

Aplicação de Modelos Ocultos de Markov para Detecção de Falhas em Componentes de Turbinas Eólicas

Fernando de Sá¹, Danielle Pinna¹, Kennedy Fernandes², Sanderson Gonzaga de Oliveira³, Rodrigo Toso⁴, Kele Belloze¹, Diego Brandão¹

¹Programa de Pós-Graduação em Ciência da Computação
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ)
Rio de Janeiro – RJ – Brasil

diego.brandao@cefet-rj.br

²Universidade Federal do Sul da Bahia - UFSB
Teixeira de Freitas – BA – Brasil

³Universidade Federal de São Paulo - Unifesp
São José dos Campos – SP – Brasil

⁴Microsoft, Washington, U.S.

Abstract. *The growing demand for renewable energy solutions highlights the importance of wind turbines in energy conversion. Monitoring, diagnosing, and predicting failures in these systems is crucial to ensuring continuous energy production. Sensors monitor the operation of the turbines, and the collected data is used to create models that identify early signs of deterioration, allowing for the rapid detection of failures and reduction of maintenance costs. This study proposes an approach based on Hidden Markov Models to monitor and diagnose wind turbine generators and gearbox failures. The results obtained through the F-Score metric demonstrate the feasibility of the proposed approach.*

Resumo. *A demanda crescente por soluções energéticas renováveis destaca a importância das turbinas eólicas na conversão de energia. Monitorar, diagnosticar e prever falhas nesses sistemas é crucial para garantir a produção contínua de energia. Sensores monitoram o funcionamento das turbinas e os dados coletados são usados para criar modelos que identificam sinais precoces de deterioração, permitindo a detecção rápida de falhas e a redução dos custos de manutenção. Este estudo propõe uma abordagem baseada em Modelos Ocultos de Markov para monitorar e diagnosticar falhas em geradores e caixas de velocidade de turbinas eólicas. Os resultados obtidos pela métrica F-Score demonstram a viabilidade da abordagem proposta.*

1. Introdução

A energia eólica tem se destacado como uma fonte promissora e sustentável de energia no Brasil, impulsionada pelo potencial eólico significativo do país [Council, 2021]. Com vastas extensões territoriais costeiras e uma topografia favorável em algumas regiões do interior, o Brasil apresenta condições climáticas ideais para o desenvolvimento da energia eólica. Além de contribuir para a diversificação da matriz energética brasileira, a energia

eólica desempenha um papel fundamental na redução das emissões de gases de efeito estufa e na mitigação dos impactos ambientais associados à geração de energia.

À medida que o uso da energia eólica se expande, surgem desafios cada vez maiores para aprimorar o desempenho na geração de energia por meio deste recurso. As turbinas eólicas, complexas e dispendiosas, exigem manutenção regular. Durante sua operação, estão sujeitas a uma variedade de pressões internas e externas. As pressões internas envolvem o desgaste de componentes, vibrações e corrosão, enquanto as externas abrangem fatores como erros humanos, condições climáticas adversas e falhas na infraestrutura elétrica [Kidam and Hurme, 2013].

Neste contexto, a manutenção preditiva emerge como uma estratégia crucial para otimizar o desempenho e garantir a confiabilidade operacional dos sistemas eólicos. Ao invés de adotar abordagens de manutenção corretiva ou preventiva, que muitas vezes podem ser dispendiosas e ineficientes, a manutenção preditiva baseia-se na análise de dados em tempo real para identificar sinais precoces de falha e realizar intervenções antes que problemas maiores ocorram [Kobbacy and Murthy, 2008]. Tal abordagem envolve a utilização de sensores e sistemas de monitoramento para coletar uma ampla gama de dados operacionais, como temperatura, vibração, pressão e consumo de energia, entre outros. Esses dados são analisados utilizando técnicas avançadas de análise de dados, como aprendizado de máquina e algoritmos de inteligência artificial, para identificar padrões e tendências que possam indicar potenciais problemas de desempenho ou falhas iminentes.

O presente trabalho aplica os Modelos Ocultos de Markov para a classificação de amostras pertencentes à operação normal e aos processos de pré-falha dos componentes da turbina eólica, especificamente as componentes gerador e caixa de velocidade. Este processamento consiste em associar cada estado do modelo a uma dessas classes (normal ou falha), acrescido a um método de seleção de características baseado no cálculo do *Maximum Likelihood Estimation* (MLE), cujo valor também é fornecido pelos modelos ocultos de Markov. Os resultados da detecção e diagnóstico de falhas em evolução são processados segundo uma classificação multiclasse, da qual extraímos métricas para avaliarmos a sua efetividade. Essa abordagem é aplicada em dados reais oriundos de sensores que avaliam a velocidade do vento e o funcionamento do gerador de turbinas eólicas disponibilizados pela empresa Energias de Portugal (EDPv) [EDP, 2021].

Este trabalho está dividido em mais 4 seções. Os trabalhos relacionados são discutidos na Seção 2. Uma breve revisão sobre modelos ocultos de Markov é apresentada na Seção 3, bem como a métrica de desempenho utilizada para avaliar o modelo desenvolvido. A Seção 4 apresenta os resultados obtidos pelo modelo desenvolvido bem como uma discussão sobre eles. Por fim, a Seção 5 apresenta as considerações finais e propostas de trabalhos futuros.

2. Trabalhos Relacionados

Os trabalhos relacionados aqui apresentados foram obtidos por meio da consulta à base de artigos acadêmicos Google Scholar utilizando a seguinte expressão de busca (“*hidden markov model*” and “*wind turbine*” and (“*fault detection*” or “*anomaly detection*” or “*fault monitoring*” or “*fault diagnosis*”)). Essa consulta retornou 21 referências, das quais quatro foram eliminadas pelos motivos: escrita em chinês, apresentar uma abordagem de gêmeos digitais para monitoramento em tempo de real, focar no monitoramento de linhas

de transmissão e, trabalhar com monitoramento de falhas de processos em batch por meio de lógica fuzzy.

Dentre os artigos avaliados, nove apresentavam uma revisão sobre o uso de técnicas baseadas em dados para a identificação de falhas em turbinas eólicas, especialmente técnicas de Aprendizado de Máquina (AM). No trabalho de [Khan and Byun, 2024], o mais recente dessas revisões, os autores realizam uma análise de artigos publicados entre 2013 e 2022, demonstrando um aumento no interesse pelo tema. Eles mostram que as técnicas de AM mais utilizadas para o problema são baseadas em redes neurais convolucionais (CNN) e máquinas de vetores de suporte (SVM).

Os autores em [Jiang et al., 2021] propuseram um método de monitoramento de condições em tempo real por meio da análise de características acústicas de caixas de engrenagens utilizando técnicas baseadas em autoencoders. O trabalho de [Chen et al., 2021] utiliza uma abordagem baseada em redes adversárias generativas convolucionais profundas (DCGAN) para definir um limite de autoconfiguração para monitorar rolamentos de geradores de turbinas eólicas. Em [Xu et al., 2023], os autores apresentam uma abordagem baseada em redes neurais fisicamente informadas para a identificação de falhas em sistemas eletromecânicos.

O trabalho de [Li et al., 2019] aprimora um modelo de cadeias ocultas de Markov acrescentando uma regra de degradação do desempenho do componente de uma turbina eólica, criando uma nova matriz de probabilidade de transição de estado correlacionada ao tempo com recurso de degradação. A curva de confiabilidade é obtida usando as probabilidades de estado do modelo de degradação. Os autores aplicam essa abordagem em dados de turbinas eólicas chinesas de 2011.

Os autores em [Kouadri et al., 2020] associam modelos ocultos de Markov (*Hidden Markov Models* (HMM) com o método de análise de componentes principais (PCA) para resolver o problema de detecção de falhas em sistemas de conversão de energia eólica sob condições operacionais variáveis. Os dados utilizados pelos autores são oriundos de simuladores de sistemas de turbinas eólicas. Diversos trabalhos focam na detecção de falhas em máquinas rotativas [Feng et al., 2023, Sahu et al., 2024, Li et al., 2024]. Eles propõem indicadores de saúde do sistema e trabalham com técnicas de aprendizado de máquina para identificar as falhas nesses sistemas.

Como pode ser visto, não foram encontrados artigos que utilizam HMM para detecção de falhas em turbinas eólicas a partir da base de dados da EDP [EDP, 2021].

3. Modelos Ocultos de Markov

Os modelos ocultos de Markov estendem os conceitos da Cadeia de Markov ao assumirem que cada observação é uma função de probabilidade do estado, o que resulta num modelo composto por um processo estocástico de dupla camada, na qual um processo estocástico não-observável (oculto) pode ser observado somente por outro processo estocástico, este último responsável por gerar a sequência de observações [Baum and Petrie, 1966]. Assim, a cadeia de Markov governa a transição entre estes estados, que em última instância determina qual a distribuição de probabilidade (segunda camada do processo estocástico) gera cada observação de uma série temporal.

O aprendizado em modelos ocultos de Markov envolve ajustar os parâmetros λ do modelo de Markov [Ghojogh et al., 2019] a fim de maximizar a probabilidade das observações condicionadas a este modelo $P(\mathbf{O}|\lambda)$. [Rabiner and Juang, 1986] afirmam que este é o problema canônico mais difícil, pois não se conhece nenhuma forma analítica de obtenção da máxima verossimilhança sob a forma da Equação (1).

$$\bar{\lambda} = \arg \max_{\lambda \in \Theta} P(\mathbf{O}|\lambda) \quad (1)$$

onde $\bar{\lambda}$ é o parâmetro que fornece o máximo global da probabilidade *a posteriori* dos dados durante a busca no espaço de possíveis valores desse parâmetro Θ .

Vemos essa solução global na Figura 1, para a qual $\bar{\lambda}_3$ fornece o valor máximo da probabilidade *a posteriori* $P(\mathbf{O}|\lambda)$.




Figura 1. Espaço de busca de modelos pelo algoritmo de Baum-Welch.

Para solucionar este problema, utilizamos o algoritmo de Baum-Welch, um caso especial do algoritmo de maximização de expectativa (EM, do inglês *Expectation Maximization*). O algoritmo adota uma configuração inicial de parâmetros que serão iterativamente ajustados para maximizar localmente a verossimilhança dos dados [Seymore et al., 1999]. Portanto, não estamos lidando com um método que nos fornecerá o máximo global apresentado na Figura 1.

Uma vez que o processamento do método é iterativo, iniciamos um contador em $i = 1$ e configuramos um valor inicial para os parâmetros do modelo $\lambda^{(0)}$. É importante ressaltar que o algoritmo de Baum-Welch é bastante sensível a esta configuração inicial dos parâmetros. Note também que trataremos do desenvolvimento do algoritmo de maximização de expectativa considerando o conjunto de dados completo. Discriminamos abaixo, adotando a abordagem da função $Q(\lambda^{(i)}, \lambda^{(i-1)})$, as etapas de processamento que um algoritmo de maximização de expectativa (EM) realiza [Bilmes et al., 1998]:

- *Expectation*: baseado no valor inicial do parâmetro do modelo $\lambda^{(0)}$, são calculadas as probabilidades *a posteriori* das variáveis latentes $P(\mathbf{S}|\mathbf{O}, \lambda^{(i-1)})$ a fim de calcular a função $Q(\lambda^{(i)}, \lambda^{(i-1)})$:

$$Q(\lambda, \lambda^{(i-1)}) = \sum_{q_t \in \Upsilon} \log P(\mathbf{O}, q_t | \lambda^{(i)}) P(\mathbf{O}, q_t | \lambda^{(i-1)}) \quad (2)$$

onde Υ é o espaço de todas as sequências de estados de tamanho T .

- *Maximization*: é computada a maximização de expectativa da função Q calculada no passo anterior, o que permite a atualização dos valores do parâmetro $\lambda^{(i)}$:

$$\lambda^{(i)} = \arg \max_{\lambda \in \Theta} Q(\lambda^{(i)}, \lambda^{(i-1)}). \quad (3)$$

Os passos *Expectation* e *Maximization* do algoritmo são repetidos alternadamente até que um critério de parada seja atendido, por exemplo: $\|\lambda^{(i)} - \lambda^{(i-1)}\| < \epsilon$, onde ϵ é um limiar do processamento.

Métricas de Desempenho. O *F-score* calcula a média harmônica entre a precisão e a sensibilidade. Enquanto a precisão acusa se o modelo é capaz de identificar corretamente as anomalias no conjunto de dados, a sensibilidade avalia a relação entre a identificação correta da anomalia e os casos que seriam anomalias mas foram ignorados. O *F-score* é dado por: $F\text{-score} = \frac{2 * \text{Precisão} * \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}}$, onde os cálculos de Precisão e Sensibilidade são descritos em [Sá et al., 2023].

4. Resultados

Nesta seção discutiremos os resultados do uso dos modelos ocultos de Markov para realizar a detecção e diagnóstico de anomalias. Foram utilizadas as linguagens de programação Java v.1.8, Python v.3.6.9 e MATLAB v.2017A, além do *Framework* de processamento dos modelos ocultos de Markov (hmmlearn v.0.2.4¹).

Conforme apresentado em [Sá et al., 2023], a base de dados compreende informações de monitoramento de dados de cinco turbinas eólicas disponibilizados pela EDP [EDP, 2021], fornecendo uma série temporal multivariada, com a dimensão $T \times D$ igual a 521.838×79 , sendo T o número de amostras e D o número de características.

Iniciamos a discussão pela seleção de características, que compreendeu uma etapa anterior e independente do processamento dos demais resultados. Nessa etapa todas as 79 características da base de dados foram avaliadas iterativamente. A partir de um processo aleatório as amostras de treinamento e teste foram construídas, garantindo que subsequências contidas na amostra de treinamento não estivessem contidas na amostra de teste. O valor do logaritmo da máxima verossimilhança é armazenado e a partir desse cálculo as características que apresentam o maior valor para cada componente de estado de pré-falha são selecionadas, formando o subconjunto de características selecionadas. A Tabela 1 apresenta as características selecionadas após este processo.

Tabela 1. Características selecionadas da base de dados da EDP [EDP, 2021].

Componente	Característica
Caixa de Velocidade	Temperatura média do ambiente [°C]
Gerador	Menor valor médio de rotação do gerador [rpm] no período

Cada amostra τ_i do problema foi formada por uma combinação de subsequências que abrangem um conjunto de registros coletado pelo SCADA (Sistemas de Supervisão e Aquisição de Dados)². Seja S_1 a subsequência formada por registros da operação normal, S_2 a subsequência formada por registros anteriores à falha da caixa de velocidade e S_3 a subsequência formada por registros anteriores à falha do gerador. Uma janela $k = 2000$ amostras foi adotada para a construção dessas subsequências, conforme exemplificado na Figura 2. Baseado no histórico de eventos de falhas em componentes descritos em [Sá et al., 2023], obtivemos diferentes subsequências formadas por registros ante-

¹Disponível em: <https://github.com/hmmlearn/hmmlearn>. Acessado em: 08/11/2023

²<https://scada-international.com/>

riores à falha, o que permitiu a construção de diferentes amostras τ_i a partir de diferentes combinações dessas subsequências.

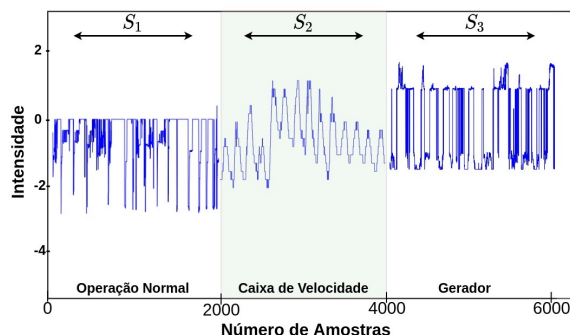


Figura 2. Cada processo nesta representação contém destacada a característica que determina o estado de pré-falha do componente. Por exemplo, o processo de falha do gerador exhibe somente a característica que marca o seu estado de deterioração.

Após a geração das amostras τ_i , estas foram divididas aleatoriamente numa proporção de 70% e 30%, respectivamente, entre os conjuntos de treinamento e teste. Esta divisão resultou em um conjunto de teste contendo três amostras τ_i , que são processadas pelo *hmmlearn*.

O processamento envolveu os problemas de aprendizado, avaliação e decodificação dos modelos ocultos de Markov, que foram processadas pelo *framework* *hmmlearn* a partir de um conjunto de parâmetros iniciais:

- Número de estados: o processamento envolve três estados, relacionados aos processos que serão classificados;
- Tipo de matriz de covariância: o *hmmlearn* estima que cada estado corresponde a uma distribuição gaussiana multivariada. Selecionamos a opção “*diag*”, pela qual cada estado utiliza somente a diagonal de uma matriz de covariância;
- Parâmetros atualizados: um conjunto de letras controla quais parâmetros serão atualizados ao longo do processamento. Definimos o conjunto “*cmt*”, onde as matrizes de covariância, os valores das médias de cada estado e a matriz de transição terão seus valores atualizados;
- Algoritmo de decodificação: definimos o uso do algoritmo de Viterbi [Lou, 1995].

As matrizes de transição foram inicializadas segundo o modelo esquerda-direita [Sá et al., 2023]. Segundo este modelo, o estado ou permanece no estado atual ou transita para um estado superior, sem poder transitar para um estado inferior ou saltar para um estado que não seja o imediatamente superior. No caso deste trabalho obedecendo a ordem de estados S_1, S_2, S_3 .

Procedemos para os resultados da classificação, considerando as amostras do conjunto de teste. A amostra τ_1 forneceu o *F-score* macro de 0,85. O método foi capaz de classificar sem erros as amostras do processo de pré-falha da caixa de velocidade (S_2). Alguma dificuldade foi encontrada nas amostras do gerador (S_3), pois possui erros de classificação maiores em comparação com os demais estados.

A amostra τ_2 forneceu *F-score* macro de 0,89, a qual também extraímos da matriz de confusão. Neste processamento, todas as amostras da operação normal (S_1) foram corretamente classificadas. A Tabela 2 apresenta um resumo dos resultados da métrica *F-score*. Os resultados obtidos são compatíveis com os obtidos pelos autores em [Kouadri et al., 2020], considerando que nossos resultados baseiam-se em dados reais, o que implica desafios não tratados pelos autores daquele trabalho.

Tabela 2. Resultado dos HMM para as demais amostras do conjunto de teste.

Amostra	F-score
τ_1	0,85
τ_2	0,89
τ_3	0,80

5. Considerações Finais

Em um cenário de marcante transição energética para a era pós-petróleo, a expansão do uso da energia eólica é um fato. Muito dessa realidade se deve ao nível de maturidade das tecnologias da energia eólica frente a outras fontes alternativas de energia. No cerne dessa revolução energética, as turbinas eólicas desempenham o protagonismo, uma vez que seu sistema é responsável pela transformação da energia mecânica do vento em energia elétrica. Contudo, as turbinas eólicas são sistemas complexos e caros que consistem de diferentes subsistemas interdependentes, cuja exposição a condições operacionais extremas, submetidas a toda sorte de eventos climáticos, exigem, além de resiliência estrutural, recursos que atestem a garantia de sua segurança operacional.

Este trabalho apresentou uma abordagem baseada em Modelos Ocultos de Markov para realizar a classificação multiclasse de componentes em processos de pré-falha e da operação normal do sistema de turbinas eólicas, associando-os aos estados ocultos do modelo. Portanto, a decodificação dos estados utilizando o algoritmo de Viterbi definiu a qual dessas classes cada amostra pertence. A abordagem desenvolvida mostrou resultados promissores indicando que novas avaliações precisam ser realizadas. O modelo desenvolvido focou nas componentes gerador e caixa de velocidade da turbina eólica. A próxima etapa deste estudo envolve avaliar a abordagem em dados oriundos dos componentes Grupo Hidráulico e Transformador. Além disso, abordagens híbridas de Modelos Ocultos de Markov com redes neurais deverão ser avaliadas.

Agradecimentos

Os autores agradecem a FAPERJ pelo financiamento deste projeto por meio do processo E-26/210.798/2024-APQ1.

Referências

- Baum, L. and Petrie, T. (1966). Statistical inference for probabilistic functions of finite state markov chains. *The Annals of Mathematical Statistics*, 37(6):1554–1563.
- Bilmes, J. et al. (1998). A gentle tutorial of the EM algorithm and its application to parameter estimation for gaussian mixture and hidden markov models. *International Computer Science Institute*, 4(510):126.

- Chen, P. et al. (2021). A threshold self-setting condition monitoring scheme for wind turbine generator bearings based on deep convolutional generative adversarial networks. *Measurement*, 167:108234.
- Council, G. W. E. (2021). Global wind report 2021. <https://gwec.net/wp-content/uploads/2021/03/GWEC-Global-Wind-Report-2021.pdf>, Acessado em 10/04/2024.
- EDP (2021). Edp - open data. <https://opendata.edp.com/pages/homepage/>, Acessado em 07/08/2021.
- Feng, Z. et al. (2023). Rolling bearing performance degradation assessment with adaptive sensitive feature selection and multi-strategy optimized svdd. *Sensors*, 23(3):1110.
- Ghojogh, B. et al. (2019). Hidden markov model: Tutorial. *enrXiv*.
- Jiang, Z. et al. (2021). Fault detection and diagnosis of wind turbine gearbox based on acoustic analysis. In *2021 International Conference on Power System Technology (POWERCON)*, pages 2047–2052. IEEE.
- Khan, P. and Byun, Y. (2024). A review of machine learning techniques for wind turbine's fault detection, diagnosis, and prognosis. *International Journal of Green Energy*, 21.
- Kidam, K. and Hurme, M. (2013). Analysis of equipment failures as contributors to chemical process accidents. *Process Safety and Environmental Protection*.
- Kobbacy, K. and Murthy, D. (2008). *Complex system maintenance handbook*. Springer Science & Business Media.
- Kouadri, A. et al. (2020). Hidden markov model-based principal component analysis for intelligent fault diagnosis of wind energy converter systems. *Renewable Energy*, 150.
- Li, J. et al. (2019). Reliability assessment of wind turbine bearing based on the degradation-hidden-markov model. *Renewable Energy*, 132:1076–1087.
- Li, X. et al. (2024). Correlation warping radius tracking for condition monitoring of rolling bearings under varying operating conditions. *Mechanical Systems and Signal Processing*, 208:110943.
- Lou, H.-L. (1995). Implementing the viterbi algorithm. *IEEE Signal processing magazine*, 12(5):42–52.
- Rabiner, L. and Juang, B. (1986). An introduction to hidden markov models. *IEEE ASSP Magazine*, 3(1):4–16.
- Sá, F. d. et al. (2023). Wind turbine fault detection: a semi-supervised learning approach with two different dimensionality reduction techniques. *International Journal of Innovative Computing and Applications*, 14(1-2):67–77.
- Sahu, D., Dewangan, R. K., and Matharu, S. P. S. (2024). An investigation of fault detection techniques in rolling element bearing. *Journal of Vibration Engineering & Technologies*, 12(4):5585–5608.
- Seymore, K. et al. (1999). Learning hidden markov model structure for information extraction. In *AAAI - workshop on machine learning for information extraction*.
- Xu, J. et al. (2023). Physics-guided, data-refined fault root cause tracing framework for complex electromechanical system. *Reliability Engineering System Safety*, 236.