

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.

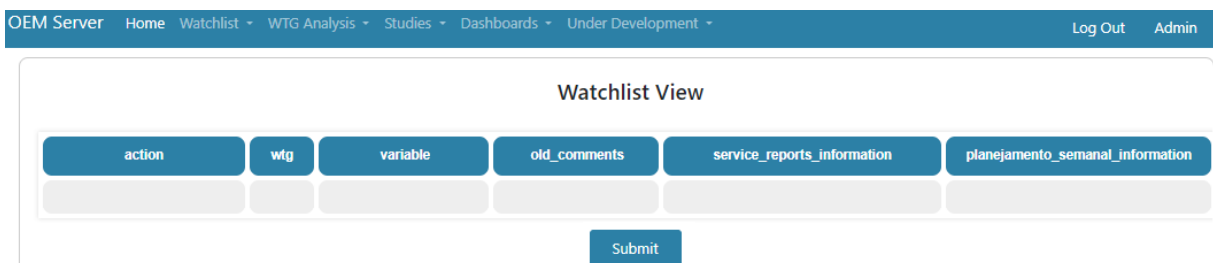


Figura 1 - Funcionalidade de visualização de variáveis consideradas importantes para acompanhamento em software proprietário desenvolvido. Na imagem, são mostrados os campos *service_reports_information*, no qual é informado a respeito de eventuais manutenções passadas ocorridas no respectivo aerogerador,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

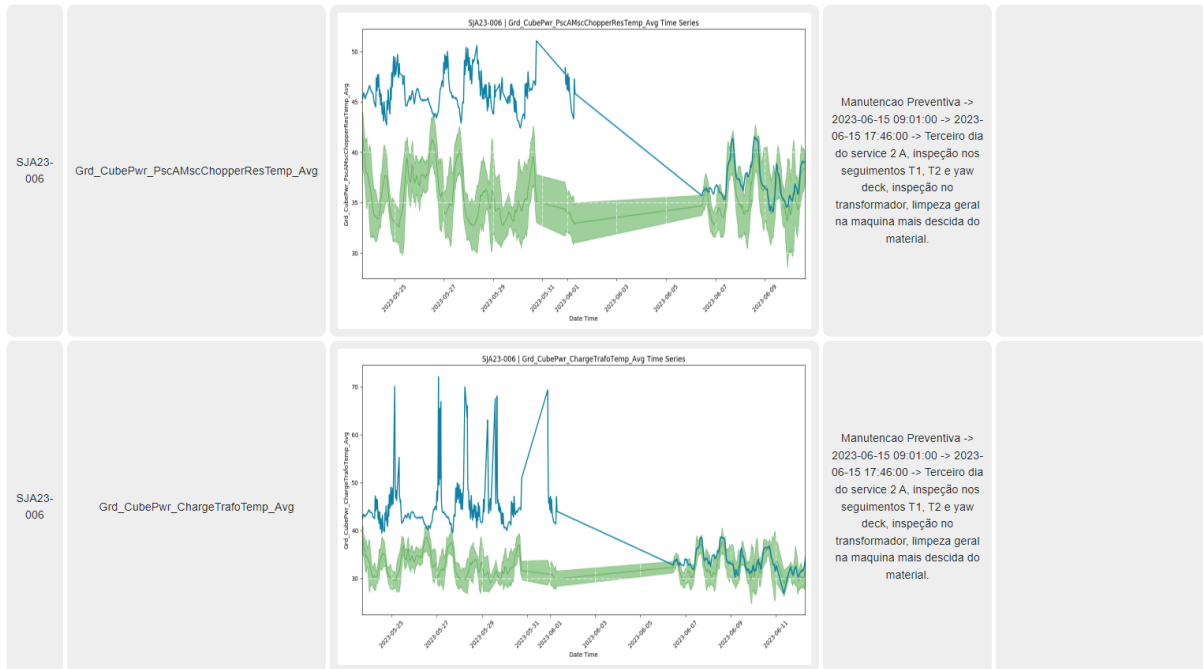


Figura 3 - Variáveis referentes a temperaturas de diferentes componentes do sistema de conversão de determinado aerogerador a serem incluídas em manutenção programada.




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 nacele 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.