estudo de caso real de resolução de problema de falhas em aerogeradores de um parque eólico, destacando as causas averiguadas, as medições feitas, a modelagem realizada e as soluções propostas.

Palavras-chaves:

Energia eólica; filtro harmônico; qualidade de energia elétrica; supraharmônico.

ABSTRACT

The need to change the world's energy matrix to one with low carbon emissions already represents an unquestionable paradigm for the scientific community, for the productive sector, for the civil community and for governments in general. Wind and solar generation are the main gears of this energy transition, along with energy storage systems. However, from the point of view of interfacing with the electrical network, many challenges are still present, such as issues related to the intermittency and power quality. Regarding power quality, harmonic distortions have been the main problem currently being investigated. And in this context, the present work intends to present a real case study of solving the problem in wind turbines failures of a wind farm, highlighting the investigated causes, the measurements taken, the modeling carried out, and the proposed solutions.

Keywords:

harmonic filter; power quality; supraharmônico; wind energy.

1. INTRODUÇÃO

As fontes de energia renováveis estão a cada dia ganhando mais espaço na matriz energética mundial. Em particular no Brasil, a energia eólica e solar tem grande destaque. A eólica já está com 13,39% da

matriz energética. Já a energia solar fotovoltaica encontra-se em pleno desenvolvimento e ganhando espaço com empreendimentos de grande porte entrando em operação e já soma 4,97% da matriz energética (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2023).

Devido a características intrínsecas à fonte primária destas energias, no caso o vento e a radiação solar, há necessidade de trabalhar com tecnologias que possam compatibilizar a energia gerada nestas fontes com os requisitos de conexão do sistema elétrico. Via de regra, estas conexões são realizadas por conversores de frequência, os quais sincronizam a energia gerada com a tensão e a frequência da rede elétrica, otimizando, também, seu rastreamento de máxima potência de extração (BOSE, B.K., 2013).

Todavia, estes conversores possuem, dentre outros efeitos colaterais, a geração de distorções harmônicas de tensão e corrente (ARRILAGA, J., WATSON, B.R., 2004). Assim, o Operador Nacional do Sistema Elétrico (ONS) solicita que os novos agentes acessantes ao Sistema Interligado Nacional (SIN) realizem estudos para analisar o impacto do empreendimento no sistema elétrico brasileiro.

A Norma Técnica 009/2016 – Rev.03 do ONS (OPERADOR NACIONAL DO SISTEMA ELÉTRICO, 2019) define as regras para realizações dos estudos em parques eólicos e fazendas solares. Por sua vez, o Submódulo 2.9 dos Procedimentos de Rede do ONS (OPERADOR NACIONAL DO SISTEMA ELÉTRICO, 2020) apresenta os valores de distorções harmônicas de tensão admissíveis.

No caso em que os resultados dos estudos, vinculados ao acesso de complexos eólicos ou solares, apresentarem valores de distorções harmônicas acima dos limites regulatórios, tem-se a necessidade de implementação de medidas mitigatórias, as quais podem ser compostas por filtros harmônicos passivos e/ou ativos (DUGAN, R.C., MCGRANAGHAN, M.F., SANTOSO, S., BEATY, H.W., 2002).

Ademais, tais complexos são obrigados a ter capacidade de fornecimento de potência reativa para de modo a ser capaz de manter seu fator de potência no intervalo entre 0,95 capacitivo e 0,95 indutivo. Detalhes desta exigência estão no Submódulo 2.10 dos Procedimentos de Rede do ONS (OPERADOR NACIONAL DO SISTEMA ELÉTRICO, 2021b).

Todas estas análises, distorção harmônica e capacidade de fornecimento de reativo, são realizadas com referência no bay de conexão do complexo com o SIN, ou seja, no Ponto de Acoplamento Comum (PAC). Todavia, como estes pontos de conexão possuem elevados níveis de tensão, de 69 kV a 500 kV, comumente as soluções são implementadas nos barramentos de 34,5 kV da subestação coletora, tendo em vista a redução de custo. Ou seja, todas as análises para os estudos do ONS são feitas com referência em um barramento que não é, via de regra, o local de instalação das soluções.

Complementarmente, deve-se destacar que os complexos de energia renováveis possuem, em geral, características que propiciam o aumento da ocorrência de ressonâncias harmônicas, quais sejam:

- Os geradores são providos de conversores de frequência que produzem correntes harmônicas sendo estas, muitas vezes, em ordens não convencionais às existentes no sistema elétrico;
- Os alimentadores são, em grande parte, constituídos por cabos blindados em 34,5 kV, os quais possuem valores de capacitâncias relativamente altos;
- É comum a existência de bancos de capacitores e filtros harmônicos com estágios, instalados em barramentos compartilhados.

Diante do exposto acima, se torna de suma importância realizar avaliações de ressonâncias harmônicas quando das entradas dos bancos de capacitores e filtros harmônicos nos barramentos de média tensão, os quais comumente possuem tensão de 34,5 kV (34,5 kV). Todavia, como esta prática não é comum ao setor, já existem casos de problemas, advindos da instalação e operação destes equipamentos, os quais vão desde desligamentos do complexo até danos severos em equipamentos da subestação coletora, alimentadores e aerogeradores. Esses problemas poderiam ser evitados se houvessem um estudo prévio à implementação da solução de compensação de reativos e distorção harmônica. O artigo (BLOCK, P.A.B, BONELLI, A.F., BONELLI, M.L., 2022) apresenta um caso real de um complexo eólico de grande porte em que, caso a solução padrão fosse instalada, ou seja, fossem analisados apenas o impacto no PAC, conforme exigência do ONS, haveria grande possibilidade de ressonância nos barramentos de 34,5 kV com potenciais danos aos equipamentos elétricos da planta de geração eólica.

Dentro do contexto supradito, o presente artigo vem apresentar outro estudo de caso de queima de equipamentos dos aerogeradores em campo. Diversos aerogeradores de um específico circuito do parque tinham seus equipamentos dos serviços auxiliares constantemente queimando, acarretando custos

extremamente altos para substituição dos equipamentos e consideráveis perdas de geração por paradas dos aerogeradores.

Após uma investigação minuciosa em campo com a realização de diversas medições e simulações computacionais, foi possível identificar a raiz do problema e projetar uma solução para resolução deste.

2. O COMPLEXO DE GERAÇÃO EÓLICA E OS PROBLEMAS DE QUEIMA DE COMPONENTES

O citado complexo de geração eólica se situa na região nordeste do Brasil e possui aerogeradores tipo *Double-Fed Induction Generator* (DFIG). Assim, estes aerogeradores possuem máquina de indução com o estator acoplado diretamente à rede elétrica e rotor conectado à rede por meio de um conversor de frequência *back-to-back*.

Em relação aos fenômenos de falhas de equipamentos relatadas, estas se manifestaram na forma de queima de componentes que perfazem o sistema elétrico de controle, levando a interrupções do processo de geração de energia de distintas máquinas, em diversas ocasiões, o que levou consideravelmente os indicadores de indisponibilidade de máquina no complexo eólico em questão. Tais equipamentos eletrônicos são alimentados, neste tipo de aerogerador, através do terciário do transformador de conexão da máquina.

Neste contexto, vale ressaltar que houve, em um primeiro momento, algumas tentativas de se solucionar o problema, incluindo a contratação de empresas consultoras brasileiras e europeias. Assim, os trabalhos apresentados por tais empresas indicaram a presença de elevados níveis de distorções nas tensões em distintos pontos do complexo, sem que houvesse, todavia, uma avaliação conclusiva da interação entre as grandezas medidas e os problemas manifestados. Nesse sentido, foi apenas esclarecido que, de fato, havia problemas de qualidade de energia elétrica na rede, os quais poderiam justificar as queimas, até então, manifestadas.

Diante do exposto acima, a MAB Engenharia foi contratada para realizar uma análise criteriosa dos fenômenos que seriam responsáveis pelos fatos ocorridos e apresentar uma solução para tais distúrbios. Assim, foram realizadas diversas medições e análises em vários pontos do citado complexo, bem como a realização de simulações computacionais. Os serviços apresentados foram executados pela equipe da MAB Engenharia em parceria com a equipe de pesquisadores da Universidade Federal de Uberlândia.

Por fim, foram apresentadas distintas soluções a serem implementadas para realização da mitigação dos problemas, as quais foram embasadas em estudos avançados envolvendo modelagens detalhadas da máquina, análises de interações harmônicas, oscilografias em campo e validação dos modelos e de soluções.

3. MEDIÇÕES DE CAMPO

Para realização das medições em campo foram utilizados analisadores de qualidade de energia elétrica classe A sincronizados via GPS e osciloscópios para análise de harmônicos de alta frequência (acima de 3 kHz). Assim, foram realizadas diversas medições em paralelo, as quais abordaram os seguintes pontos:

- Barramento de MT da subestação coletora;
- 07 locais distintos pertencentes a um aerogerador do alimentador mais problemático;
- 07 locais distintos pertencentes a um aerogerador do alimentador mais imune ao problema.

Durante as medições foram realizados diversos testes e investigações, como procedimento de energização de desenergização dos aerogeradores e do banco de capacitores da subestação coletora, bem como análise de circuito de malha de aterramento.

Com o decorrer das medições e avaliações, foram verificadas distorções harmônicas de altas frequências, sempre relacionadas a 2 kHz e seus múltiplos. Ou seja, 2 kHz, 4 kHz, 6 kHz e assim sucessivamente.

Estes harmônicos de alta frequências são comumente conhecidos, na literatura científica, como supra-harmônicos (RONNBERG, S., BOLLEN, M.H.J., LARSSON, A., LUNDMARK, M., 2014).

Um ponto importante de salientar é que as distorções harmônicas variavam muito a intensidade e ordem predominante dependendo do local e do momento da medição. Assim, em muitos locais, as maiores distorções estavam na ordem de 4 kHz, frequência esta em que os analisadores de qualidade de energia elétrica classe A padrão não conseguem mensurar, dificultando a busca pelo problema por meio do emprego de equipamentos convencionais de medição.

3.1 Medições na Subestação Coletora

Em relação às medições no barramento da média tensão da subestação coletora, têm-se, nas Figuras 1 e 2, a apresentação da oscilografia e o espectro harmônico da tensão, respectivamente. Estas medições evidenciam que as frequências de baixa ordem se apresentam em proporções bastante reduzidas, fato este que determina o pleno cumprimento os valores esperados pelos Procedimentos de Rede do ONS. Por outro lado, embora em proporções não tão elevadas, constata-se a presença de um conjunto de tensões harmônicas, com valores acima daqueles encontrados para as baixas frequências, cujos valores máximos se apresentam em torno de 1,5% e em frequências nas imediações de 4 kHz.




Figura 1 – Oscilografias das tensões trifásicas na MT da SE Coletora do Parque Eólico.




Figura 2 – Espectro harmônico da fase A na MT da SE Coletora do Parque Eólico.

3.2 Medições em Aerogerador de Alimentador Problemático

Como apresentado anteriormente, alguns alimentadores, do presente complexo, possuíam muitos aerogeradores com falhas constantes. Por outro lado, alguns alimentadores apresentavam baixo nível de

falha nos aerogeradores. Desta forma, serão apresentadas medições em um aerogerador com alto índice de falha e em outro com baixo índice de falha.

3.2.1 Medições em aerogerador com alto índice de falha (Aerogerador 1)

Dentre os diversos pontos mensurados no aerogerador, este trabalho selecionou, para efeito de ilustração e discussão, as medições em dois locais, a saber:

- Rede de MT da saída do transformador;
- Terciário do transformador (BT), o qual alimenta os sistemas de controle que apresentavam falhas.

Voltando-se às medições no barramento da média tensão da saída do Aerogerador 1, as Figuras 3 e 4 apresentam, respectivamente, a oscilografia e o espectro harmônico da tensão neste barramento. As distorções aqui encontradas são nas mesmas frequências presentes na medição da subestação coletora, ou seja, estão na por volta de 4 kHz. Não obstante tratar-se da mesma rede, neste último ponto, os níveis de distorção se apresentam extremamente superiores àqueles anteriormente encontrados nas medições da SE. Isto aponta para o reconhecimento da existência de uma ressonância localizada, a qual conduziu a níveis de distorções nas mesmas ordens anteriores, todavia, em proporções de até 13,5% e com valores de pico superiores a 30% do nominal, ou, ainda, uma maior proximidade com a fonte geradora do problema.

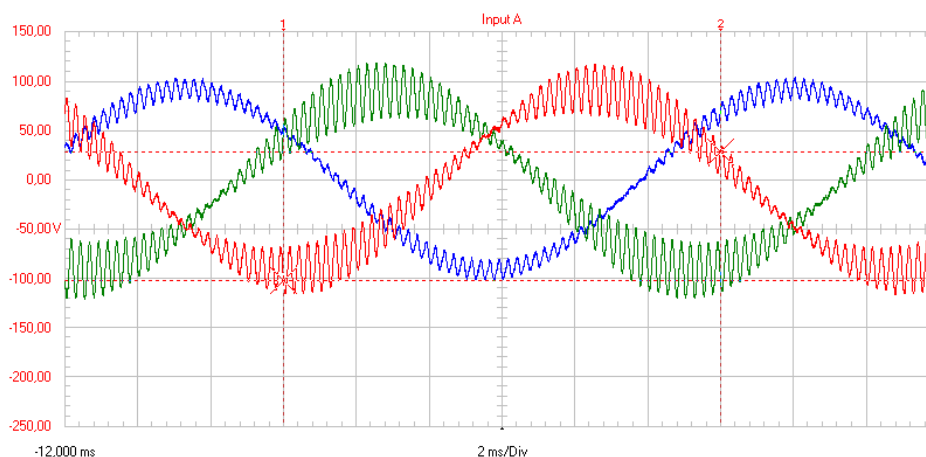


Figura 3 – Oscilografias das tensões trifásicas na MT do Aerogerador 1.




Figura 4 – Espectro harmônico da fase A na MT do Aerogerador 1.

Quanto às medições na saída de BT do transformador do Aerogerador 1, têm-se as Figuras 5 e 6 apresentando a oscilografia e o espectro harmônico da tensão, respectivamente. Também são verificadas distorções harmônicas de magnitudes elevadas nas proximidades dos 4 kHz, apresentando distorções máximas de 14,7% e valores de pico de 32% acima do nominal. As distorções aqui registradas se apresentam condizentes com aquelas verificadas para o barramento de MT.




Figura 5 – Oscilografias das tensões trifásicas no lado de BT do transformador do Aerogerador 1.




Figura 6 – Espectro harmônico da fase A no lado de BT do transformador do Aerogerador 1.

3.2.2 Medições em aerogerador com baixo índice de falha (Aerogerador 2)

Como para na análise anteriormente detalhada, este trabalho apresenta as medições em dois locais do Aerogerador 2, a saber:

- Rede de MT da saída do transformador;
- Terciário do transformador (BT), o qual alimenta os sistemas de controle que apresentam falhas.

Voltando-se às medições no barramento da média tensão da saída do Aerogerador 2, têm-se as Figuras 7 e 8 apresentando a oscilografia e o espectro harmônico da tensão, respectivamente. Nestas imagens verificam-se baixos conteúdo harmônico. Todavia, embora em proporções pequenas, são verificadas distorções nas imediações dos 4 kHz, cujo valor máximo é de 1%. Além disso, são também manifestados harmônicos em baixas frequências, cujo valor máximo é 2,1% de 2ª ordem. Já o valor pico apresentou magnitude equivalente à condição nominal.




Figura 7 – Oscilografias das tensões trifásicas na MT do Aerogerador 2.




Figura 8 – Espectro harmônico da fase A na MT do Aerogerador 2.

Quanto às medições na saída de BT do transformador do Aerogerador 2, têm-se as Figuras 9 e 10 apresentando a oscilografia e o espectro harmônico da tensão, respectivamente. Como para a medição na MT, a presente medição resultou em um espectro harmônico com baixas magnitudes na faixa dos 4 kHz, cujo valor máximo é equivalente a 1,2%. Todavia, para esta medição, a predominância espectral se apresenta nos entornos dos 2 kHz, resultando em distorções com magnitude máxima de 2,5%. Os valores de pico apresentam um aumento de 5% com relação ao seu valor nominal.




Figura 9 – Oscilografias das tensões trifásicas no lado de BT do transformador do Aerogerador 2.




Figura 10 – Espectro harmônico da fase A no lado de BT do transformador do Aerogerador 2.

4. MODELO COMPUTACIONAL

Foi realizada a modelagem computacional da rede interna do complexo eólico e dos aerogeradores DFIG no programa MATLAB/Simulink visando, sobretudo, a reprodução em ambiente computacional, das condições operacionais encontradas no presente complexo eólico, com destaque às questões associadas às distorções harmônicas. Assim, foram realizados estudos investigativos diversos objetivando a identificação da origem dos fenômenos responsáveis pelas anomalias operativas ocorridas em campo e apresentação de proposição de soluções para os problemas encontrados.

Objetivando avaliar o desempenho do modelo computacional implementado, foram realizadas simulações diversas, cujos resultados foram confrontados com respostas advindas das medições feitas em campo. Desta forma, foram comparadas variáveis de corrente e tensão na subestação coletora, nos terminais do transformador do aerogerador dentre outras variáveis do aerogerador, como a velocidade do rotor.

Deve-se destacar que a combinação de circuitos envolvendo fontes geradoras de harmônicos e a topologia de um sistema podem, via de regra, proporcionar regiões mais susceptíveis à manifestação de ressonâncias, as quais provocam amplificações harmônicas. De forma mais objetiva, dentro do contexto do arranjo, pode ocorrer a intensificação de anomalias, a exemplo de aumento das intensidades das tensões harmônicas devido a uma combinação entre efeitos indutivos e capacitivos advindos de linhas, cabos, transformadores, etc. Assim, foram realizadas simulações para identificação as áreas de maior vulnerabilidade, ou críticas, sob o ponto de vista de harmônicos.

5. SOLUÇÕES

Diante de todo o sistema computacionalmente modelado e validado, voltou-se para a busca de soluções de mitigação dos problemas. Para tanto, foram apresentadas 4 possíveis soluções, as estão são detalhadas na sequência.

5.1 Solução 1 – Filtragem na Subestação Coletora

A Solução 01 consistia na instalação de filtros harmônico nos barramentos de MT da subestação coletora. Esta estratégia tem como objetivo atenuar as distorções na forma de onda da tensão no complexo como um todo e evitar possíveis problemas futuros na instalação.

De fato, a Solução 01 foi efetiva na redução das distorções harmônicas no barramento da Subestação Coletora, todavia, não houve resultados expressivos para o circuito de BT dos aerogeradores críticos, o que não resolveria o problema da queima nos componentes dos aerogeradores.

5.2 Solução 2 – Filtragem na Média Tensão Próximo aos Aeroogeradores

A Solução 02 também está associada com o emprego de filtros no circuito de MT do complexo, todavia em locais distintos dos elucidados anteriormente. Neste caso, os equipamentos são instalados nos terminais de cada circuito (próximo aos aeroogeradores).

Quanto à eficácia da Solução 02, os resultados esclarecem que esta reduziu as distorções harmônicas em todos os pontos analisados, principalmente quando se observou os valores próximos de 4 kHz, os quais são, a priori, as frequências causadoras da queima nos componentes instalados na BT dos transformadores dos aeroogeradores.

Tendo em vista que a Solução 02 é composta vários filtros de MT, sendo estes instalados em cada circuito mais próximo aos aeroogeradores, naturalmente esta proposta se apresenta com valores superiores aos anteriores.

5.3 Solução 3 – Filtragem no Lado de BT do Transformador dos Aeroogeradores

Uma alternativa à instalação de filtros para mitigação das distorções a nível dos barramentos de MT é apresentada na forma de Solução 03. Esta está alicerçada na eliminação do problema de forma localizada aos pontos para os quais foram manifestados os problemas de danos de natureza física em componentes elétricos e respectivos impactos sobre a operação dos aeroogeradores. Tais recursos mitigatórios seriam aplicados diretamente nos terminais de BT do transformador, enrolamento esse que, se mostra com expressivos níveis de distorção diante das transferências dos efeitos manifestados na média tensão para os enrolamentos de baixa tensão. Em assim sendo, facilmente se compreende que, desta feita, os filtros se apresentam em escalas de tensão e potência bastante inferiores aos anteriormente considerados, conseqüentemente apresentando preços menores.

Como esperado, a Solução 03 praticamente não afetou os valores das distorções harmônicas nos barramentos e circuitos de média tensão, todavia, os resultados obtidos no enrolamento de BT foram eficazes.

5.4 Solução 4 – Filtragem na Subestação Coletora e no Lado de BT do Transformador dos Aeroogeradores

A Solução 04 consiste numa fusão das soluções contempladas na Solução 01 e na Solução 03. Naturalmente, o seu objetivo está centrado numa alternativa visando a solução dos problemas de forma sistemática.

Tendo em mente que a estratégia ora considerada se apresenta como uma associação daquelas propostas como Soluções 01 e 03, o custo estimado de sua implementação, por conseguinte, corresponde a soma dos valores destas.

6. CONCLUSÕES

Neste trabalho foi feita uma contextualização da importância da geração eólica no contexto da transição energética para uma matriz de baixo carbono, ressaltando o papel do Brasil nesta importante mudança de paradigma. Assim, foram evidenciados os desafios que ainda se fazem presentes no âmbito da qualidade da energia elétrica, com destaque a problemas envolvendo distorções harmônicas da forma de onda.

Então, de modo a contribuir com investigações científicas correlatas à mitigação de problemas relacionados com emissão harmônica, foi apresentado um estudo de caso real de falhas em aeroogeradores de um parque eólico no nordeste do Brasil. De forma complementar, foram apresentados os resultados de medições em campo, juntamente com uma análise do que estava ocorrendo naquela planta eólica. E, por fim, foi abordado um leque de soluções.

Diante do exposto, concluiu-se que problemas envolvendo teorias avançadas no campo da qualidade da energia elétrica estão cada vez mais presentes nas plantas eólicas brasileiras, os quais muitas vezes passam despercebidos pela maioria das medições de qualidade da energia elétrica, haja vista que parte destes problemas se encontram em faixas de frequência superiores às avaliadas pela maioria dos equipamentos de medição de qualidade de energia elétrica. Ademais, outros conceitos, tais como interações harmônicas, oscilações subsíncronas e supraharmônicos, ainda são muito pouco investigados em âmbito nacional e internacional.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, SIGA – Sistema de Informações de Geração da ANEEL. Disponível em <https://app.powerbi.com/view?r=eyJrIjoibNjc4OGYyYjQtYWM2ZC00YjllLWJlYmEtYzdkNTQ1MTc1NjM2liwidCI6IjQwZDZmOWI4LWVjYjYtNDZhMi05MmQ0LWVhNGU5YzAxNzBIMSIsImMiOjR9>. Acesso em: 30 de junho de 2023.

ARRILAGA, J., WATSON, N. R. Watson, “Power system harmonics”, John Wiley & Sons, 2a Edição, England, 2004.

BLOCK, P.A.B, BONELLI, A.F., BONELLI, M.L., “Soluções de Filtragem Harmônica para Complexos Eólicos: Determinação dos Impactos na Média Tensão”, Brazil Windpower, Outubro de 2022.

BOSE, B.K., “Global energy scenario and impact of power electronics in 21st century. Industrial Electronics,” IEEE Transactions on, 60(7), 2638-2651, 2013.

DUGAN, R.C., MCGRANAGHAN, M.F., SANTOSO, S., BEATY, H.W., “Electrical Power Systems Quality”, McGra-Hill, 2ª Edição, Nova Iorque, 2002.

INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC 61000-3-6 – “Limits - Assessment of emission limits for the connection of distorting installations to MV, HV and EHV power systems”, 2008.

INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC 61400-21-1 – “Wind energy generation systems – Part 21-1: Measurement and assessment of electrical characteristics – Wind turbines”, 2019.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO – NT 009/2016 Rev. 03 – “Instruções para Realização de Estudos e Medições de QEE Relacionados aos Acessos à Rede Básica ou aos Barramentos de Fronteira com a Rede Básica para Parques Eólicos, Solares, Consumidores Livres e Distribuidoras”, 2019.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO – PROCEDIMENTOS DE REDE – Submódulo 2.3 “Premissas, critérios e metodologia para estudos elétricos - Metodologia”, 2021a.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO – PROCEDIMENTOS DE REDE – Submódulo 2.9 “Requisitos mínimos de qualidade de energia elétrica para acesso ou integração à Rede Básica”, 2020.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO – PROCEDIMENTOS DE REDE – Submódulo 2.10 “Requisitos técnicos mínimos para a conexão às instalações de transmissão”, 2021b.

RONNBERG, S., BOLLEN, M.H.J., LARSSON, A., LUNDMARK, M., “An overview of the origin and propagation of Supraharmonics (2-150 kHz)”, Nordac, September 2014.

Implementação de Sistema de Lubrificação Automática e Filtro Offline em Aerogeradores

Fabício André Rörig¹, Gustavo Pombo Filippon², Alexandre Simon Shyu³

fabricao.rorig@statkraft.com¹, gustavo.filippon@statkraft.com², alexandre.shyu@statkraft.com³

RESUMO

A indústria de energia eólica vem experienciando falhas precoces de importantes componentes de aerogeradores, com a maioria dessas falhas envolvendo rolamentos. Estudos recentes estimam que somente 10% de todos os rolamentos de turbinas eólicas operam propriamente ao longo de todo seu ciclo de vida, sendo 36% de todas as falhas prematuras em rolamentos causadas por falta de lubrificação apropriada, o que se combinado com o percentual de rolamentos danificados por lubrificantes contaminados, chega a 50% [1][2]. No presente trabalho são apresentados dois sistemas implementados em aerogeradores para melhorar a lubrificação de rolamentos: sistema de lubrificação automática, filtro offline na gearbox.

Palavras-chaves:

Lubrificação automática; Rolamentos; Filtro Offline; Manutenção; Automação.

ABSTRACT

The wind energy industry has been experiencing early failures of important wind turbine components, with most of these failures involving bearings. Recent studies estimate that only 10% of all wind turbine bearings operate properly throughout their entire life cycle, with 36% of all premature failures in bearings being caused by lack of proper lubrication, which if combined with the percentage of bearings damaged by contaminated lubricants, reaches 50% [1][2]. In the present work, two systems implemented in wind turbines to improve the lubrication of bearings are presented: automatic lubrication system, gearbox offline filter.

Keywords:

Automatic Lubrication; Bearings; Offline Filter; Maintenance; Automation.

1. INTRODUÇÃO

Até o início de 2023, o Brasil registra 890 parques eólicos instalados, somando 25,04 GW de capacidade instalada em operação comercial, e projeções mostram que esse número deve chegar a 44,78 GW até 2028 [3]. A geração de energia eólica traz benefícios econômicos e ambientais que superarão os métodos tradicionais de geração de energia a longo prazo, no entanto, o crescimento acelerado da indústria eólica também trouxe novos desafios [4].

As complexas condições operacionais, como rápidas alterações de temperatura, pressão do ar, velocidade

do vento e cargas, fazem desses equipamentos extremamente vulneráveis a falhas, com destaque para falhas em rolamentos, que são os componentes principais de seções críticas, e têm efeito significativo no sistema de transmissão, o que ajuda a fornecer um movimento de rotação suave. Estudos recentes estimam que somente 10% de todos os rolamentos de turbinas eólicas operam propriamente ao longo de todo seu ciclo de vida, sendo 36% de todas as falhas prematuras em rolamentos causadas por falta de lubrificação apropriada, o que se combinado com o percentual de rolamentos danificados por lubrificantes contaminados, chega a 50% [1][2].

Como qualquer outro sistema mecânico, turbinas eólicas necessitam lubrificação apropriada para funcionarem de forma ideal. No entanto, diferentemente de máquinas em chão de fábrica, que podem ser facilmente lubrificadas rotineiramente de forma manual, a lubrificação dos aerogeradores requer mão de obra especializada, em locais de difícil acesso, além do frequente monitoramento da condição da lubrificação nos rolamentos.

No presente trabalho são apresentados dois sistemas implementados em aerogeradores para melhorar a lubrificação de rolamentos e engrenagens, de forma a aumentar a produtividade, minimizar impactos ambientais, e melhorar a saúde e segurança dos trabalhadores: implementação de sistema de lubrificação automática; instalação de filtro offline nos equipamentos Gearbox.

2. SISTEMA DE LUBRIFICAÇÃO AUTOMÁTICA

A lubrificação adequada é essencial para manter os aerogeradores em movimento e minimizar o tempo de inatividade. Sistemas de lubrificação automática estão se tornando padrão em turbinas maiores que 2 MW e são particularmente importantes para unidades offshore. Esses sistemas oferecem melhorias pois reduzem o tempo de inatividade, estendem a vida útil do equipamento, aumentam a eficiência e economizam materiais.

Sistemas de lubrificação automática fornecem lubrificante de forma confiável e precisa para os componentes móveis do aerogerador, enquanto a máquina está em movimento, reduzindo o atrito dentro dos rolamentos e ajudando a evitar a contaminação. Com a lubrificação automática é possível garantir que os rolamentos sempre estão com uma quantidade de lubrificante próxima à ideal, sem a necessidade de mão-de-obra recorrente, diferentemente da lubrificação manual. A exemplificação da efetividade da lubrificação automática em comparação com a manual é apresentada na Figura 1.




Figura 1 - Comparação entre as lubrificações automática e manual.

2.1 ROLAMENTO PRINCIPAL E FALHAS NA LUBRIFICAÇÃO

O Rolamento Principal é o componente rotativo central de uma turbina eólica, devendo suportar todo o peso das pás e do *hub*, e transmitir o torque gerado pelas pás à Gearbox. Cabe também ao rolamento principal suportar os carregamentos alternados gerados pelo torque das pás, além do próprio peso delas, os requisitos para sua performance mecânica ao longo de sua vida útil são extremamente altos [5].

Dessa forma, o uso de lubrificantes é necessário para evitar o contato direto entre os elementos girantes e a pista [6], formando uma fina camada de óleo na superfície, reduzindo assim a fricção interna no rolamento. Lubrificantes reduzem o desgaste dos rolamentos quando o aerogerador está em operação, e estabilizam a estrutura para manter o equipamento rodando de forma constante e controlada.

A lubrificação inadequada desse rolamento ao longo de sua vida operacional pode afetar diretamente a performance e a confiabilidade do aerogerador, levando à falha prematura do componente. Os modos de falhas nesse rolamento podem ser separados em 3 causas diferentes:

1. Falha no rolamento devido a lubrificação excessiva;
2. Falha no rolamento devido a deterioração do lubrificante;
3. Falha no rolamento devido a lubrificação insuficiente.




Figura 2 - Elemento rolante de rolamento principal [11] de aerogerador danificado devido a lubrificação insuficiente.

Já os fatores físicos que levam a falhas na lubrificação em rolamentos de aerogeradores estão principalmente ligados à influência da velocidade do rolamento, temperatura e cargas [7]. Como as peças de atrito operam sob condições de alto cisalhamento, o lubrificante está constantemente sujeito a tensão de cisalhamento e força centrífuga, o que causa a destruição de sua estrutura. O desgaste dessa camada de lubrificante levará a fenômenos como a perda de precipitação dele, para fora da interface. Durante o funcionamento do rolamento, ele é jogado para fora do rolamento devido à força centrífuga, resultando finalmente na perda de eficácia do lubrificante [8].

Sabendo que o rolamento principal está propenso a ter falhas prematuras, uma vez que ele deve suportar constantes cargas elevadas, e o difícil acesso torna-o suscetível a problemas relacionados a lubrificação manual falha, o rolamento principal foi selecionado para a instalação de protótipo de sistema de lubrificação automática.

2.2 O PROTÓTIPO

O sistema selecionado é composto por um reservatório onde a graxa é armazenada, uma bomba, e mangueiras conectadas, e fixadas em pontos específicos do rolamento principal, por onde a graxa é bombeada até ele. O equipamento foi instalado próximo ao rolamento principal, em local estratégico para facilitar o preenchimento do reservatório.



Figura 3 – Sistema de lubrificação automática selecionado



Figura 4 – Sistema de lubrificação automática instalado no aerogerador



Figura 5 – Simulação da saída da graxa pelas mangueiras do Sistema de lubrificação automática

2.3 RESULTADOS

Com o protótipo de sistema de lubrificação automática instalado no rolamento principal de um aerogerador, foi possível observar resultados positivos em 3 esferas:

- a. **Redução da exposição a riscos:** O trabalho de realizar lubrificações manuais recorrentes no rolamento principal é perigoso. Esse componente fica em local de difícil acesso dentro da nacela, situada a mais de 80 metros de altura. Por isso, reduzir a frequência de visitas técnicas é um fator mitigatório para potenciais acidentes.

- b. **Extensão da vida útil do equipamento:** Com o sistema instalado, é possível garantir que o rolamento nunca está com excesso ou escassez de graxa. Com a injeção recorrente de lubrificante novo, também se minimiza as chances de falhas por deterioração do lubrificante. Dessa forma, tem-se as melhores condições possíveis para que o rolamento possa funcionar apropriadamente. Para rolamentos previamente danificados, a lubrificação pode auxiliar na extensão da condição

atual, até uma troca do componente, estendendo assim a sua vida útil. O potencial ganho em extensão da vida útil do equipamento é ainda maior se o sistema for instalado em um rolamento novo.

- c. **Redução de custos e geração de resíduos:** com o sistema de lubrificação automática, reduz-se os custos com mão de obra, visto que a frequência de visitas técnicas é reduzida. Contudo, o maior ganho se dá na redução do desperdício com o material. O aumento da eficiência e qualidade da aplicação permite que o sistema utilize um volume menor e mais preciso de lubrificante a cada intervalo de manutenção. Menos graxa também reduz o impacto ambiental do desperdício dela.

3. FILTRO OFFLINE

A filtragem do óleo é um processo crucial para manter a qualidade e a eficiência dos sistemas de lubrificação industrial. O objetivo principal é remover partículas sólidas indesejadas, como poeira, areia, partículas metálicas, resíduos de desgaste e outros contaminantes presentes no óleo lubrificante. Essas partículas podem ser extremamente prejudiciais para componentes mecânicos, causando desgaste, corrosão e danos prematuros [9].

No processo de filtragem, o óleo passa por um elemento filtrante que atua como uma barreira para as partículas sólidas (Figura 6). Em muitos casos, a filtragem convencional não é suficiente para eliminar as partículas de contaminantes e garantir que o óleo flua pelo sistema no grau de limpeza desejado. Nestes casos, é instalado um sistema de filtragem offline, onde o óleo é derivado da linha principal para um circuito paralelo, passando por um filtro e retornando para a Gearbox [10].



Figura 6 – Representação do funcionamento de um filtro offline.

A presença de partículas no óleo lubrificante pode causar danos significativos ao sistema de engrenagens de equipamentos Gearbox de turbinas eólicas, resultando em desgaste prematuro, falhas e, eventualmente, na necessidade de reparos ou substituição dos componentes. Dessa forma, filtros offline podem ser usados para proteger o sistema contra partículas e contaminantes geradas pelo desgaste normal das engrenagens e outros componentes, que podem entrar no óleo lubrificante.

Existem vários tipos de filtros utilizados na indústria para remoção de partículas sólidas do óleo lubrificante. Os filtros de cartucho são compostos por um meio filtrante de alta eficiência, projetado para capturar partículas finas, sendo amplamente utilizados em sistemas que requerem boas precisões de filtragem.

Sabendo da necessidade de uma boa precisão de filtragem da Gearbox de turbinas eólicas, e do potencial de filtros offline de cartucho, foi instalado um protótipo em uma caixa multiplicadora de um aerogerador, para estudar os resultados.

4. RESULTADOS

Com o protótipo de sistema de filtragem offline instalado na Gearbox de um aerogerador, foi possível observar através de análises de óleo realizadas antes e após a instalação do sistema, com um período de 3 meses entre as amostras, a diminuição da quantidade de partículas contaminante (Figura 7), além da redução do teor de água (Figura 8), e do PQI (Figura 9).

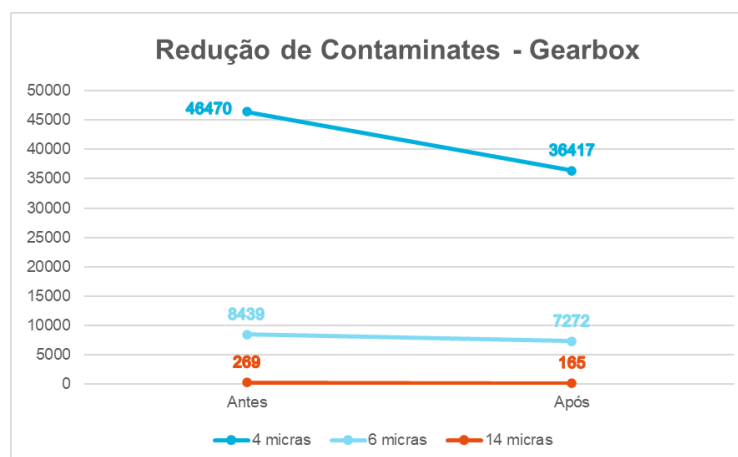


Figura 7 – Variação da quantidade contaminantes no óleo da Gearbox, antes e após a instalação do sistema.




Figura 8 – Variação do teor de água (ppm), antes e após a instalação do sistema



Figura 9 – Variação do PQI, antes e após a instalação do sistema

Apesar do período de amostragem ser curto, já é possível verificar ganhos, porém não muito grandes. Estima-se que em um período de 1 ano após a instalação do sistema de filtragem offline, atinge-se a purificação completa do óleo.

5. CONCLUSÕES

Foram apresentados dois sistemas implementados em aerogeradores para melhorar a lubrificação de rolamentos: sistema de lubrificação automática, filtro offline na Gearbox.

Para o sistema de lubrificação automática, foi possível através do protótipo identificar ganhos através da redução da exposição a riscos ao reduzir a frequência de visitas técnicas; a extensão da vida útil do equipamento ao garantir as melhores condições possíveis para que o rolamento possa funcionar apropriadamente, sendo possível auxiliar na extensão da condição atual de um rolamento previamente danificado até uma troca do componente; além de proporcionar uma redução nos custos e na geração de resíduos através da diminuição dos gastos com mão de obra e desperdícios com a graxa lubrificante.

Já para o caso do sistema de filtro offline instalado na Gearbox, foi possível observar a redução da quantidade de partículas contaminantes, do teor de água, e do PQI, mesmo com um período curto de amostragem após a instalação do sistema, e com a vazão do filtro baixa. Espera-se que com um período de um ano após a instalação do sistema, a purificação completa do óleo seja atingida.

REFERÊNCIAS

- [1] Venci A.; Rac A. Diesel engine crankshaft journal bearings failures: Case study. *Eng. Fail. Anal.*, v. 44, September, p. 217-228, 2014.
- [2] de la Hermosa González, R.R.; Márquez, F.P.G.; Alexander, K.; Papaelias, M. In *Methods and tools for the operational reliability optimisation of large-scale industrial wind turbines*, Proceedings of the Ninth International Conference on Management Science and Engineering Management, Springer: pp 1175-1188, 2015.
- [3] AGÊNCIA BRASIL. Capacidade de geração de energia eólica deve bater recorde neste ano. Disponível em: <https://agenciabrasil.ebc.com.br/economia/noticia/2023-04/capacidade-de-geracao-de-energia-eolica-deve-bater-recorde-neste-ano>. [Acessado em 26 de junho de 2023].
- [4] Agarwal T., Verma S., Gaurh A. Issues and challenges of wind energy. *International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*, Chennai, India, pp. 67-72, 2016.
- [5] Islam M., Fartaj A., Carriveau R. Analysis of the Design Parameters Related to a Fixed-Pitch Straight-Bladed Vertical Axis Wind Turbine. *Wind Engineering*. v. 32, n. 5, p. 491-507, 2008.
- [6] Stammer M., Reuter A., Poll G. Cycle counting of roller bearing oscillations—case study of wind turbine individual pitching system. *Renewable Energy Focus*. v. 25. P. S.40-47, 2018.
- [7] Márquez F.P.G., Pérez J.M.P., Marugán A.P., Papaelias M. Identification of critical components of wind turbines using FTA over the time. *Renewable Energy*, v. 87, n.2, p. 869-883, 2016.
- [8] Gershuni L., Larson M.G., Lugt P.M. Lubricant replenishment in rolling bearing contacts. *Tribology Transactions*, 51:5, 643-651, 2018.
- [9] Szeri, A. Z. *Fluid Film Lubrication: Theory and Design* (2nd ed.). Cambridge University Press, 2013.
- [10] Bloch, H. P., Geitner, F. K. Machinery Oil Analysis - Methods, Automation, Benefits, and Limitations. *Journal of Failure Analysis and Prevention*, v. 7, n. 6, p. 17-27, 2007.
- [11] SKF. *Bearing arrangements for wind turbine main shafts*. Disponível em: <https://www.skf.com/group/industries/wind-energy/drivetrain/main-shaft/bearing-arrangements>. [Acessado em 29 de junho de 2023].

OPTIMIZING LIFETIME STRATEGIES:

HOW CAN MAST, SCADA DATA, AND DIGITALIZATION MAKE THE DIFFERENCE?

Cyrille Huant – Project Engineer

UL Solutions

Cyrille.Huant@ul.com

ABSTRACT

Wind assets valuation is playing a key role for a successful business model. Evaluating the remaining useful life of operating wind assets is the basis for creating multiple economic scenarios and for choosing the one that meets company's goals and mission.

While the upcoming IEC 61400-28 standard will support the industry with defining lifetime extension best practices, it will also focus on ensuring safety of the operating wind assets. Accurate calculation of remaining useful life requires both analytical and practical analysis, for which various input data are valuable. After conducting lifetime evaluations over more than 25 GW worldwide, UL analyzed results of these calculations depending on the available input data at site.

The impact of the number of years available, the minimum number of variables to be considered and the comparison with other sources of information, such as wind measurement inputs based on met mast / RSD is shared. On average, remaining Useful Life can vary 5 years and uncertainties can reduce on two or three-fold depending on the availability of some data, and consequently an emphasis is given on how it can be a game changer for owners and operators to define the most relevant strategy for their operational asset complying with their safety and sustainability goals as well as their ESG commitment.

Keywords:

Lifetime extension, uncertainties, risks, asset management

1. INTRODUCTION

1.1 OBJECTIVE

This article aims to analyze the impact on the quantity and quality of data to offer accurate lifetime forecast for wind turbines, through a comprehensive assessment of real cases all over Europe, and to emphasize on how this kind of studies will be critical for Brazilian wind park owners to maintain competitiveness.

1.2 RELEVANCE FOR BRAZILIAN INDUSTRY

Brazil has gone through an exponential growth in wind power industry since first auctions started in 2009 exclusively for wind energy. Those first auctioned parks are now more than a decade old, which means that they are exceeding half of expected lifetime. Owners and operators aim to ensure the long-term performance and reliability of wind turbines, consequently, diminishing operational costs as much as

possible, to achieve this, it is necessary to account with the proper studies that provide meaningful insights for decision makers. Lifetime evaluation, encompassing the comprehensive assessment of wind turbine components, structural integrity, and inspection strategies, will play a paramount role in maximizing energy production, minimizing downtime, and optimizing the economic viability of wind power projects.

This article shows the impact of data availability through a comprehensive analysis of European experience in aging wind parks, this experience will provide relevant insights for the Brazilian wind industry. The first topics offer a brief technical base of lifetime evaluation method calculation which can be applied to any wind park in operation, followed by a comparative analysis of diverse scenarios in which different data sets were available. After this, an uncertainty calculation shows the impacts on data availability for critical wind turbine components, to end with main conclusions and final remarks.

1.3 LIFETIME EVALUATION BASIS

Lifetime evaluation for wind turbines refers to the comprehensive assessment of various factors that impact the performance, durability, and operational lifespan of these renewable energy systems. It involves the systematic examination of key components such as blades, gearbox, generator, control systems, and support structures to determine their condition and potential for deterioration over time. Through a combination of data analysis, inspections and monitoring, lifetime evaluation aims to identify any potential issues, defects, or weaknesses that could affect the efficiency, reliability, and safety of wind turbines throughout their operational lifespan. By proactively assessing and addressing these factors, operators can optimize the energy output, minimize downtime, and extend the useful life of wind turbines, ultimately improving the overall sustainability and economic viability of wind power projects.

2. LIFETIME EVALUATION ANALYSIS ASPECTS

2.1 MAIN INPUTS

Lifetime evaluation is a flexible analysis that may adapt to the available data. Owners and operators may hold a diverse quantity and quality of data sets, depending on several factors, such as: wind turbine manufacturer, previous development, wind park age, data collection software, available met masts, among others. The following items divide the three main data sources to perform lifetime evaluation analysis:

- **Site related:** Topography, layout, complexity, obstacles, Site Values for Load Calculation
- **Turbine Related:** Type certificate, power curves, independent aeroelastic model, etc. for the calculation of design and site-specific loads
- **Operational Information:** SCADA, logs, inspection, maintenance

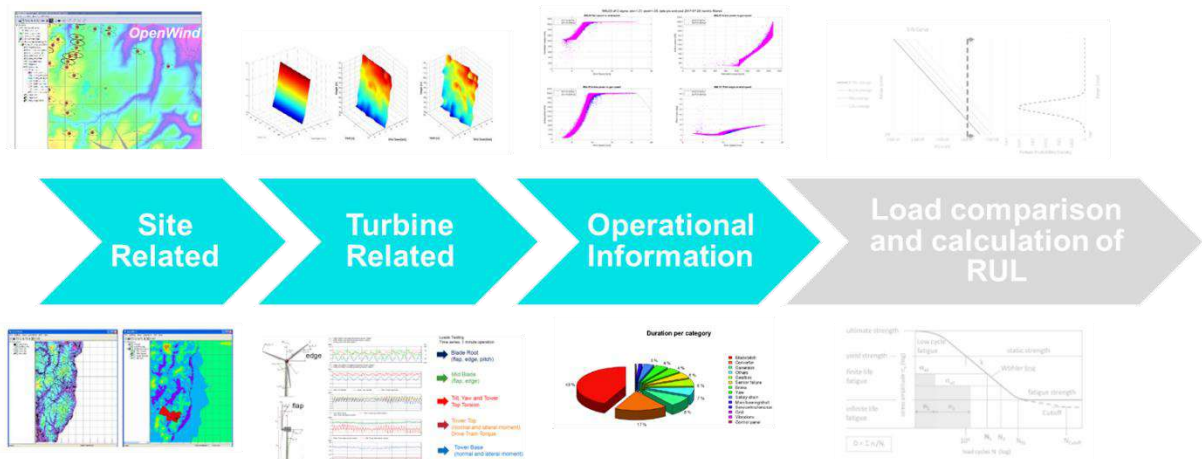


Figure 1 Possible dataset for LTE analysis

2.2 MAIN UNCERTAINTIES

All of LTE variables play a relevant role in accurate calculation. However, two main variables are highly sensitive to reduce uncertainties:

- **Wind speeds:** Due to physics characteristics of wind power output, wind speed has traditionally been a critical sensible variable for all forecasts, as wind power is directly proportional to the cube of wind speed, which means that small changes in wind speed have significant impacts on power output.
- **Turbulence:** Refers to the irregular fluctuations in wind speed and direction, it can have a significant impact on the structural integrity and fatigue life of wind turbine components. High turbulence can accelerate wear and tear, leading to premature failures and reduced life expectancy of the turbine.

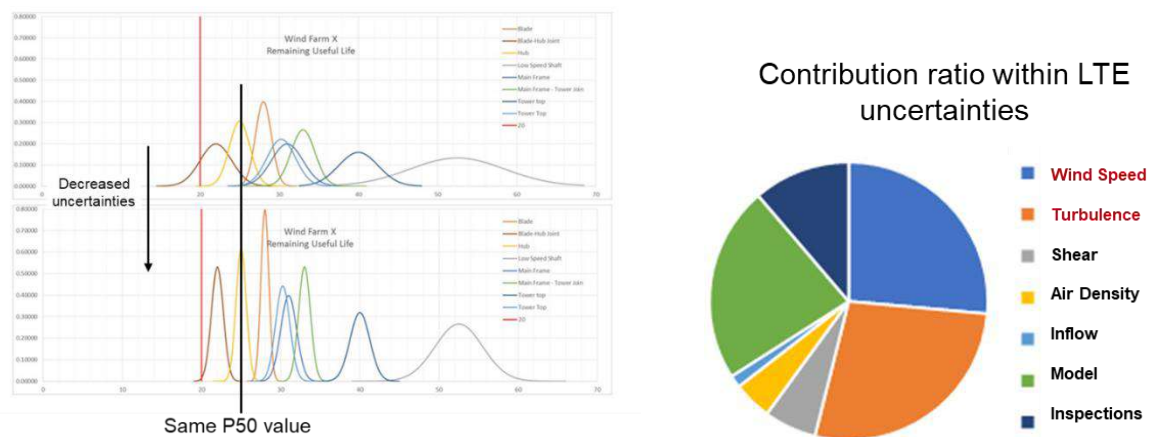


Figure 2 Model sensitiveness to several variables

3. MÉTODO DO ESTUDO

3.1 CASE STUDIES

As the study objective is to emphasize the relevance of data quality and quantity for lifetime extension, regardless of wind park location, 12 wind farms across Europe were selected. As seen in the table and figure below, the locations varied considerably, which established a wind speed, turbulence, layout, and overall characteristics diversity to the study. The turbine models were considered the same for all wind parks in order to focus on wind data sensitivity and avoid any bias by other factors. For each wind park, 4 scenarios of data were applied, as described in the following topic.

Table 1 Analyzed wind parks

Project Name	Country	Capacity (MW)	Mean Wind Speed Affected Wakes (m/s)	Effective turbulence Intensity @15m/s (%)
WF1	Spain	10	5.6	13.98
WF2	Italy	42	7.5	14.56
WF3	Italy	30	7.1	15.42
WF4	Italy	16	7.0	14.84
WF5	Germany	24	6.0	15.05
WF6	France	12	6.1	13.60
WF7	Italy	66	6.2	16.62
WF8	Italy	56	6.5	14.25
WF9	UK	9	7.9	15.31
WF10	Spain	5	7.1	15.63
WF11	Italy	23	6.4	18.96
WF12	Germany	6	6.7	18.02



Figure 3 Wind parks location

3.2 SCENARIO DEFINITION

The following scenario configuration was defined by characteristics of datasets commonly provided by wind industry players to perform such studies. The reason to perform lifetime extension studies may vary, ranging from M&A due diligence activities to O&M strategies such as repowering or revamping actions. It is expected that not always a complete data set is available, either because there is no access, or it is not being produced. The scenarios presented below aim to cover such data availability situations.

1. Mesoscale wind model (no further inputs)
2. Mesoscale wind model and O&M reports (with production and availability)
3. Mesoscale, O&M reports and 10-min SCADA data (average wind speed mean values and standard deviations, wind direction)
4. Mesoscale, O&M reports, 10-min SCADA data (only average wind speed) and high-quality on-site measurements (mast)

Table 2 Scenarios characteristics

Scenario	Wind speed correction	Shear	Wind speed distribution	Effective Turbulence Intensity at 15 m/s	Wind direction
1	No	Mesoscale	Mesoscale	Mesoscale	Mesoscale
2	Yes	Mesoscale	Mesoscale + O&M	Mesoscale + O&M	Mesoscale + O&M
3	Yes	Mesoscale	Mesoscale + O&M + SCADA data	Mesoscale + O&M + SCADA data	Mesoscale + O&M + SCADA data(wind vane)
4	Yes	On-site Mast	Mesoscale + O&M + SCADA data + On-site Mast	Mesoscale + O&M + SCADA data + On-site Mast	Mesoscale + O&M + SCADA data + On-site Mast

3.3 LONG TERM CORRECTION

Prior to calculate the lifetime extension, a long-term correction for the wind model must be applied. This is performed by using SCADA data, which is also used to understand turbine behavior over the years, particularly any previous condition on the equipment. Depending on quality and quantity of data a minimum of 5 years of consistent data should be needed, considering 7-8 years a best-case scenario for results quality.

3.4 AEROELASTIC MODELS

Aeroelastic models for wind turbines are mathematical representations or simulations that combine the principles of aerodynamics and structural dynamics to study the interactions between the wind and the turbine structure. These models are used to analyze and predict the behavior of wind turbines under various

operating conditions, including normal operation, extreme weather events, and design considerations. Aeroelastic models consider the following key factors:

- 1. Aerodynamics:** The interaction between the wind and the turbine blades is crucial for understanding how the turbine captures energy. The aerodynamic model considers factors such as wind speed, air density, angle of attack, and lift and drag forces acting on the blades.
- 2. Structural Dynamics:** The response of the wind turbine structure to aerodynamic forces is modeled using principles of structural mechanics. This includes the dynamic behavior of the rotor, tower, and other components under various loads, such as gravity, wind, and turbulence.
- 3. Control Systems:** Aeroelastic models also incorporate the control algorithms and systems used to regulate the operation of wind turbines. These systems adjust parameters such as blade pitch and generator torque to optimize energy capture and ensure the turbine operates within safe limits.

By combining these elements, aeroelastic models can provide valuable insights into the performance, stability, and reliability of wind turbines. They help engineers evaluate design choices, assess the impact of environmental conditions, and optimize turbine operation for maximum energy production and structural integrity.

Such models can be implemented using various techniques, ranging from simplified linear models to more complex nonlinear simulations. These models are typically validated and calibrated using real-world measurements from operational wind turbines and wind tunnel experiments to ensure accuracy and reliability.

3.5 MAIN ASSUMPTIONS

- Loads analysis based on independent aeroelastic models (IAM)
- UL4143 standard / state-of-the-art industry practices / upcoming IEC 61400-28
- Turbine Related input data: same IAM for all projects
- Multidirectional analysis: 84 sectors
- Focus on the most critical / limiting structural components: For 80% of UL fleet analyzed these were the most limiting components (> 26 GW):
 - Blade Root, Composite
 - Blade Root, Joint
 - Hub
- + Tower Bottom (Additional component)
- Load uncertainties are based on:
 - wind conditions, IAM, inspections
 - sensitivity load analysis per wind parameter and structural component
 - quadratic sum of each contribution that are considered independent



Figure 4 Critical wind turbine parts considered

4. RESULTS

4.1 MAIN VALUES AND DISCUSSION

Blade Root, Composite: The following image shows that remaining useful life spans 32 to 41 years for all scenarios, at 50% of probabilities of exceedance. Results showed consistency as the standard deviation was 5% as average at 50% the probability of exceeding the remaining Useful Life values between each scenario.




Figure 5 Exceedance Probability of RUL - Blade root, Composite

The tables below depict the uncertainties levels difference among main parameters when considering the different dataset scenarios. Uncertainties can increase from 9.62% to 30.27% for wind shear, and from 2.7% to 10.3% for wind speed. As stated previously, particularly wind speed is a critical value to provide accurate results due to its high sensitivity in simulations and calculations.

Table 3 Main wind characteristics variations

Parameter	Design	Scenario 1 Mesoscale	Scenario 2 O&M report	Scenario 3 SCADA	Scenario 4 On-site
Wind speed	10.0	7.14	6.22	6.1	6.07
TI at 15 m/s	17.97	15.43	14.87	20.21	16.38
Shear	0.20	0.11	0.11	0.1	0.04
Air Density	1225	1.13	1.13	1.13	1.13
Inflow Angle	8.00	-0.16	-0.16	-0.16	-0.17

Table 4 Uncertainty levels

Parameter	Scenario 1 Mesoscale	Scenario 2 O&M report	Scenario 3 SCADA	Scenario 4 On-site
Wind speed	10.30%	5.33%	4.63%	2.76%
Effective TI at 15 m/s	30.27%	30.27%	22.85%	8.50%
Shear	30.27%	30.27%	30.27%	9.62%
Air density	6.41%	6.41%	5.06%	3.51%
Inflow Angle	5.48%	5.48%	2.45%	2.45%

Blade Root, Composite: Life expectancy values trend shows higher values for the scenario 4 (with on-site measurements). Lowest uncertainties for scenario 4 (with on-site measurements) lower than 20% when compared to other scenarios which are above 40%.




Figure 6 Blade Root, Composite

Blade Root, Joint: Life expectancy values trend shows higher values for the scenario 4 (with on-site measurements). Lowest uncertainties for scenario 4 (with on-site measurements) lower than 10% when compared to other scenarios which are above 20%.




Figure 7 Blade Root, Joint

Hub: Life expectancy values trend shows higher values for the scenario 4 (with on-site measurements). Lowest uncertainties for scenario 4 (with on-site measurements) lower than 15% when compared to other scenarios which are above 35%.




Figure 8 Hub

Tower Bottom: Life expectancy in this case is provided only for calculations, as it is intended that is a much stronger structural turbine component. This analysis is given specially to understand the sensibility difference between Turbulence and Wind Speed. Sensibility to Turbulence Intensity much higher than to Wind speed. Lowest uncertainties for scenario 4 (with met mast). However, in some cases, tower bottom may also be impacted by other factors and its life expectancy could be drastically reduced.




Figure 9 Tower Bottom / Wind Speed




Figure 10 Tower Bottom / Turbulence

5. FINAL REMARKS

- The study shows that the scenarios with less data available and without on-site measurements lead to more conservative results which means that lifetime expectations, especially for blades, can be underestimated. On the other hand, by using a more complete datasets, components lifetime can be fully harnessed, while still evaluating its risks. This gap may vary approximately 5 years difference between scenarios, as seen in the previous graphs.
- SCADA and Mesoscale scenario provide the most conservative results in some cases. Which can be relevant depending on the wind farm age and the operator approach and risks perception. In addition, without using SCADA it will be impossible to understand relevant events that may have affected fatigue conditions for the wind turbine.
- In critical components, blades and hub, uncertainties dropped by a half or a third. This is crucial when interpreting the results and to roll out O&M activities such as future inspections schedules or repowering options, thus, it is possible to perform more accurate OPEX estimates. This study also provides insights of uncertainties levels for LTE screenings for financing Due Diligence or M&A processes.
- Brazilian turbine fleet is ageing, therefore, it is relevant to perform similar studies considering Wind Parks with COD prior to 2010 approximately, and verify the parameters behavior and trends, to understand if local wind conditions effects in wear and fatigue.

REFERÊNCIAS

ANSI/UL, "UL 4143 Wind Turbine Generator - Life Time Extension (LTE)," ANSI/UL, 2018.

Eurocode 3, "Design of Steel Structures, part 1-9 fatigue strength".

Eurocode 2, "Design of concrete structures Part 1-1: General rules and rules for buildings".

International Institute of Welding, "International Institute of Welding," [Online]. Available: <http://www.iiwelding.org/Pages/Default.aspx>. [Accessed March 2017].

Germanisher Lloyd, Guideline for the Certification of Wind Turbines 2003, GL, 2003.

International Electrotechnical Commission (2008), "Wind Turbines - Part1: Design requirements. 61400-1 Third Edition 2005-08," IEC, 2005-08.

Technical University of Denmark, "Flex 5".

IEC, "IEC Wind turbines - 61400-1 Ed.2.0 - Safety requirements," International electrotechnical Commission, 1999.

E. L. Committee., "EA-4/02:Evaluation of the Uncertainty of Measurement In Calibration," 2013.

European Accreditation Laboratory Committee, "EA-4/02 M: 2013 Evaluation of the Uncertainty of Measurement in Calibration," EA Laboratory Committee, 2013.

"ISO/TC 135/SC 8 Thermographic testing".

"3, ISO/TC 135/SC, Ultrasonic testing".

"CEN - EN 1369 Founding - Magnetic particle testing".

"ISO 3452-1:2013 Non-destructive testing -- Penetrant testing -- Part 1: General principles".