

Utilização de *Transfer Learning* no Monitoramento de Temperatura de Transformadores de Aero geradores

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.

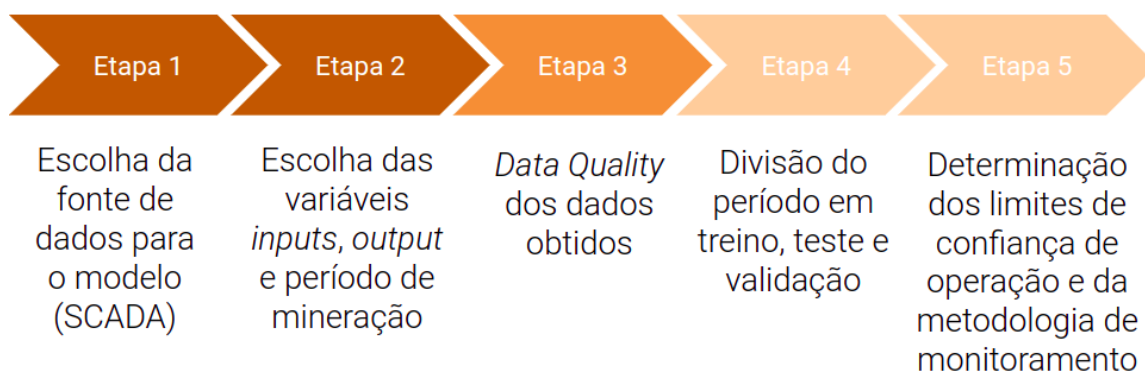


Figura 1 - Etapas do processo de treino do modelo preditivo

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.

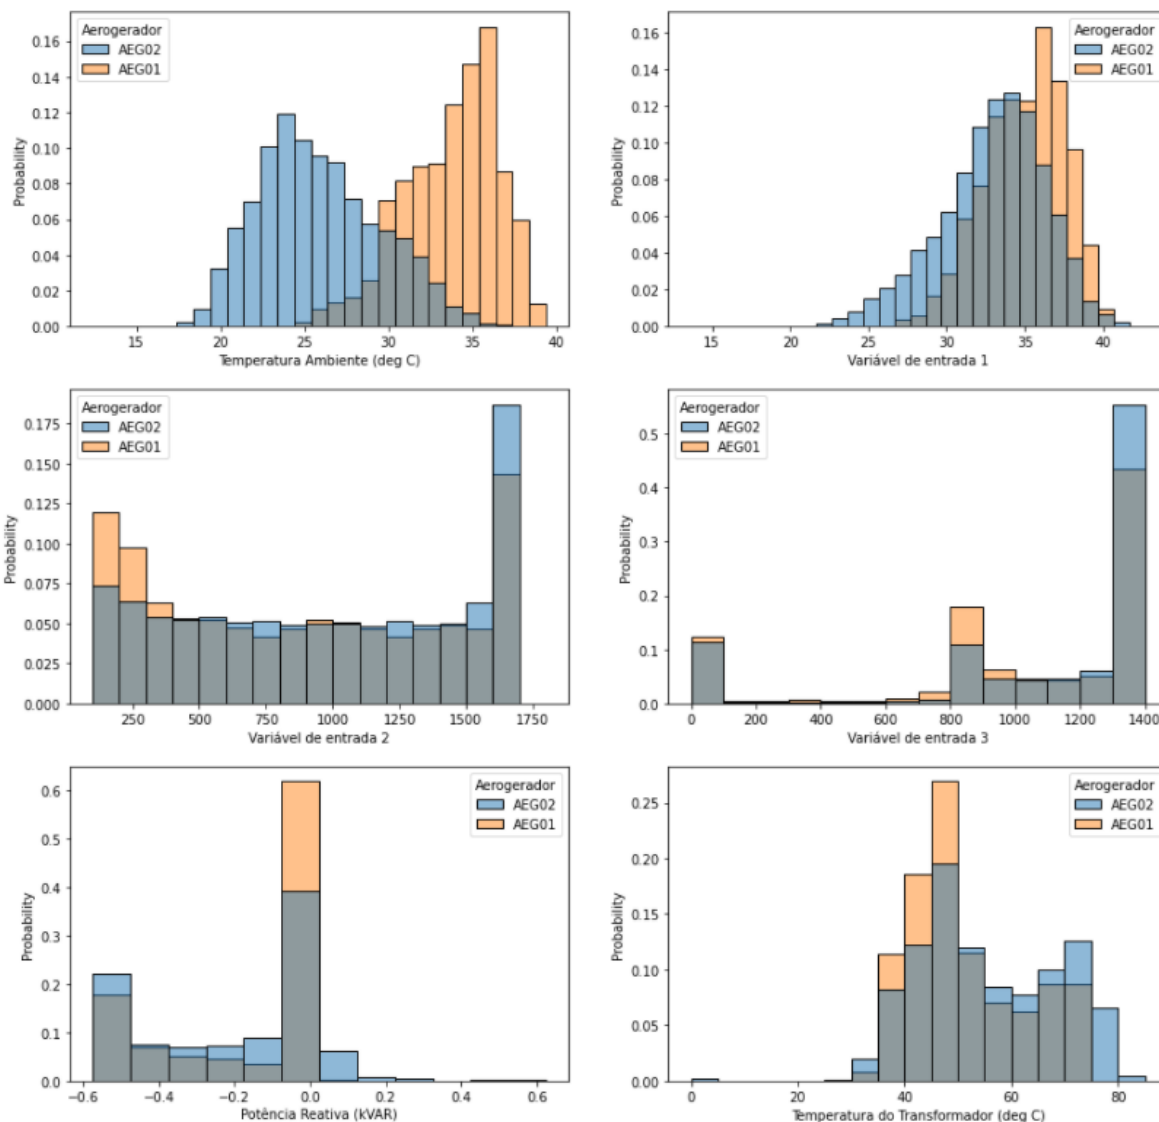


Figura 2 - Comparação entre as distribuições das variáveis de entrada para treinamento dos aerogeradores AEG01 e AEG02

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.

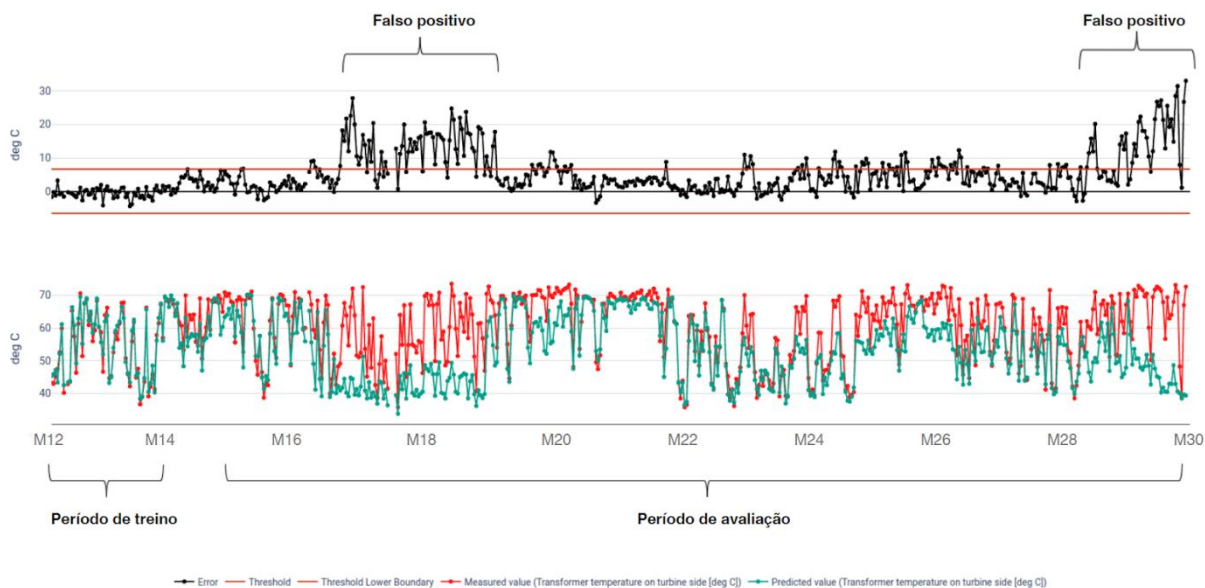


Figura 4 - Linha do tempo de avaliação do modelo de referência (sem *transfer learning*) da AEG01

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.

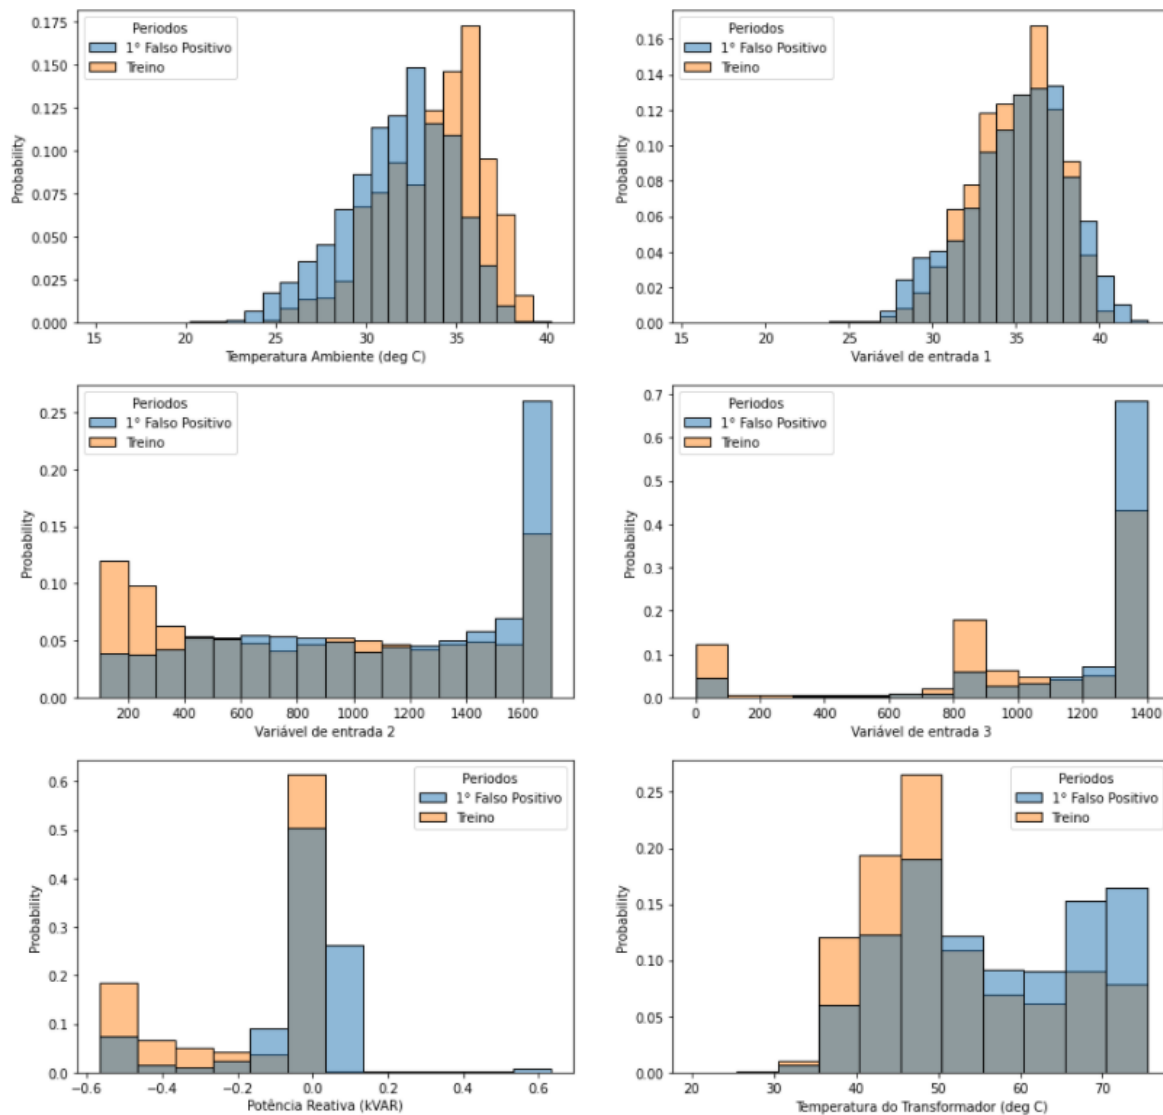


Figura 5 - Comparação entre as distribuições das variáveis de entrada das redes neurais nos períodos do treinamento e no período de alarme falso-positivo entre os meses M16 e M19 (1º período de falso-positivo)

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.

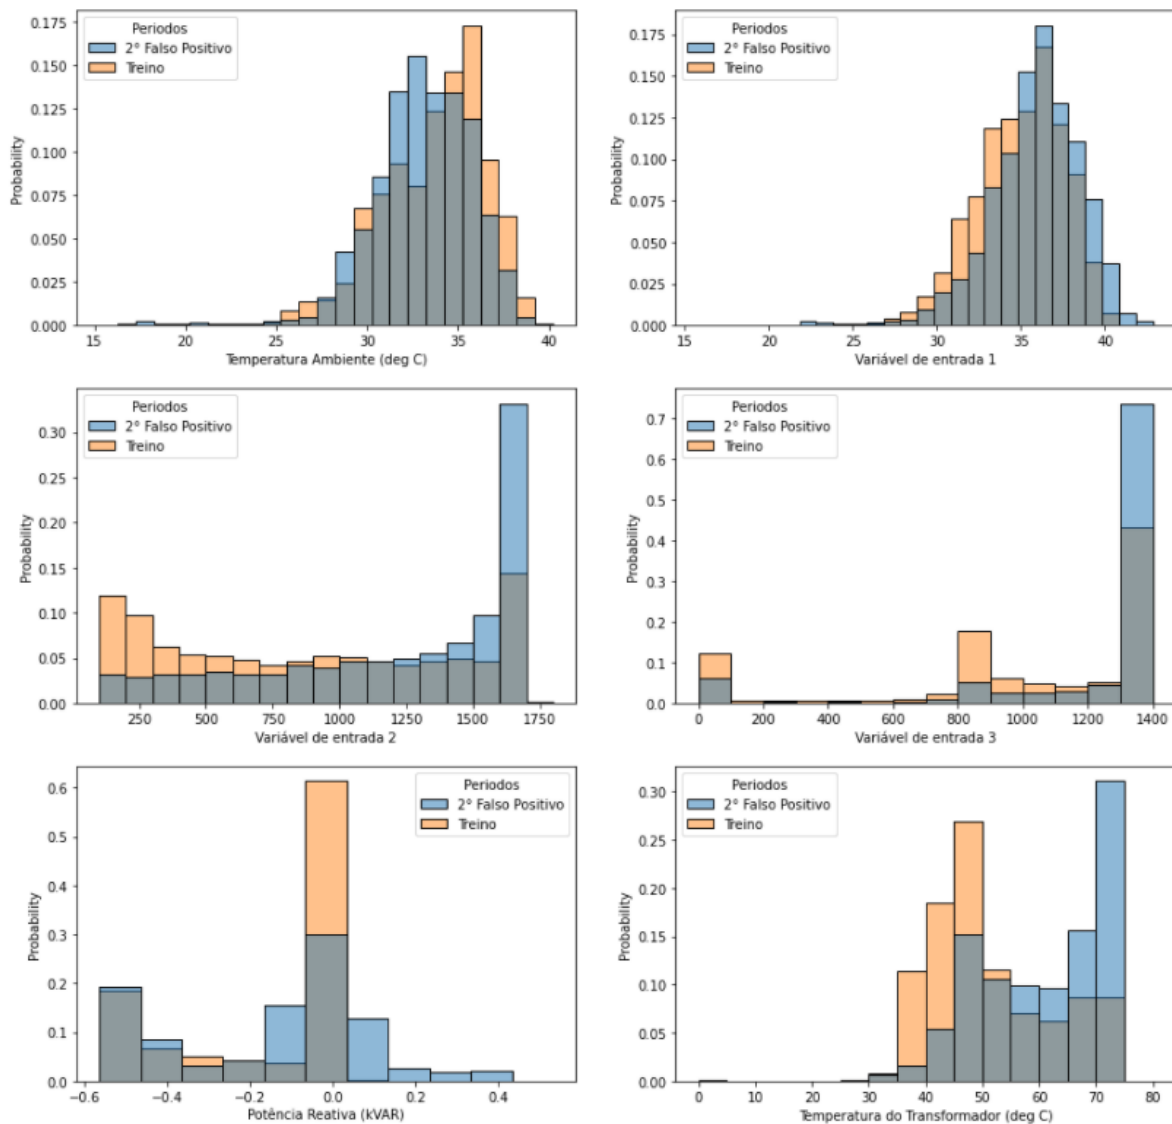


Figura 6 - Comparação entre as distribuições das variáveis de entrada das redes neurais nos períodos do treinamento e no período de alarme falso-positivo entre os meses M28 e M30 (2º período de falso-positivo)

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.