



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

OTHON VINÍCIUS CAVALCANTI DE SOUZA

**PROGNÓSTICO DA VIDA ÚTIL REMANESCENTE DOS ROLAMENTOS DE
AEROGERADORES UTILIZANDO MODELOS DE APRENDIZAGEM
PROFUNDA**

Recife

2024

OTHON VINÍCIUS CAVALCANTI DE SOUZA

**PROGNÓSTICO DA VIDA ÚTIL REMANESCENTE DOS ROLAMENTOS DE
AEROGERADORES UTILIZANDO MODELOS DE APRENDIZAGEM
PROFUNDA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação

Área de Concentração: Inteligência Computacional

Orientador: Prof. Dr. Tsang Ing Ren

Coorientador: Prof. Dr. Alexandre Carlos Araújo da Costa

Recife

2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Souza, Othon Vinicius Cavalcanti de.

Prognóstico da vida útil remanescente dos rolamentos de aerogeradores utilizando modelos de aprendizagem profunda / Othon Vinicius Cavalcanti de Souza. - Recife, 2024.

70f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro de Informática, Programa de Pos-Graduação em Ciência da Computação, 2024.

Orientação: Tsang Ing Ren.

Coorientação: Alexandre Carlos Araújo da Costa.

1. Redes Neurais Convolucionais; 2. LSTM; 3. Energia Eólica; 4. Prognóstico; 5. Vida Útil Remanescente. I. Ren, Tsang Ing. II. Costa, Alexandre Carlos Araújo da. III. Título.

UFPE-Biblioteca Central

OTHON VINÍCIUS CAVALCANTI DE SOUZA

**PROGNÓSTICO DA VIDA ÚTIL REMANESCENTE DOS ROLAMENTOS DE
AEROGERADORES UTILIZANDO MODELOS DE APRENDIZAGEM
PROFUNDA**

Dissertação apresentada ao Programa de Pós Graduação em Ciência da Computação da Universidade Federal de Pernambuco, Centro de Informática, como requisito para a obtenção do título de Mestre em Ciência da Computação. Área de concentração: Inteligência Computacional.

Aprovado em: 30/07/2024.

BANCA EXAMINADORA

Prof. Dr. Tsang Ing Ren (Orientador)
Universidade Federal de Pernambuco - UFPE

Prof. Dr. George Darmiton da Cunha Cavalcanti (Examinador Interno)
Universidade Federal de Pernambuco - UFPE

Prof. Dr. Gustavo de Novaes Pires Leite (Examinador Externo)
Instituto Federal de Pernambuco - IFPE

AGRADECIMENTOS

Agradeço a toda a minha família, em especial meus pais, Robson e Alcidenia, que me criaram em um lar com muito amor e carinho, além de sempre apoiar minhas decisões e incentivar aos estudos; minha irmã, Rafaela, que sempre torceu por mim e é um grande apoio na minha vida; meu sobrinho, Bernardo, que me alegra a cada momento em que está ao meu lado, além de auxílio para obter os resultados contidos neste projeto; e Mariana, que esteve ao meu lado me dando suporte em muitos momentos durante a pesquisa.

Agradeço ao Centro de Capoeira São Salomão, que me apoiaram durante toda a minha vida e foram fundamentais na minha caminhada como pesquisador.

Agradeço aos meus amigos que tive o prazer de conviver e que caminhamos juntos em apoio mútuo.

Agradeço ao Centro de Energias Renováveis da UFPE (CER-UFPE) e ao Programa de Pós-Graduação de Ciência da Computação (PPGCC-UFPE). E aos professores Tsang Ing Ren e Alexandre Costa pela orientação.

Por fim, agradeço ao apoio financeiro fornecido pela CAPES pela bolsa de incentivo à pesquisa durante o programa de pós-graduação; e a RAESA/Multiner S.A. , pelo auxílio no âmbito do projeto de P&D ANEEL NEO.PROGFALHAS (CONVÊNIO Nº 67/2020 UFPE) e a CPFL, pelo auxílio no âmbito do projeto de P&D ANEEL CPFL.APE (SERVIÇOS Nº CW2314196 - 23076.055770/2023-96)

RESUMO

Nos últimos anos, a geração de energia eólica cresceu expressivamente, tanto no Brasil quanto no mundo. No entanto, um dos grandes desafios observados ao longo do tempo está no processo de manutenção e operação dos aerogeradores, onde os custos podem variar entre 20% e 35% durante toda a vida útil do equipamento. Nesse sentido, a utilização de metodologias para a manutenção preditiva das máquinas é de extrema importância para a realização de manutenções programadas em momentos oportunos, como em períodos de baixos ventos e climas amenos, além de permitir a utilização otimizada do aerogerador, maximizando seu aproveitamento e, conseqüentemente, minimizando seus custos. Neste contexto, o presente trabalho propõe uma metodologia para a combinação de modelos de aprendizagem profunda, como CNN, LSTM e CNN-LSTM, para o prognóstico da vida útil remanescente (RUL) dos rolamentos no planetário da caixa de engrenagens, permitindo a manutenção em períodos programáveis. As principais contribuições deste trabalho são: i) a aplicação de uma abordagem de rotulação de dados para prognóstico baseado no histórico de falhas dos aerogeradores; ii) a extração de características tanto no domínio do tempo quanto na decomposição em tempo-frequência; iii) a combinação de modelos de aprendizagem profunda para o prognóstico da RUL dos aerogeradores; e iv) a abordagem de máquinas similares para o treinamento dos modelos de forma supervisionada. Com essa metodologia, observou-se uma melhoria nos resultados de prognóstico da RUL do componente em estudo, acompanhando o valor real estimado pela metodologia aplicada. Além disso, a metodologia foi capaz de estimar a degradação com até 60 dias de antecedência da falha, o que permite gerar uma manutenção programada com essa mesma antecedência.

Palavras-chaves: Redes Neurais Convolucionais. LSTM. Energia Eólica. Prognóstico. Vida Útil Remanescente.

ABSTRACT

In recent years, wind energy generation has grown significantly, both in Brazil and worldwide. However, one of the major challenges observed over time lies in the maintenance and operation processes of wind turbines, where costs can vary between 20% and 35% over the entire lifespan of the equipment. In this sense, the use of methodologies for predictive maintenance of the machines is extremely important for conducting scheduled maintenance at opportune moments, such as during periods of low winds and mild weather. This also allows for the optimized use of the wind turbine, maximizing its utilization and consequently minimizing its costs. In this context, the present work proposes a methodology for combining deep learning models, such as CNN, LSTM, and CNN-LSTM, for the prognosis of remaining useful life (RUL) of the bearings in the planetary gear system, allowing for maintenance at scheduled intervals. The main contributions of this work are: i) the application of a data labeling approach for prognosis based on the historical failure data of the wind turbines; ii) the extraction of features in both the time domain and the time-frequency decomposition; iii) the combination of deep learning models for the prognosis of the RUL of the wind turbines; and iv) the use of similar machines for supervised model training. With this methodology, an improvement in the prognosis results of the RUL for the component under study was observed, aligning with the actual value estimated by the applied methodology. Additionally, the methodology was able to estimate degradation up to 60 days in advance of the failure, which allows for scheduled maintenance to be generated with the same lead time.

Keywords: Convolutional Neural Networks, LSTM. Wind Energy. Prognosis. Remain Useful Life.

LISTA DE FIGURAS

Figura 1 – Degradação do sinal em relação ao tipo de manutenção.	13
Figura 2 – Disposição dos sensores do CMS no aerogerador.	15
Figura 3 – Disposição dos sensores do CMS no aerogerador.	17
Figura 4 – Exemplo da metodologia baseada em dados do tempo de vida.	18
Figura 5 – Exemplo da metodologia baseada em dados do tempo de vida.	19
Figura 6 – Exemplo da metodologia baseada em dados do tempo de vida.	20
Figura 7 – Sinal característico da degradação de rolamentos e as STFTs em diversos períodos de operação.	21
Figura 8 – Exemplo de neurônio artificial.	22
Figura 9 – Arquitetura da Perceptron Multicamadas (MLP).	23
Figura 10 – Arquitetura da célula LSTM.	24
Figura 11 – Exemplo da rede convolucional aplicada.	25
Figura 12 – Fluxograma da metodologia proposta	31
Figura 13 – Arquitetura da LSTM proposta	35
Figura 14 – Arquitetura da CNN proposta	36
Figura 15 – Arquitetura da CNN-LSTM proposta	37
Figura 16 – Arquitetura da MLP proposta	38
Figura 17 – Vibração ao longo do tempo de cada aerogerador em estudo	42
Figura 18 – RUL de saída para o Aerogerador 2 considerando o Aerogerador 1	45
Figura 19 – RUL de saída para o Aerogerador 3 considerando o Aerogerador 1	45
Figura 20 – RUL de saída para o Aerogerador 4 considerando o Aerogerador 1	46
Figura 21 – RUL de saída para o Aerogerador 1 considerando o Aerogerador 2	47
Figura 22 – RUL de saída para o Aerogerador 3 considerando o Aerogerador 2	48
Figura 23 – RUL de saída para o Aerogerador 4 considerando o Aerogerador 2	48
Figura 24 – RUL de saída para o Aerogerador 1 considerando o Aerogerador 3	50
Figura 25 – RUL de saída para o Aerogerador 2 considerando o Aerogerador 3	50
Figura 26 – RUL de saída para o Aerogerador 4 considerando o Aerogerador 3	51
Figura 27 – RUL de saída para o Aerogerador 1 considerando o Aerogerador 4	52
Figura 28 – RUL de saída para o Aerogerador 2 considerando o Aerogerador 4	52
Figura 29 – RUL de saída para o Aerogerador 3 considerando o Aerogerador 4	53

Figura 30 – <i>Ensemble</i> para o Aerogerador 2 considerando o Aerogerador 1	54
Figura 31 – <i>Ensemble</i> para o Aerogerador 3 considerando o Aerogerador 1	55
Figura 32 – <i>Ensemble</i> para o Aerogerador 4 considerando o Aerogerador 1	55
Figura 33 – <i>Ensemble</i> para o Aerogerador 1 considerando o Aerogerador 2	56
Figura 34 – <i>Ensemble</i> para o Aerogerador 3 considerando o Aerogerador 2	57
Figura 35 – <i>Ensemble</i> para o Aerogerador 4 considerando o Aerogerador 2	57
Figura 36 – <i>Ensemble</i> para o Aerogerador 1 considerando o Aerogerador 3	58
Figura 37 – <i>Ensemble</i> para o Aerogerador 2 considerando o Aerogerador 3	59
Figura 38 – <i>Ensemble</i> para o Aerogerador 4 considerando o Aerogerador 3	59
Figura 39 – <i>Ensemble</i> para o Aerogerador 1 considerando o Aerogerador 4	60
Figura 40 – <i>Ensemble</i> para o Aerogerador 2 considerando o Aerogerador 4	61
Figura 41 – <i>Ensemble</i> para o Aerogerador 3 considerando o Aerogerador 4	61

LISTA DE TABELAS

Tabela 1 – Histórico de manutenções dos aerogeradores em estudo.	43
Tabela 2 – Erro Quadrático Médio (MSE) da LSTM sobre a quantidade de dias a regressão da Vida Útil Remanescente (RUL).	43
Tabela 3 – MSE da CNN sobre a quantidade de dias a regressão da RUL.	43
Tabela 4 – MSE da CNN-LSTM sobre a quantidade de dias a regressão da RUL. . . .	43
Tabela 5 – Resultados do RMSE para os modelo treinados com o Aerogerador 1. . . .	44
Tabela 6 – Resultados do MAE para os modelo treinados com o Aerogerador 1. . . .	44
Tabela 7 – Resultados do RMSE para os modelo treinados com o Aerogerador 2. . . .	47
Tabela 8 – Resultados do MAE para os modelo treinados com o Aerogerador 2. . . .	47
Tabela 9 – Resultados do RMSE para os modelo treinados com o Aerogerador 3. . . .	49
Tabela 10 – Resultados do MAE para os modelo treinados com o Aerogerador 3. . . .	49
Tabela 11 – Resultados do RMSE para os modelo treinados com o Aerogerador 4. . . .	49
Tabela 12 – Resultados do MAE para os modelo treinados com o Aerogerador 4. . . .	51
Tabela 13 – Métricas do modelo <i>ensemble</i> treinados com o Aerogerador 1.	62
Tabela 14 – Métricas do modelo <i>ensemble</i> treinados com o Aerogerador 2.	63
Tabela 15 – Métricas do modelo <i>ensemble</i> treinados com o Aerogerador 3.	64

LISTA DE ABREVIATURAS E SIGLAS

CMS	Sistema de Monitoramento de Condição
CNN	Rede Neural Convolucional
FPT	<i>First Prediction Time</i>
LSTM	<i>Long Short-Term Memory</i>
MAE	Erro Médio Absoluto
MLP	Perceptron Multicamadas
MSE	Erro Quadrático Médio
O&M	Operação e Manutenção
RMS	Raiz do Valor Quadrático
RMSE	Raiz do Erro Quadrático Médio
RUL	Vida Útil Remanescente
SCADA	<i>Supervisory Control and Data Acquisition</i>
SIN	Sistema Interligado Nacional
STFT	Transformada de Fourier de Curto Termo

SUMÁRIO

1	INTRODUÇÃO	12
2	CONCEITOS PRELIMINARES	15
2.1	AEROGERADOR	15
2.2	SISTEMA DE MONITORAMENTO DE CONDIÇÕES	16
2.3	VIDA ÚTIL REMANESCENTE	17
2.4	TRANSFORMADA DE FOURIER DE CURTO TERMO	20
2.5	PERCEPTRON MULTICAMADAS	21
2.6	<i>LONG SHORT-TERM MEMORY</i>	23
2.7	<i>CONVOLUTIONAL NEURAL NETWORKS</i>	25
3	REVISÃO DA LITERATURA	27
4	METODOLOGIA	31
4.1	EXTRAÇÃO DE CARACTERÍSTICAS	31
4.1.1	Cálculo das Estatísticas Temporais	32
4.1.2	Decomposição em Tempo-Frequência	33
4.2	ROTULAÇÃO DE DADOS	34
4.3	MODELOS E COMBINAÇÃO	35
4.3.1	LSTM	35
4.3.2	CNN	36
4.3.3	CNN-LSTM	36
4.3.4	Suavização e Combinação	37
4.4	AVALIAÇÃO	38
5	RESULTADOS	41
5.1	CONJUNTO DE DADOS	41
5.2	ESTIMATIVA DA RUL	43
5.3	ESTUDO DE CASO 1: TROCA DA <i>GEARBOX</i>	44
5.4	ESTUDO DE CASO 2: MANUTENÇÃO DA <i>GEARBOX</i>	46
5.5	COMBINAÇÃO	53
6	CONCLUSÕES E PERSPECTIVAS	65
	REFERÊNCIAS	67

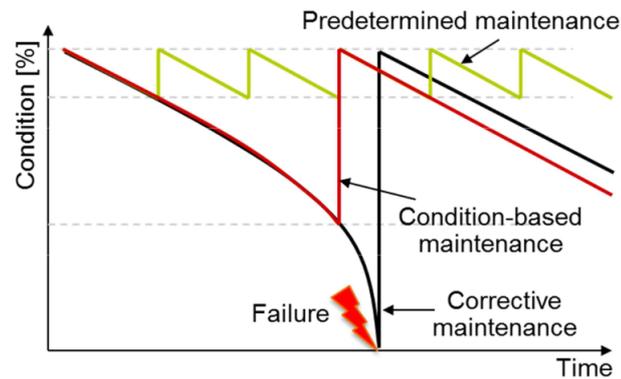
1 INTRODUÇÃO

Nos últimos anos, o interesse pela geração de energia elétrica a partir de fontes renováveis cresceu expressivamente em todo o mundo, devido, entre outros fatores, à preocupação com a emissão de gases poluentes que agravam o efeito estufa. A energia eólica é uma das fontes renováveis que mais cresce globalmente, alcançando, em 2023, uma participação de 10% na geração elétrica mundial (WWEA, 2024). No Brasil, essa fonte gerou 95,8 TWh de energia no mesmo período, representando um crescimento de 17,4% em relação ao ano anterior (EPE, 2024). Diante desse cenário de crescente participação da energia eólica na matriz elétrica nacional, é de suma importância o desenvolvimento de soluções que reduzam o tempo de indisponibilidade dos aerogeradores. Tais soluções devem ser baseadas em uma programação inteligente da manutenção, orientada por decisões fundamentadas em prognósticos sobre a vida útil remanescente dos componentes dos aerogeradores. Estratégias de manutenção baseadas nesses prognósticos são fundamentais tanto para a redução da insegurança no Sistema Interligado Nacional (SIN) quanto para a redução dos custos das empresas.

Um dos grandes desafios na Operação e Manutenção (O&M) de aerogeradores está nas falhas que podem ocorrer durante sua vida útil. Alguns estudos mostram que os custos de O&M representam entre 20% e 35% (MANNA, 2023) do total ao longo da vida útil do aerogerador. Para minimizar o impacto causado por falhas nos componentes dos aerogeradores, são realizadas atividades de manutenção. No geral, as estratégias utilizadas são as seguintes (CORONADO; FISCHER, 2015; LEITE; ARAUJO; ROSAS, 2018): i) Manutenção corretiva, que ocorre após a falha completa do componente. Esse tipo de manutenção pode gerar danos catastróficos, pois a falha pode desencadear outros prejuízos à máquina. ii) Manutenção preventiva programada, realizada periodicamente para prolongar a vida útil dos componentes. No entanto, esse processo gera custos desnecessários, já que, em muitos casos, a máquina poderia continuar operando sem danos iminentes. iii) Manutenção preditiva, na qual se monitora continuamente as condições de operação da máquina. Ao identificar uma degradação acentuada (superando um limiar predefinido), a manutenção é realizada. Esse método otimiza a vida útil dos componentes e permite o agendamento da manutenção em períodos que minimizem perdas financeiras. A Figura 1 ilustra a degradação ao longo do tempo para cada um desses tipos de manutenção.

É importante destacar que as falhas em componentes mecânicos são, frequentemente, precedidas por certos sinais, condições ou indicativos de que uma falha está prestes a ocorrer

Figura 1 – Degradação do sinal em relação ao tipo de manutenção.



Fonte: Coronado e Fischer (2015).

(AHMAD; KAMARUDDIN, 2012). Nesse contexto, o monitoramento contínuo do aerogerador é fundamental para a realização de prognósticos adequados. A instalação do Sistema de Monitoramento de Condição (CMS) – nos componentes da máquina auxilia na obtenção de dados observacionais relevantes para a compreensão do comportamento da máquina e a modelagem dos processos de interesse. No caso dos aerogeradores, o monitoramento das vibrações dos rolamentos desempenha um papel essencial, considerando a complexa dinâmica dos componentes móveis da máquina (SAWALHI; RANDALL, 2014; MOHAMMED; RANTATALO, 2020).

Neste sentido, o presente trabalho tem como objetivo realizar o prognóstico dos componentes dos aerogeradores, estimando a RUL para auxiliar na manutenção preventiva condicionada, visando minimizar os custos operacionais. Especificamente, o prognóstico será realizado sobre o rolamento do planetário da caixa de engrenagens, componente que é objeto de estudo em diversos desafios de falhas na gearbox. Este trabalho se destaca por: i) apresentar uma nova abordagem de rotulação de dados, possibilitando a estimativa da RUL para o treinamento de modelos de redes neurais profundas; ii) realizar a extração de características dos dados de vibração do CMS, tanto no domínio do tempo (estatísticas temporais) quanto a partir da decomposição em tempo-frequência; iii) combinar modelos de deep learning para agregar informações extraídas dos dados de vibração; e iv) realizar o prognóstico dos rolamentos dos aerogeradores a partir do histórico de falhas, possibilitando o aprendizado supervisionado dos modelos propostos.

Por fim, este documento está organizado da seguinte forma: no Capítulo 2 são abordados os conceitos preliminares para a compreensão do trabalho. No Capítulo 3, é apresentada a revisão bibliográfica, mostrando o estado da arte sobre o prognóstico de aerogeradores. O Capítulo 4 descreve a metodologia proposta. No Capítulo 5, são discutidos os resultados e as

considerações sobre a metodologia. Por fim, o Capítulo 6 traz as conclusões e as perspectivas futuras do trabalho.

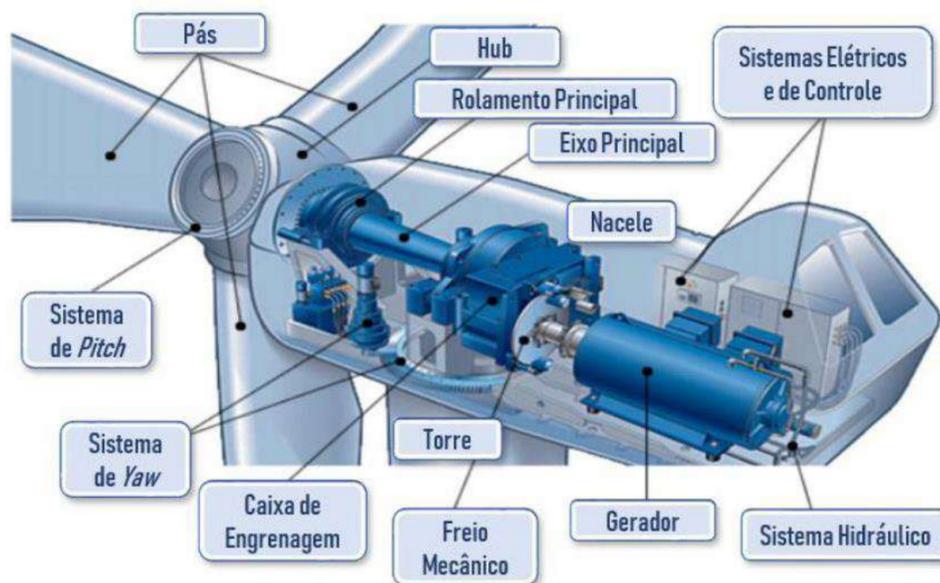
2 CONCEITOS PRELIMINARES

Para facilitar a compreensão do trabalho proposto nesta dissertação, este capítulo aborda conceitos preliminares relevantes para o entendimento da proposta apresentada.

2.1 AEROGERADOR

O aerogerador é uma máquina composta por vários componentes mecânicos e elétricos, cujo objetivo é converter a energia cinética dos ventos em energia elétrica. A arquitetura mais conhecida dessa máquina consiste em três pás acopladas a um eixo horizontal. Em alguns designs, esse eixo está conectado a caixa de engrenagens (*gearbox*), que tem como função transformar a rotação do eixo principal em uma rotação mais alta. Algumas máquinas não possuem esse componente, e o acoplamento é feito diretamente ao gerador elétrico. A Figura 2 mostra o aerogerador e seus respectivos componentes.

Figura 2 – Disposição dos sensores do CMS no aerogerador.



Fonte: Bezerra (2019).

No rotor aerodinâmico encontram-se as pás e o cubo, projetados aerodinamicamente para maximizar a eficiência na captação da energia cinética dos ventos e transmitir a rotação ao eixo principal. O conjunto formado pelo rotor aerodinâmico e o eixo principal é denominado turbina eólica. Esse conjunto está conectado à nacela, cuja função é abrigar os componentes responsáveis por transformar a energia mecânica em energia elétrica.

Dentro da nacela, encontram-se principalmente dois componentes: a caixa de engrenagens e o gerador elétrico. O gerador elétrico transforma a rotação de seu eixo, proveniente da turbina eólica, em energia elétrica. Essa energia é então transmitida para o sistema. A caixa de engrenagens, como mencionado anteriormente, é composta por componentes mecânicos, principalmente rolamentos e engrenagens, cujo objetivo é modificar a velocidade de rotação da turbina eólica (baixa rotação) para velocidades mais altas, a fim de serem acopladas ao gerador. As caixas de engrenagens, em geral, possuem três partes acopladas: o eixo principal (*main shaft*), o eixo de velocidade intermediária (*intermediate speed shaft*) e o eixo de alta velocidade (*high speed shaft*). Algumas arquiteturas modernas não possuem caixa de engrenagens; nesse caso, a turbina eólica é conectada diretamente ao gerador (*direct drive*), que possui um conversor eletrônico de potência para a conexão com a rede elétrica.

Em suma, nota-se a complexidade da disposição dos diferentes componentes do aerogerador. Além disso, as máquinas estão sujeitas a intempéries ambientais, como variações de temperatura, velocidade do vento, pressão, etc. Desse modo, a ocorrência de falhas pode ser observada em diversos estudos, tanto na detecção e diagnóstico de falhas quanto no prognóstico, com o objetivo de gerar uma manutenção preditiva dos componentes do aerogerador em períodos oportunos, como durante baixa geração de energia (MORONEY; VERMA, 2023; BADIHI et al., 2022).

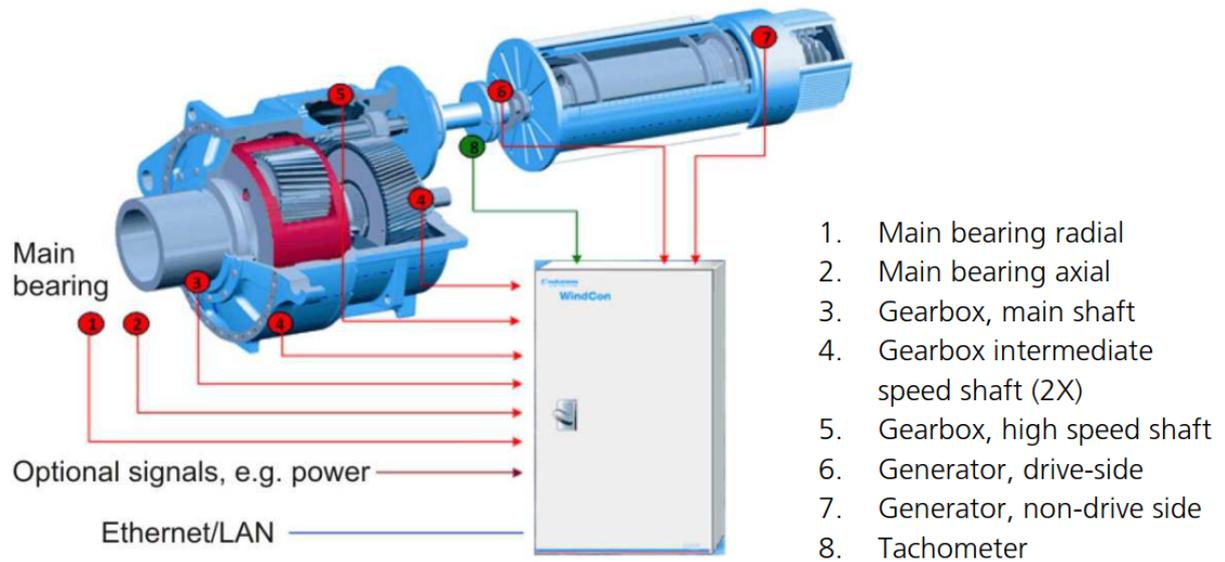
2.2 SISTEMA DE MONITORAMENTO DE CONDIÇÕES

Técnicas de monitoramento de condição têm como objetivo detectar mudanças nas condições de operação do aerogerador. A utilização de CMS para turbinas eólicas baseia-se em inspeções regulares, manutenções e análises dos componentes ao longo do tempo. No geral, o CMS se concentra predominantemente no monitoramento da vibração dos componentes. De forma específica, a análise é realizada no eixo principal, na caixa de engrenagens e no gerador. A Figura 3 representa a disposição dos sensores de vibração nos rolamentos do aerogerador.

Observa-se, a partir da imagem, que os sensores de vibração estão relacionados a cada parte do aerogerador. Os sensores do *main bearing* têm como principal função monitorar a vibração do rotor principal do aerogerador. Essas medições são feitas no sentido radial e/ou axial do eixo.

Já na caixa de engrenagens, as medições são realizadas em seus rolamentos, com o objetivo de avaliar a degradação ao longo do tempo. Nota-se que os sensores estão dispostos em três

Figura 3 – Disposição dos sensores do CMS no aerogerador.



Fonte: Coronado e Fischer (2015).

partes: o *main shaft*, no qual a caixa de engrenagens está acoplada ao eixo principal, etapa em que a velocidade de rotação é baixa; o *intermediate speed shaft*, onde a rotação é intermediária; e, por fim, o *high speed shaft*, conectado ao gerador.

No gerador, os sensores estão posicionados em duas partes: o rolamento do lado de acionamento (*drive end*), que interliga a caixa de engrenagens ao gerador, e o rolamento do lado oposto ao acionamento (*non-drive end*), que não está conectado à caixa de engrenagens. Todo esse sistema possui métodos independentes de aquisição de dados, com o objetivo de avaliar a condição de operação de cada componente.

Todas essas informações são armazenadas e transferidas para um sistema que realiza o monitoramento adequado da operação da máquina. Qualquer anomalia identificada durante o processo deve ser devidamente analisada e, conseqüentemente, deve-se programar a manutenção apropriada. Em suma, todo esse sistema busca monitorar o comportamento do aerogerador e, a partir dessas análises, realizar manutenções preditivas para prevenir falhas que possam ocorrer na máquina.

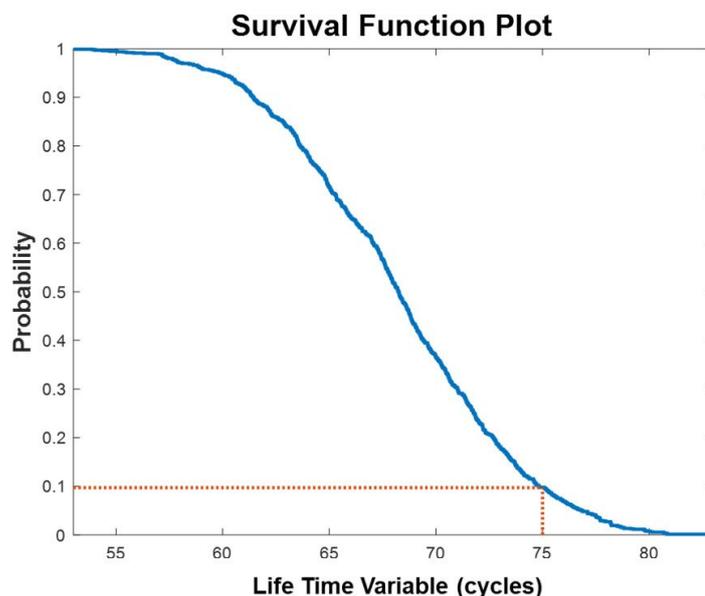
2.3 VIDA ÚTIL REMANESCENTE

A Vida Útil Remanescente (RUL) é o tempo estimado entre o estado atual do sistema e a falha do componente, ou seja, o período em que o componente pode continuar em operação até

o final de sua vida útil. Esse indicativo pode ser expresso em dias, ciclos, voos ou outras métricas que representem a quantidade de vezes que a máquina pode operar sem causar prejuízos. O prognóstico envolve a estimativa da RUL, permitindo ao operador do SIN tomar decisões informadas sobre o planejamento da manutenção, viabilizando a manutenção preditiva. Dessa forma, uma previsão acurada da RUL otimiza a eficiência operacional, maximizando a utilização do componente, evitando paradas não planejadas que geram custos financeiros e possibilitando o agendamento de manutenções em momentos oportunos, como em períodos de ventos fracos e condições climáticas favoráveis. Desse modo, três principais métodos podem ser empregados na estimativa da RUL: i) análise de sobrevivência; ii) limiar de degradação; e iii) similaridade de máquinas (BARU; JOHNSON, 2023; MATHWORKS, 2018).

A metodologia que utiliza a análise de sobrevivência é aplicada em situações onde não se dispõe do histórico completo de operação da máquina, mas apenas de informações do estado atual. Nesse contexto, com base em dados de outras máquinas semelhantes cuja falha já foi registrada, é possível criar uma distribuição de probabilidade de falha do componente, permitindo estimar seu tempo de vida. A Figura 4 exemplifica essa abordagem na estimativa da RUL de uma bateria.

Figura 4 – Exemplo da metodologia baseada em dados do tempo de vida.

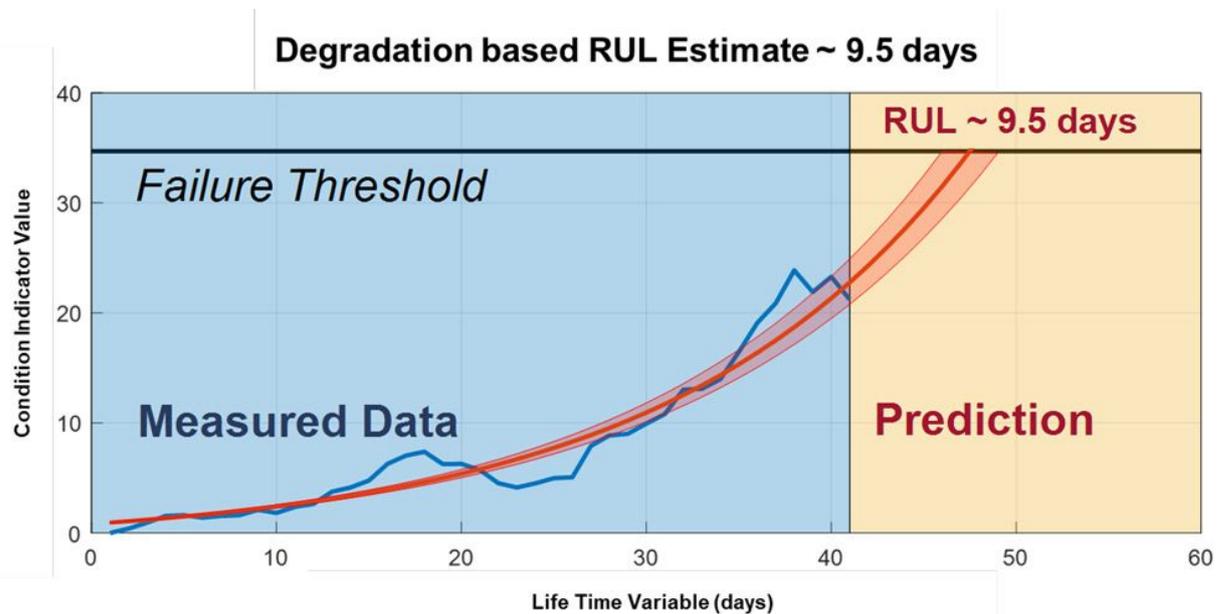


Fonte: Baru e Johnson (2023)

Por outro lado, a metodologia baseada no limiar de degradação é utilizada quando não há informações disponíveis de máquinas semelhantes. Nesse caso, realiza-se o monitoramento de uma característica que indica a degradação do equipamento e, com base na definição de um

limiar crítico, estima-se a RUL do componente. A Figura 5 mostra o monitoramento de uma *feature* e a estimativa da RUL a partir de um limiar crítico.

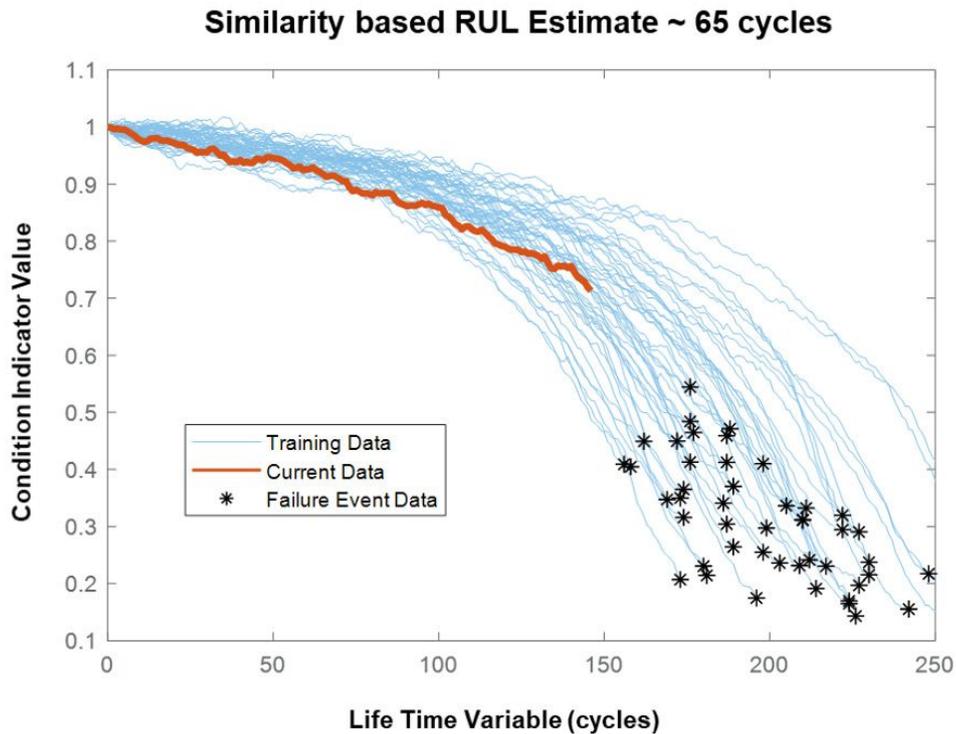
Figura 5 – Exemplo da metodologia baseada em dados do tempo de vida.



Fonte: Baru e Johnson (2023)

Por fim, a metodologia de similaridade de máquinas é utilizada quando se dispõe do histórico de vida do componente. Através dessa abordagem, é possível comparar o histórico do componente com o de outras máquinas idênticas, permitindo a aplicação de técnicas de aprendizado para estimar a RUL do componente. A Figura 6 ilustra como a RUL de componentes é estimada com base na comparação entre diferentes máquinas semelhantes.

Figura 6 – Exemplo da metodologia baseada em dados do tempo de vida.



2.4 TRANSFORMADA DE FOURIER DE CURTO TERMO

A Transformada de Fourier de Curto Termo (STFT) é uma ferramenta fundamental na análise de sinais não-estacionários (SEJDIĆ; DJUROVIĆ; JIANG, 2009; LI; ZHANG; DING, 2019). Enquanto a Transformada de Fourier clássica assume que o sinal é estacionário e aplica uma análise global, a STFT permite observar como as frequências de um sinal mudam ao longo do tempo, dividindo o sinal em segmentos menores e aplicando a Transformada de Fourier a cada um deles.

A ideia central da STFT é utilizar uma janela de tempo que se move ao longo do sinal. Essa janela pode ser retangular, hamming, hanning, entre outras. Ao aplicar a Transformada de Fourier em cada segmento do sinal, obtemos uma representação no domínio do tempo e da frequência. Essa representação é frequentemente visualizada como um espectrograma, onde o eixo horizontal representa o tempo, o eixo vertical representa a frequência, e a intensidade da cor ou brilho indica a magnitude da frequência em cada ponto no tempo. A Equação 2.1 representa a transformação do sinal de entrada:

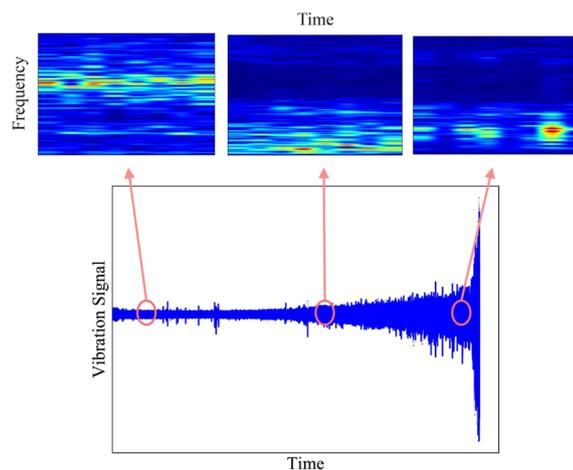
$$\text{STFT}(\tau, \omega) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (2.1)$$

no qual $x(t)$ é o sinal contínuo no tempo que deve ser transformado; $w(t)$ é a função janela que desliza sobre todo o sinal e ω é a frequência angular.

Embora a STFT ofereça uma análise detalhada de sinais não-estacionários, há um compromisso entre a resolução temporal e a de frequência dependendo do tamanho da janela utilizada. Janelas curtas favorecem a resolução no tempo, enquanto janelas longas melhoram a resolução em frequência, o que pode mascarar mudanças rápidas no sinal. Assim, a STFT é uma ferramenta versátil e poderosa em várias áreas do processamento de sinais.

A Figura 7

Figura 7 – Sinal característico da degradação de rolamentos e as STFTs em diversos períodos de operação.



Fonte: Li, Zhang e Ding (2019).

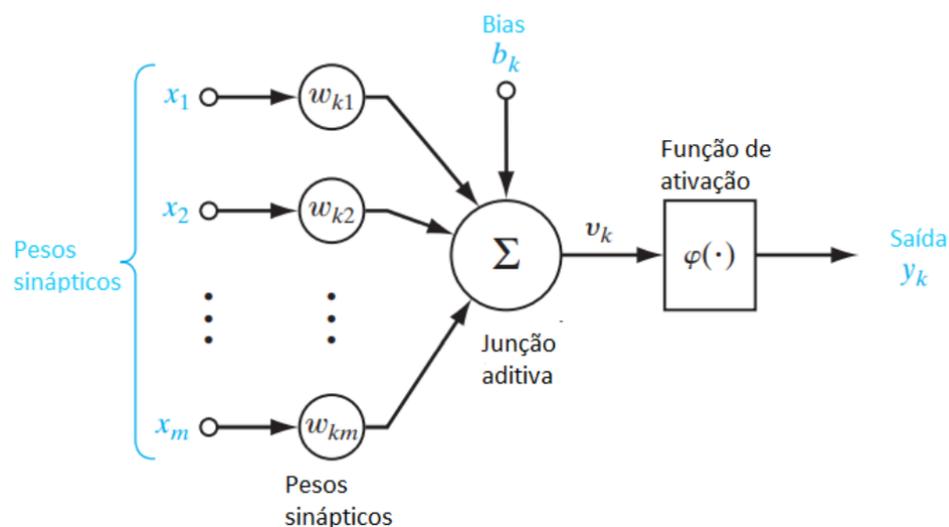
2.5 PERCEPTRON MULTICAMADAS

As MLPs são um dos tipos mais populares de redes neurais artificiais. Sua estrutura é composta por múltiplas camadas de neurônios, o que permite que essas redes sejam capazes de capturar e modelar relações complexas em conjuntos de dados, inclusive aqueles com padrões não lineares. As MLPs são amplamente utilizadas em tarefas de classificação, regressão e previsão, sendo a base para muitas aplicações de aprendizado de máquina (HAYKIN, 2009; ZHANG et al., 2023).

A estrutura básica da MLP é composta por três elementos principais: a camada de entrada, onde os dados brutos são recebidos, que correspondem às características ou variáveis independentes do problema em questão; as camadas ocultas, que processam as informações vindas da camada de entrada. As camadas ocultas são responsáveis pela maior parte do "aprendizado". A função de ativação aplicada aos neurônios, como a função sigmoide, ReLU (*Rectified Linear Unit*) ou tanh, introduz não linearidade, o que torna a rede capaz de aprender padrões complexos. A quantidade de camadas ocultas e o número de neurônios em cada camada são hiperparâmetros que devem ser ajustados de acordo com o problema; por fim, a camada de saída fornece a previsão final, que pode ser uma classe, no caso de classificação, ou um valor contínuo, no caso de regressão. O número de neurônios nessa camada varia conforme a tarefa. Cada camada é composta por neurônios interconectados, e a comunicação entre eles ocorre por meio de pesos e funções de ativação.

A Figura 8 representa o neurônio artificial. Os pesos sinápticos são representados por números reais que equivalem às sinapses biológicas, onde um sinal de entrada x_j , proveniente da sinapse j conectada ao neurônio k , é multiplicado pelo peso sináptico w_{kj} . O somador atua como um combinador linear, somando os sinais de entrada com seus respectivos pesos sinápticos. Por fim, a função de ativação limita a amplitude de saída do neurônio, que normalmente varia entre $(0, 1)$, $(-1, 1)$ ou $(0, \infty)$.

Figura 8 – Exemplo de neurônio artificial.

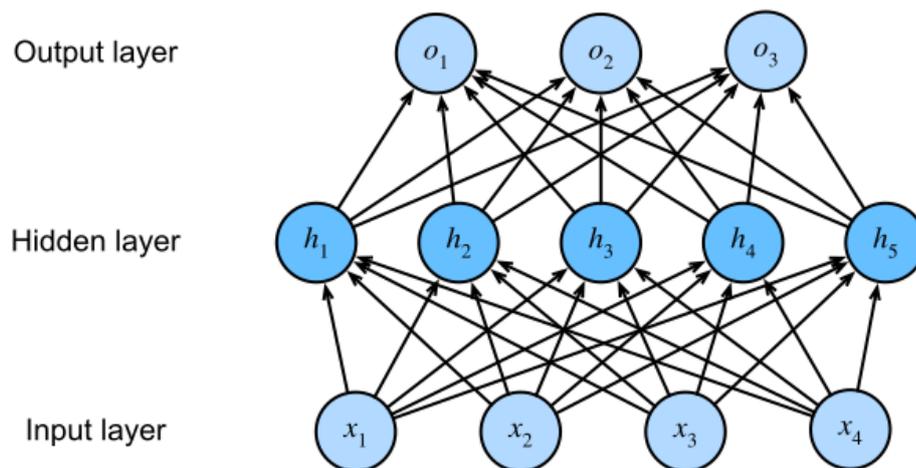


Fonte: Haykin (2009) adaptado.

O treinamento de uma rede MLP é realizado por meio do aprendizado supervisionado, onde a rede ajusta seus pesos com base em exemplos rotulados de dados de entrada e saída.

O algoritmo mais comum utilizado nesse processo é o Retropropagação, frequentemente combinado com um otimizador, como o Gradiente Descendente. O treinamento ocorre em três fases principais: Propagação Direta, onde os dados de entrada fluem pela rede até a camada de saída; Cálculo do Erro, que compara a previsão da rede com a saída real utilizando uma função de custo; e Retropropagação, que ajusta os pesos das conexões entre os neurônios para minimizar o erro. Esse ciclo é repetido ao longo de várias épocas até que o erro seja suficientemente reduzido, permitindo que a rede forneça previsões adequadas. A combinação dessas fases garante que a MLP aprenda a partir dos dados, capturando padrões complexos e melhorando seu desempenho em tarefas específicas, como classificação e regressão. A Figura 9 ilustra a arquitetura da MLP.

Figura 9 – Arquitetura da MLP.



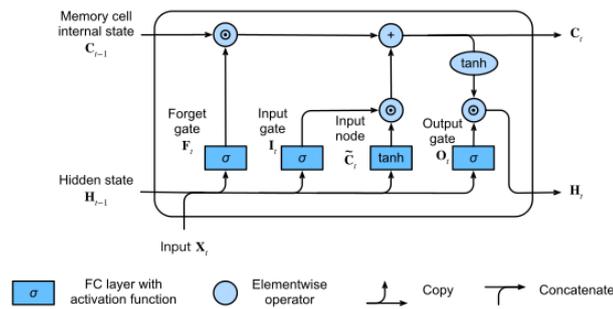
Fonte: Zhang et al. (2023).

2.6 LONG SHORT-TERM MEMORY

A *Long Short-Term Memory* (LSTM) é um tipo de rede neural recorrente projetada para modelar sequências temporais e dependências de longo prazo em dados sequenciais. Criadas para superar as limitações das RNNs tradicionais, as LSTMs utilizam uma arquitetura de células de memória que pode reter informações por longos períodos. Essa estrutura permite que as LSTMs lidem eficazmente com o problema do desaparecimento do gradiente, que afeta o treinamento das redes recorrentes clássicas (ZHANG et al., 2023). A Figura 10 ilustra a arquitetura da LSTM.

A arquitetura da LSTM armazena informações internas por meio de seus três portões, que determinam: i) input gate, que define quais valores de entrada devem afetar o estado interno da célula; ii) forget gate, que determina quais informações da célula de memória devem ser descartadas; e iii) output gate, que define quais valores devem ser usados para produzir a saída da célula.

Figura 10 – Arquitetura da célula LSTM.



Fonte: Zhang et al. (2023).

As Equações 2.2 - 2.4 exemplificam o cálculo de cada portão na célula LSTM.

$$I_t = \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i) \quad (2.2)$$

$$F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f) \quad (2.3)$$

$$O_t = \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o) \quad (2.4)$$

No qual X_t é a entrada na célula, H_{t-1} é o estado da célula anterior W_{xi} , W_{xf} e W_{xo} são os pesos de cada portão, e b_i , b_f e b_o os seus *bias*. O *Input Node* (Equação 2.5) H_t da célula é similar aos portões, mas com uma função de ativação agregada, e é dada por:

$$\tilde{C}_t = \tanh(X_t W_{xc} + H_{t-1} W_{hc} + b_c) \quad (2.5)$$

A memória interna da célula é dado por:

$$C_t = F_t \odot C_{t-1} + I_t \odot \tilde{C}_t \quad (2.6)$$

Por fim, a saída da célula é dado pela Equação 2.7.

$$H_t = O_t \odot \tanh(C_t) \quad (2.7)$$

2.7 CONVOLUTIONAL NEURAL NETWORKS

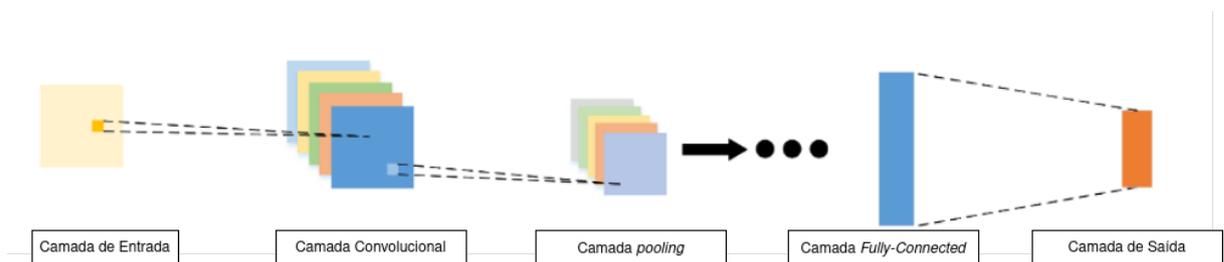
A Rede Neural Convolucional (CNN) é um tipo de rede neural projetada especificamente para processar dados com uma estrutura de grade, como imagens. Elas têm sido altamente bem-sucedidas em várias tarefas de visão computacional, como reconhecimento de imagem, detecção de objetos e segmentação de imagem (ZHANG et al., 2023). As camadas de convolução utilizam filtros (ou *kernels*) que se movem pela entrada, aplicando uma operação de convolução para detectar características específicas, como bordas e texturas. A saída das redes convolucionais pode ser expressa pela Equação 2.8:

$$C_i = f(w_i * x_i) + b_i \quad (2.8)$$

Em que C_i denota a saída da i -ésima camada convolucional, w_i a matriz de peso (*kernel*), x_i a saída da camada anterior e b_i o vetor de *bias*. $f(\cdot)$ a função de ativação resultante do produto interno entre w_i e x_i .

A Figura 11 ilustra a arquitetura básica de uma rede convolucional. A camada de entrada é composta pelas imagens disponíveis para o treinamento dos modelos. Na camada convolucional são realizadas convoluções utilizando filtros que serão treinados para extrair as características relevantes. Na camada de *pooling* operações são realizadas com o objetivo de reduzir a dimensionalidade das entradas. Após a extração dessas características, as informações são encaminhadas para uma rede totalmente conectada (MLP), que gera a saída desejada.

Figura 11 – Exemplo da rede convolucional aplicada.



Fonte: Wang et al. (2023a) adaptado.

As CNNs possuem várias vantagens, como a capacidade de capturar padrões espaciais e temporais nos dados e a significativa redução da necessidade de engenharia manual de características. Além disso, sua excelência em diversas tarefas de visão computacional é amplamente comprovada. No entanto, essas redes também apresentam desvantagens, como a necessidade

de grandes quantidades de dados rotulados para um treinamento eficaz, altos requisitos computacionais e a dificuldade de interpretar como as características internas influenciam a decisão final, conhecido como o problema da "caixa-preta".

3 REVISÃO DA LITERATURA

Com o crescimento da geração de energia elétrica a partir de fontes eólicas (EPE, 2024) e a expansão de modelos baseados em redes profundas aplicadas ao prognóstico de rolamentos, diversos estudos podem ser encontrados na literatura abordando a resolução de problemas de O&M em aerogeradores (KUMAR; RAOUF; KIM, 2023). Esses estudos tratam de prognósticos de vários componentes de aerogeradores, utilizando dados de sistemas como *Supervisory Control and Data Acquisition* (SCADA), CMS, análises sonoras, entre outros (PANDIT; ASTOLFI; CARDENAS, 2023).

Por outro lado, a aplicação de modelos baseados em aprendizagem profunda no prognóstico de rolamentos é amplamente abordada na literatura (BERMEO-AYERBE et al., 2023; VELASCO-GALLEGO et al., 2023). Nesses casos, os dados utilizados são obtidos em um ambiente controlado, onde a carga e a velocidade de rotação do rolamento permanecem constantes durante toda a sua vida útil. Além disso, esse ambiente controlado permite a operação do rolamento até a falha completa, o que não é possível em aerogeradores (NECTOUX et al., 2012; WANG et al., 2020).

Wang et al. (2023b) utilizou um modelo baseado em redes convolucionais e Gated Recurrent Unit (GRU) bidirecional para o prognóstico de rolamentos em bancada. A proposta dos autores consiste no treinamento das redes a partir de técnicas de reamostragem pelo algoritmo de *bootstrap*. Nesse caso, foi implementada a técnica de FPT para avaliar a degradação inicial do rolamento.

Huang et al. (2021a) propôs um modelo que utiliza CNN e MLP para o prognóstico de rolamentos em bancada. Para alimentar esses modelos, foi realizada a decomposição em tempo e frequência a partir da Continuous Wavelet Transform (CWT) e a extração de características no domínio do tempo. Além disso, foi aplicado um algoritmo de *bootstrap* para tornar o modelo mais robusto. Como resultado, foi observado que a extração de informações em ambos os domínios teve um desempenho melhor do que os modelos isolados.

Contudo, os dados reais obtidos dos sistemas SCADA e CMS não refletem a operação até a falha completa, como já citado anteriormente. Além disso, a medição dos dados nessas condições é mais controlada e equidistante, o que não ocorre na medição dos dados de vibração do CMS. Nesse sentido, diversos trabalhos buscam realizar o prognóstico de seus componentes a partir de diferentes técnicas e metodologias propostas.

Devido à importância do monitoramento das condições de operação dos aerogeradores, diversos estudos que buscam compreender o estado da arte do prognóstico em aerogeradores podem ser encontrados na literatura. Leite, Araujo e Rosas (2018) agruparam vários estudos sobre a manutenção de aerogeradores com base em suas condições de operação. Esse estudo apresenta informações relevantes sobre as principais falhas conhecidas na operação de turbinas eólicas e o tempo de parada causado por sua degradação. Observa-se que as falhas mecânicas mais frequentes ocorrem nas pás dos rotores e na caixa de engrenagens, sendo essas também as falhas que resultam no maior tempo de inatividade da máquina.

Kordestani et al. (2020) apresentaram um estudo sobre três aerogeradores monitorados durante 10 anos. O modelo se baseia em Dynamic Principle Component Analysis (DPCA), adaptado a um modelo de *Support Vector Machine* (SVM), para isolar as falhas. Em seguida, o modelo proposto foi comparado com modelos de redes neurais. Nesse estudo, foi observado que o SVM identificou a degradação do planetário com 1 mês de antecedência em comparação aos demais modelos.

Guo et al. (2020) propuseram uma metodologia de prognóstico da *gearbox* de aerogeradores com dados do SCADA, domínio físico e registros de falhas dos aerogeradores, com o objetivo de realizar um prognóstico probabilístico. Eles utilizaram a temperatura adquirida no sistema SCADA e a modelaram com uma distribuição de Weibull para estimar a falha no rolamento da caixa de engrenagens. Modelos probabilísticos são uma solução útil devido aos graus de incerteza gerados, o que proporciona um intervalo de confiança para a tomada de decisões sobre a manutenção.

Gao e Liu (2021) realizaram um estudo sobre prognóstico e diagnóstico de falhas, identificando as principais causas da degradação dos componentes do aerogerador. Para as pás e o rotor, as principais causas de falhas foram corrosão e fissuras, redução da dureza, aumento da rugosidade das superfícies, deformação das pás, erros no ângulo de pitch e desbalanceamento do rotor. Em relação à *gearbox*, foram observados desalinhamentos dos eixos, danos em rolamentos, eixos e engrenagens, além de problemas de lubrificação, como temperatura do óleo, vazamentos e baixa lubrificação. No gerador, as falhas mais comuns são causadas por excesso de vibração e superaquecimento.

Owolabi et al. (2022) agruparam estudos sobre o prognóstico da RUL especificamente em *gearboxes*. Esses estudos identificaram que as falhas críticas nas *gearboxes* representam os maiores custos e o maior tempo de inatividade na operação e na geração de energia no sistema elétrico. Além disso, as falhas mais frequentes ocorrem nos rolamentos do eixo de alta veloci-

dade, eixo de velocidade intermediária e no planetário, que correspondem a aproximadamente 75% das falhas na gearbox.

Ma et al. (2023) realizaram o prognóstico do *main bearing* de turbinas eólicas utilizando sensores acústicos posicionados no aerogerador. Foram feitas análises espectrais das frequências de banda dos dados obtidos por esses sensores, que são bastante eficientes na identificação localizada da degradação do rolamento em estudo. Observando os harmônicos detectados pelos sensores, foi possível identificar o ponto em que a degradação ocorre. Estudos de prognóstico utilizando sensores acústicos mostram-se promissores para futuras pesquisas, devido à eficácia na extração de dados.

Pandit, Astolfi e Cardenas (2023) estudaram os tipos de dados utilizados para o treinamento de modelos de RUL de aerogeradores. Eles observaram que os dados para o prognóstico da RUL provêm principalmente do monitoramento do óleo, dos dados de vibração (CMS) e do sistema SCADA, sendo este último o mais amplamente utilizado devido à sua disponibilidade em todos os aerogeradores.

Zou et al. (2023) propuseram a combinação do *Grey Model* e *Double Exponential Smoothing* para o prognóstico com base na concentração de partículas de ferro e molibdênio presentes no óleo da caixa de engrenagens, resultantes da degradação dos rolamentos. Além disso, implementaram um sistema de alarme para avaliar a degradação dos componentes a partir da diferença entre um modelo linear de decaimento. Contudo, o monitoramento de condições baseado na análise do óleo é realizado *offline*, ou seja, a análise é feita em diferentes intervalos de tempo, sem a possibilidade de transmissão de informações em tempo real.

Brijder, Helsen e Ompusunggu (2023) realizaram a detecção e o prognóstico de aerogeradores *offshore*. Essas máquinas operam em condições muito diferentes das *onshore*, pois estão situadas no alto mar e sofrem os efeitos do ambiente marinho. Os autores propuseram uma metodologia que aplica filtros de Kalman para diagnóstico e, posteriormente, três métodos de prognóstico baseados na função de degradação.

Shaheen e Németh (2023) treinaram redes neurais artificiais para o prognóstico da RUL e a manutenção programada dos aerogeradores com base nos dados do sistema SCADA. Após o treinamento, os modelos passaram por um processo de soma acumulada para agregar as informações de degradação ao modelo. Nesse estudo, observou-se que o modelo busca corrigir a eficiência do aerogerador durante o monitoramento para estimar sua vida útil

Castellani et al. (2024) conduziram um estudo que combina dados do SCADA e do CMS para o prognóstico da RUL da *gearbox*. Um dos principais desafios dessa abordagem é a

diferença entre os tempos de aquisição de dados dos dois sistemas. Para superar isso, os dados do SCADA foram utilizados para o treinamento de um modelo de SVM, enquanto os dados do CMS foram processados para extração de características e treinamento com um modelo *Autoencoder*. A combinação dos resultados gerou um limiar que identifica a degradação dos rolamentos da *gearbox*. Contudo, os dados do CMS foram obtidos por cálculos de estatísticas, o que não aproveita totalmente as informações em tempo-frequência presentes no sinal.

Vieira et al. (2024) fizeram o prognóstico da RUL do *main bearing* de aerogeradores utilizando dados do SCADA. O estudo combinou diferentes modelos de aprendizado de máquina, como SVM, *gradient boosting*, *random forest* e árvores de decisão. A variável utilizada foi o aumento da temperatura medida pelo SCADA, e o estudo identificou a degradação com pelo menos 20 dias de antecedência. Um destaque desse trabalho foi a alta acurácia no prognóstico, mesmo com dados ausentes na série temporal de temperatura.

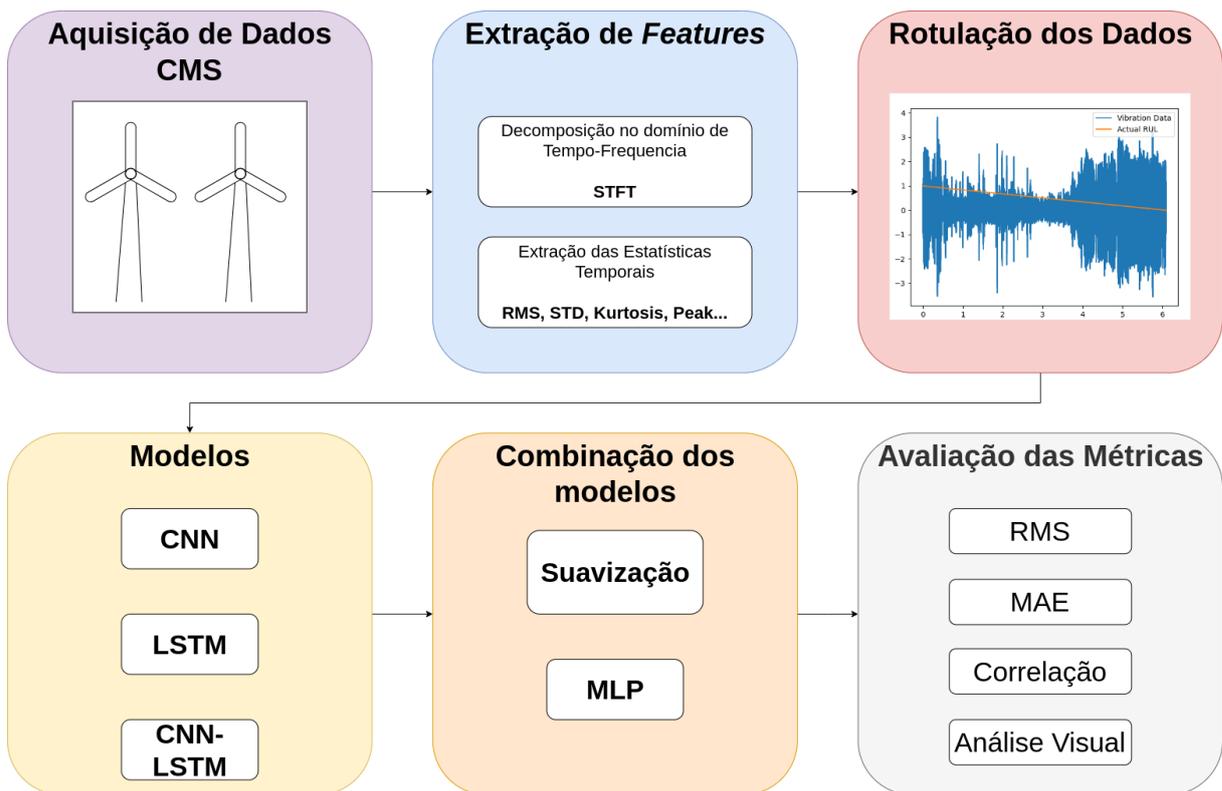
Zaniboni et al. (2024) utilizaram Análise de Componentes Principais (PCA) e *Autoencoder* para o monitoramento da condição das pás dos aerogeradores. Com a metodologia proposta, foi possível reconstruir o sinal a partir dos dados reais e monitorar em tempo real a degradação desse componente. Além disso, essa abordagem permitiu identificar anomalias com base nas informações adquiridas do sistema SCADA, possibilitando avaliar as diferentes regiões de operação e tomar decisões mais informadas sobre a saúde da máquina.

Nesse sentido, observa-se que a maioria dos trabalhos sobre prognóstico de aerogeradores baseia-se em dados do sistema SCADA, enquanto estudos relacionados ao monitoramento de vibração dos componentes são mais escassos. Análises de vibração dos rolamentos geralmente são realizadas em dados de bancada, um ambiente controlado que permite a operação até a falha total do rolamento. Assim, este estudo emprega dados de vibração provenientes do CMS para o prognóstico de aerogeradores, utilizando dados obtidos durante a operação real da máquina.

4 METODOLOGIA

Neste capítulo, será abordada a metodologia empregada para o prognóstico da RUL nos rolamentos do aerogerador. Especificamente, esse prognóstico deve ser realizado no planetário da *gearbox*, o qual contém um rolamento de baixa rotação. A Figura 12 apresenta o diagrama geral da metodologia proposta, onde são observadas seis etapas distintas: i) aquisição dos dados de vibração dos rolamentos do aerogerador, provenientes do CMS; ii) extração das *features*, na qual são obtidas as informações necessárias para o treinamento dos modelos; iii) rotulação dos dados, onde é gerada a informação-alvo para realizar a regressão; iv) treinamento dos modelos de aprendizagem profunda para os rolamentos em teste; v) combinação das saídas das redes neurais; e vi) avaliação dos resultados obtidos a partir da metodologia proposta.

Figura 12 – Fluxograma da metodologia proposta



Fonte: o autor (2024).

4.1 EXTRAÇÃO DE CARACTERÍSTICAS

De posse dos dados de vibração, a etapa seguinte é a extração de informações dessas amostras, uma fase crucial no processo de aprendizado de máquina, pois a extração de ca-

racterísticas dos dados permite treinar os modelos e identificar o processo de degradação dos rolamentos em análise. Assim, duas abordagens foram realizadas para obter essas *features*: i) cálculo de estatísticas temporais e ii) decomposição no domínio do tempo e da frequência.

4.1.1 Cálculo das Estatísticas Temporais

Seguindo a estratégia de compreender o comportamento da vibração dos rolamentos do aerogerador, é possível observar as mudanças e variações capturadas pelo sensor durante a operação da máquina. Uma forma de analisar isso é através do cálculo de algumas estatísticas no domínio do tempo, como a Raiz do Valor Quadrático (RMS), na qual o aumento dessa variável ao longo do tempo está diretamente relacionado com a degradação (CAMPO; SANDIN; STRÖMBERGSSON, 2020). Essas características podem auxiliar na observação da degradação do componente e, assim, no treinamento dos modelos de aprendizagem profunda.

Sendo assim, para este estudo, foram selecionadas oito *features* para a análise temporal da degradação do rolamento do planetário da caixa de engrenagens do aerogerador. Essas características são: média, desvio padrão, máximo, mínimo, pico-a-pico, RMS, curtose e assimetria. As Equações 4.1 - 4.8 apresentam cada uma delas, respectivamente. Essas características também podem ser encontradas em outros trabalhos de prognóstico de rolamentos (HUANG et al., 2021a).

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N} \quad (4.1)$$

$$\sigma = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N} \quad (4.2)$$

$$Max = \max(x_i) \quad (4.3)$$

$$Min = \min(x_i) \quad (4.4)$$

$$P_k = \max(x_i) - \min(x_i) \quad (4.5)$$

$$RMS = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}} \quad (4.6)$$

$$\text{Curtose} = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{\sigma^4} \quad (4.7)$$

$$\text{Assimetria} = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{\sigma^3} \quad (4.8)$$

Em que x_i é o valor da aceleração observado pelo sistema CMS; \bar{x} é a média calculada sobre o conjunto de amostras; N é o número de amostras observadas, que, no caso em estudo, são 4096 valores; e σ é o desvio padrão da série temporal.

4.1.2 Decomposição em Tempo-Frequência

Embora o cálculo de estatísticas sobre os dados de vibração possa fornecer informações relevantes sobre a degradação do rolamento, algumas características intrínsecas da série temporal podem ser perdidas nesse processo, como as frequências associadas ao desgaste do rolamento. Dessa forma, a aplicação de técnicas de decomposição da série temporal pode extrair essas informações, permitindo identificar frequências características que sinalizam a degradação do rolamento.

Técnicas de decomposição, como a *Continuous Wavelet Transform* (CWT) e a *Short-Time Fourier Transform* (STFT), têm sido utilizadas em estudos sobre vibração de rolamentos (HUANG et al., 2021a; LI; ZHANG; DING, 2019). Como o objetivo deste trabalho é identificar frequências características em que a degradação ocorre, optou-se pela STFT. Esse método permite observar frequências da série temporal em situações não estacionárias. Espera-se que essa técnica identifique padrões de frequência distintos que indiquem a degradação do rolamento, possibilitando a aplicação de modelos de aprendizagem profunda.

Nesse sentido, a aplicação da STFT foi realizada utilizando as 4096 amostras adquiridas em cada intervalo de medição. Diversos tipos de janelas de amostragem podem ser utilizadas, como a quadrada, Hanning, Hamming, entre outras. Para este estudo, foi escolhida a janela de Hamming com 128 amostras. Com o objetivo de minimizar a perda de informações nas bordas das janelas deslizantes, foi aplicado a sobreposição de 64 amostras. Dessa forma, dentro de cada janela, pode-se considerar que o comportamento da vibração é estacionário, permitindo a aplicação da Transformada de Fourier.

A janela é deslizada ao longo da série até que todas as informações de frequência sejam extraídas. Como a STFT gera números complexos, foi calculado o valor absoluto da saída.

O resultado gerado por cada amostra produziu uma matriz de dimensão 65 x 65, a qual foi utilizada como variável de entrada para os modelos de *deep learning*.

4.2 ROTULAÇÃO DE DADOS

Um dos desafios observados durante este trabalho é o fato de os sensores terem sido instalados nos aerogeradores em um período posterior ao início de operação das máquinas. Assim, informações relevantes sobre a saúde da máquina podem estar comprometidas, uma vez que a degradação pode ter começado antes da instalação do CMS. Por esse motivo, estratégias como o *First Prediction Time* (FPT) não podem ser empregadas de forma adequada para observar o decaimento da RUL ao longo do tempo. Nesse sentido, buscou-se uma nova estratégia de rotulação de dados para contornar o problema da ausência de informações em máquinas sadias.

Com base nas informações coletadas, foram selecionadas máquinas para o treinamento e a avaliação dos modelos propostos. Como o comportamento da degradação ao longo do tempo não é conhecido, a estratégia utilizada para obter essas informações é a seguinte:

1. O dia em que o aerogerador parou foi considerado como o fim da vida útil do componente em questão; assim, a RUL nesse momento é considerada como zero.
2. A partir do item anterior, foi definido um intervalo de dias anteriores em que a degradação é identificável. Com base nisso, o valor da RUL decai linearmente até a data de parada.
3. Por fim, os valores de RUL antes da degradação e após a manutenção foram definidos como unitários.

Para realizar este experimento, os dados foram separados em subconjuntos, com 80% destinados ao treinamento e 20% à validação. Os modelos foram então treinados com a RUL, considerando inícios de degradação a 30, 60, 90 e 120 dias antes da parada. Por fim, para cada modelo, foi escolhida a quantidade de dias que apresentasse o menor erro quadrático médio (MSE).

4.3 MODELOS E COMBINAÇÃO

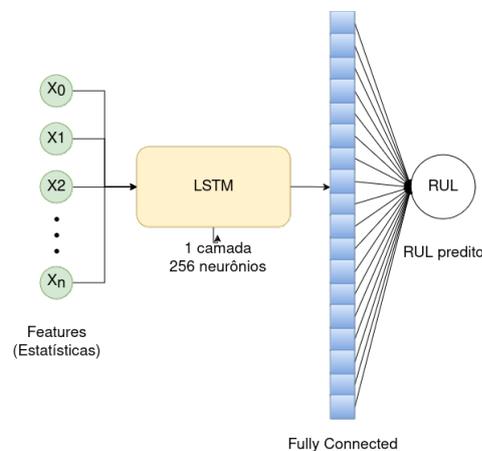
Nesta seção, serão apresentados os modelos propostos para a regressão da RUL dos rolamentos do planetário da caixa de engrenagens, bem como a combinação das saídas desses modelos. Foram desenvolvidos três modelos: LSTM, CNN e CNN-LSTM.

4.3.1 LSTM

Para o treinamento do modelo LSTM, foram utilizados os dados obtidos no domínio do tempo. Como mencionado anteriormente, a extração de características resultou em 8 variáveis distintas para cada amostra. No entanto, apenas o cálculo das estatísticas não permite explorar adequadamente o crescimento ou o decaimento de uma determinada variável. Nesse sentido, o modelo visa capturar informações ao longo do tempo, utilizando uma janela de amostras que serve como entradas para a rede neural. Essa janela variou entre 5 a 15 variáveis regressoras.

A Figura 13 ilustra a arquitetura da LSTM proposta para prever a RUL dos rolamentos do aerogerador. Nesse caso, a janela temporal foi utilizada para a previsão, com cada amostra contendo as estatísticas no domínio do tempo. Em seguida, esses valores foram processados pela rede LSTM, que utilizou 256 neurônios, determinado a partir de uma análise de sensibilidade que variou de 64 a 256 neurônios, seguidos por uma camada totalmente conectada. Para o treinamento do modelo, foi empregado o otimizador **Adam**, com uma taxa de aprendizado de $1 \cdot 10^{-3}$, e a função de perda utilizada foi o erro quadrático médio (MSE).

Figura 13 – Arquitetura da LSTM proposta

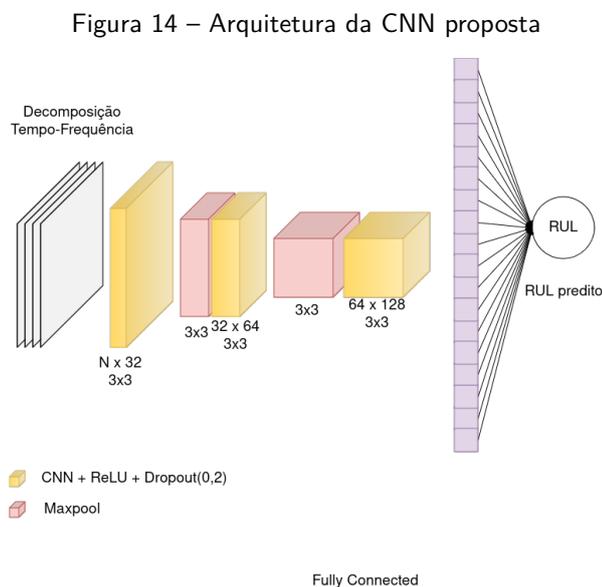


Fonte: o autor (2024)

4.3.2 CNN

O modelo CNN aplicado ao prognóstico da RUL dos rolamentos foi ajustado para aprender a partir da decomposição da série de vibração obtida por meio da STFT. Após a decomposição, a série adquire uma dimensão de 65×65 , que pode ser interpretada como uma imagem para a rede convolucional. Em seguida, foi realizado um estudo sobre a quantidade de amostras simultâneas que deveriam servir como entrada para a rede, funcionando como um "pacote" de informações ao longo do tempo, permitindo que o modelo compreenda as frequências associadas à degradação. A Figura 14 ilustra o modelo proposto para a previsão.

No primeiro caso, as decomposições servem como entrada. Em seguida, essas informações são processadas por três camadas convolucionais, cada uma com um *kernel* de 3×3 , utilizando a função de ativação ReLU e um *dropout* de 0,2 para prevenir o overfitting do modelo. Entre cada camada, é aplicada a operação de *max pooling*, com o objetivo de reduzir a dimensão das "imagens". Assim como na rede LSTM, o modelo CNN utilizou os mesmos parâmetros de aprendizado.



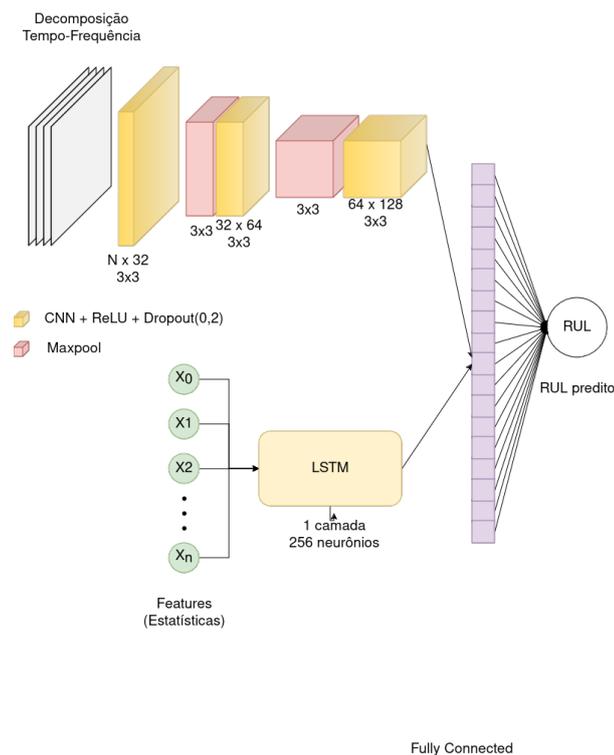
Fonte: o autor (2024)

4.3.3 CNN-LSTM

Com o objetivo de obter informações em diferentes domínios de aprendizado, este modelo combina as informações tanto no domínio do tempo quanto no domínio tempo-frequência de

forma simultânea. Dessa maneira, busca-se melhorar a acurácia do prognóstico, aproveitando o melhor de ambas as redes neurais. A arquitetura pode ser visualizada na Figura 15. Observa-se que as duas arquiteturas anteriores são apresentadas neste caso de forma paralela, e a saída da rede totalmente conectada é concatenada. Assim como nos casos anteriores, foi realizada a busca pela janela temporal que melhor se ajusta à regressão da RUL. Os parâmetros de treinamento também são idênticos aos utilizados nas abordagens anteriores.

Figura 15 – Arquitetura da CNN-LSTM proposta



Fonte: o autor (2024)

4.3.4 Suavização e Combinação

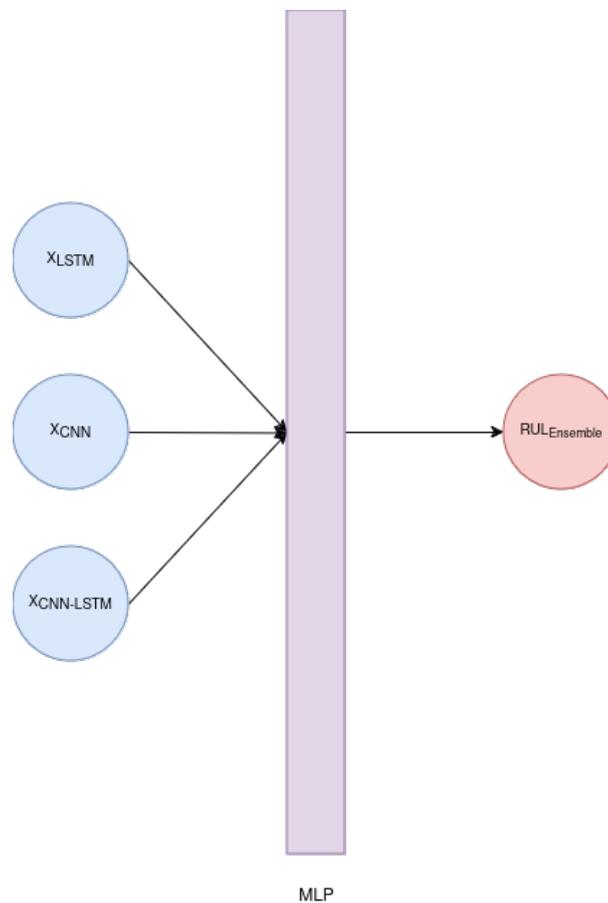
Enquanto a identificação de padrões globais de degradação da RUL pode ser realizada após o treinamento das redes neurais, flutuações locais frequentemente ocorrem, resultando em informações enganosas, como o aumento da RUL. Isso se deve ao fato de que, uma vez que a degradação se inicia, o tempo de vida útil tende a diminuir continuamente. Para contornar esse problema, foi aplicada uma metodologia de suavização do sinal, conforme descrito na equação 4.9. Para obter informações mais próximas da falha, foi selecionada uma janela de

120 dias para cada aerogerador, na qual a degradação foi aplicada em cada modelo.

$$R_t = \begin{cases} R_t, & \text{se } R_t \leq R_{t-1}, \\ R_{t-1} & \text{caso contrário} \end{cases} \quad (4.9)$$

Em seguida, as saídas de cada modelo foram utilizadas como dados de entrada em uma rede neural do tipo MLP, visando combinar os resultados obtidos. Neste caso, a arquitetura consistiu em uma camada oculta com 16 neurônios e função de ativação do tipo ReLU. O otimizador selecionado foi o Adam, com uma taxa de aprendizado de $1 \cdot 10^{-3}$. A Figura 16 ilustra a arquitetura da rede proposta.

Figura 16 – Arquitetura da MLP proposta



Fonte: o autor (2024)

4.4 AVALIAÇÃO

Para a avaliação dos modelos, foram selecionadas três estatísticas: o Erro Médio Absoluto (MAE) (Equação 4.10) e a Raiz do Erro Quadrático Médio (RMSE) (Equação 4.11), que visam

medir a discrepância entre os valores reais e as saídas dos modelos. Além disso, foi utilizado o coeficiente de correlação de Pearson (Equação 4.12), que busca relacionar a degradação observada na máquina com os valores previstos pelos modelos.

$$\text{MAE} = \frac{\sum_{i=1}^N |x_i - \hat{x}_i|}{N} \quad (4.10)$$

$$\text{RMSE} = \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{N} \quad (4.11)$$

$$\text{Correlação} = \frac{1}{N} \frac{\sum_{i=1}^N (x_i - \bar{x})(\hat{x}_i - \bar{\hat{x}})}{\sigma_x \sigma_{\hat{x}}} \quad (4.12)$$

No qual x_i representa o valor real da RUL no instante i ; \bar{x} é a média da RUL real; \hat{x}_i é o valor previsto para a RUL pelo modelo; $\bar{\hat{x}}$ é a média dos valores previstos; e σ_x e $\sigma_{\hat{x}}$ são os desvios padrão da RUL real e prevista, respectivamente.

A primeira etapa envolve a separação dos conjuntos de treinamento e teste dos modelos, visando identificar o comportamento da degradação ao longo do tempo a partir do histórico de falhas e manutenções ocorridas. Dessa forma, com a análise adequada dos conjuntos, é possível extrair informações sobre o decaimento da vida útil e, conseqüentemente, estimar de forma acurada o decaimento da RUL dos aerogeradores.

Em seguida, é necessário aplicar uma metodologia para rotular o decaimento da RUL dos rolamentos em estudo. É importante destacar que o início da série temporal de vibração não coincide com o início da operação da máquina, ou seja, o CMS foi instalado muito tempo após a entrada em operação das máquinas. Esse fato pode afetar de forma negativa a rotulação dos dados, uma vez que os sinais observados podem não conter informações da máquina quando está em plena saúde, o que impossibilita a extração de informações sobre componentes em bom estado.. Sendo assim, técnicas de observação como *First Time Predict* (FPT) são impossibilitados de realizar a rotulação dos dados (VIEIRA et al., 2024). Sendo assim, a estratégia utilizada foi aplicar a roturação dos dados a partir da análise de sensibilidade em relação a quantidade de dias em que é observada variações no sinal de vibração e como ela acarreta na falha observada. A partir dessa proposta, pode-se identificar a quantidade de dias mínimos necessários para observar o decaimento da vida útil do aerogerador.

Para realização do treinamento dos modelos, faz-se necessária a extração de *features* dos dados de vibração. Os dados brutos, além de terem dimensão alta, o que gera custos computacionais elevados, trazem muita variabilidade que pode ser difícil dos modelos preverem.

Sendo assim, são calculadas estatísticas e decomposições da vibração do rolamento de modo a observar seu comportamento quanto a degradação. Para isso, foram selecionadas características tanto no domínio do tempo quanto na decomposição de tempo-frequência a partir da STFT.

O prognóstico da RUL é realizado utilizando modelos de *Deep Learning*, que representam o estado da arte para a previsão da degradação em rolamentos de bancada (LI; ZHANG; DING, 2019; HUANG et al., 2021b). Para implementar a proposta deste trabalho, foram treinados três modelos de *deep learning*: i) LSTM, com o objetivo de extrair informações no domínio do tempo; ii) CNN, que trata as informações de decomposição em tempo e frequência como imagens e realiza as convoluções desejadas; e iii) CNN-LSTM, que busca obter simultaneamente informações do domínio do tempo e das decomposições. Essa complementaridade pode gerar resultados mais precisos e, conseqüentemente, proporcionar um prognóstico confiável para aplicação no sistema interligado de energia, permitindo a tomada de decisão quanto à manutenção dos aerogeradores.

5 RESULTADOS

Neste capítulo será discutido os resultados obtidos a partir da aplicação da metodologia descrita acima sobre o CMS. Os resultados que devem ser observados são relacionados a: i) estimativa da RUL; ii) estudo de caso para a troca da *gearbox*; iii) estudo de caso para manutenção da máquina; e iv) avaliação do modelo de combinação.

5.1 CONJUNTO DE DADOS

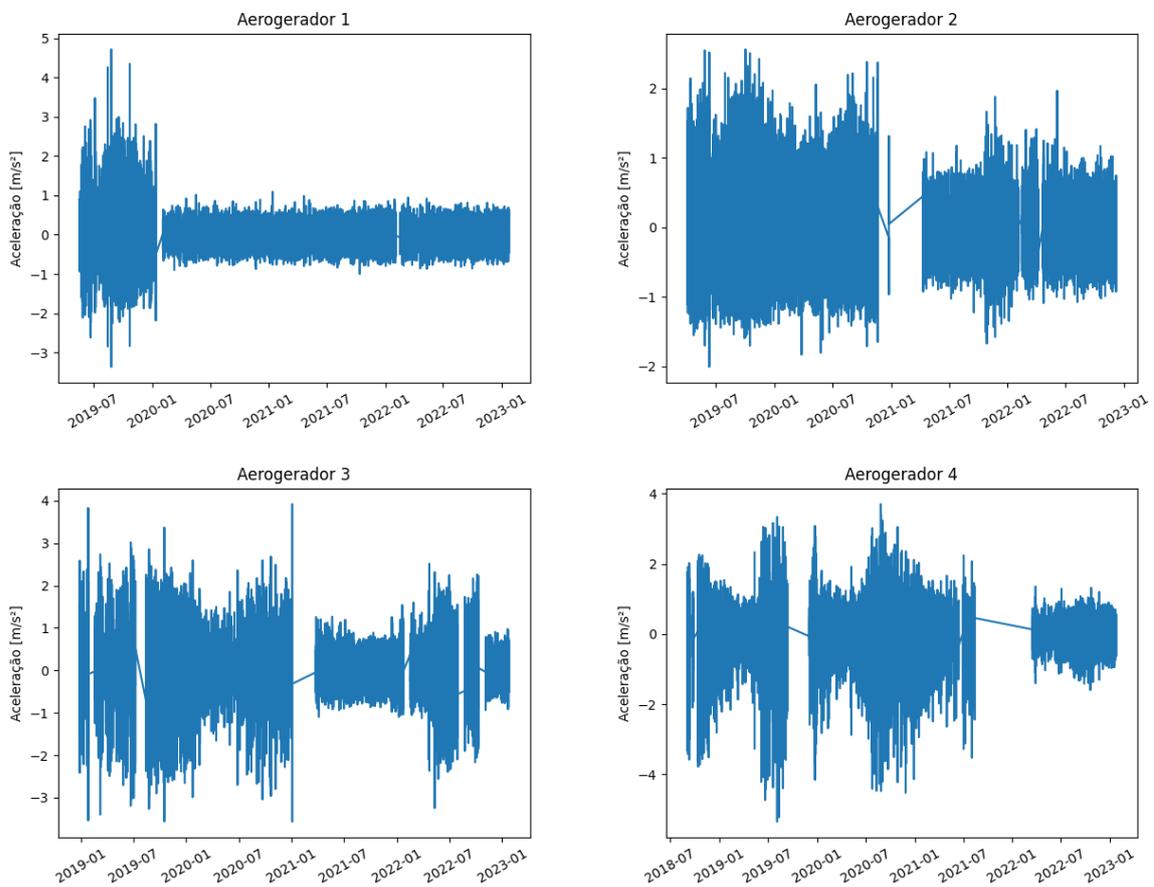
Os dados do CMS disponibilizados neste trabalho foram obtidos no âmbito de um projeto de Pesquisa e Desenvolvimento (P&D) da ANEEL, executado pelo Centro de Energias Renováveis da Universidade Federal de Pernambuco (CER-UFPE), em parceria com pesquisadores do Centro de Informática (CIn-UFPE). Por questões de confidencialidade, foram ocultadas algumas informações sensíveis das máquinas, como latitude, longitude, fabricante, modelo e potência nominal dos aerogeradores. Contudo, trata-se de máquinas idênticas (mesma potência nominal e do mesmo fabricante). Como o objeto de estudo é o prognóstico no planetário, foram identificados quatro aerogeradores que apresentaram falhas conhecidas neste componente durante o período de aquisição de dados, que se inicia no começo de 2019 e se prolonga até o final de 2022, totalizando aproximadamente quatro anos de dados de vibração do CMS.

Os sensores do CMS instalados em cada aerogerador monitoram, entre outras variáveis, a aceleração dos rolamentos. Para este estudo, foi definido trabalhar com os dados da aceleração axial dos rolamentos, uma vez que esses dados apresentam o comportamento da vibração do rolamento em análise e, em algumas máquinas, foi observado um deslocamento de alguma engrenagem do planetário, informação essa fornecida pela empresa. O sensor mencionado possui uma taxa de amostragem de 256 Hz, medidos em períodos diários. Vale ressaltar que esse intervalo de medição não é exatamente equidistante, pois, em alguns casos não especificados, a medição pode ser realizada de forma mais frequente, isto é, realizar mais medições dentro do mesmo dia. Cada amostra do sensor extrai 4096 dados de aceleração, e são esses dados que serão utilizados para o treinamento dos modelos propostos neste trabalho.

A Figura 17 mostra o comportamento da aceleração dos rolamentos ao longo do período em análise para cada uma das máquinas em estudo. Nela, é possível observar a vibração dos rolamentos durante os quatro anos mencionados, sendo notável que a amplitude se comporta

de forma diferente nos períodos antes da manutenção e após a correção da falha. Durante o projeto, foi disponibilizado o histórico de falhas dos aerogeradores, que informa as datas de parada do aerogerador, o momento de retorno à operação normal, a quantidade de dias que a máquina permaneceu parada para correção da falha, e o diagnóstico fornecido pela equipe de manutenção. Algumas dessas informações das máquinas em estudo podem ser vistas na Tabela 1. Segundo o registro de manutenção, no Aerogerador 1 foi realizada a substituição completa da *gearbox*, enquanto nos demais foi constatado um deslocamento em um dos três rolamentos do planetário, porém o componente não foi substituído.

Figura 17 – Vibração ao longo do tempo de cada aerogerador em estudo



Fonte: o autor (2024)

Tabela 1 – Histórico de manutenções dos aerogeradores em estudo.

	Data de parada	Data de Retorno	# dias parados
Aerogerador 1	12/01/2020	03/02/2020	22
Aerogerador 2	20/11/2020	09/04/2021	140
Aerogerador 3	02/01/2021	19/03/2021	76
Aerogerador 4	16/08/2021	07/11/2021	83

5.2 ESTIMATIVA DA RUL

A primeira avaliação necessária é a análise do decaimento da RUL. As Tabelas 2 - 4 apresentam o MSE obtido pela metodologia proposta para essa estimativa. Observa-se que, na maioria dos casos, o erro associado a essa previsão é superior a 60 dias. Isso indica que, a partir da aplicação dos modelos, o sinal de degradação do rolamento pode ser detectado com aproximadamente dois meses de antecedência.

Tabela 2 – MSE da LSTM sobre a quantidade de dias a regressão da RUL.

	30	60	90	120
Aerogerador 1	0.0620	0.0417	0.0598	0.0601
Aerogerador 2	0.0339	0.0376	0.0269	0.0356
Aerogerador 3	0.0174	0.0090	0.0131	0.0065
Aerogerador 4	0.0638	0.0472	0.0417	0.0589

Tabela 3 – MSE da CNN sobre a quantidade de dias a regressão da RUL.

	30	60	90	120
Aerogerador 1	0.0038	0.0022	0.0021	0.0027
Aerogerador 2	0.0038	0.0022	0.0021	0.0027
Aerogerador 3	0.0001	0.0002	0.0002	0.0001
Aerogerador 4	0.0015	0.002	0.0024	0.0055

Tabela 4 – MSE da CNN-LSTM sobre a quantidade de dias a regressão da RUL.

	30	60	90	120
Aerogerador 1	0.0474	0.0459	0.0302	0.0439
Aerogerador 2	0.0122	0.0066	0.0101	0.0102
Aerogerador 3	0.0026	0.0019	0.0029	0.0028
Aerogerador 4	0.0197	0.01891	0.0184	0.0127

Com os resultados apresentados e estudos mais aprofundados, é possível superar um dos desafios identificados no prognóstico da RUL dos rolamentos de aerogeradores. De modo geral,

os dados disponíveis para o treinamento das redes neurais não têm seu início coincidente com a operação da máquina, o que inviabiliza a aplicação de técnicas como o *First Predict Time*. Além disso, as máquinas não costumam operar até o final de sua vida útil, uma vez que isso poderia causar danos catastróficos e prejuízos financeiros. No entanto, essa limitação pode ser contornada utilizando-se o histórico de manutenção das máquinas.

5.3 ESTUDO DE CASO 1: TROCA DA GEARBOX

Conforme mencionado na descrição dos dados, o Aerogerador 1 teve a troca da *gearbox* registrada em seu histórico de manutenção. Assim, este tópico busca treinar as redes neurais com base nessa máquina e testar seus resultados nos demais aerogeradores.

As Tabelas 5 e 6 apresentam os resultados do RMSE e MAE, respectivamente. É possível observar que os modelos com menor erro associado ao prognóstico da RUL dos rolamentos do aerogerador são aqueles que se baseiam em redes convolucionais.

Tabela 5 – Resultados do RMSE para os modelo treinados com o Aerogerador 1.

	LSTM	CNN	CNN-LSTM
Aerogerador 2	0.23539	0.28369	0.20279
Aerogerador 3	0.25793	0.18622	0.22122
Aerogerador 4	0.23176	0.27446	0.22748

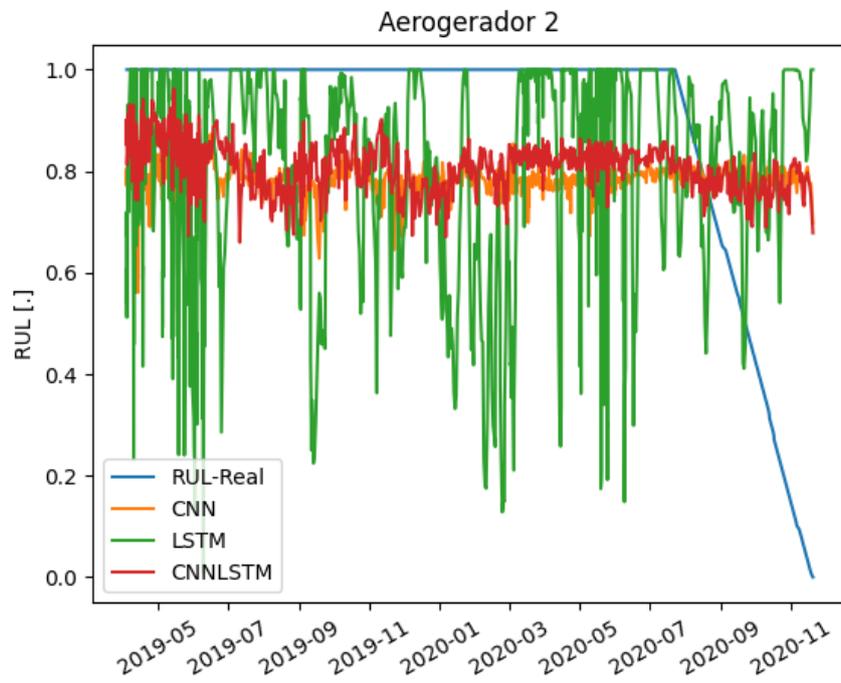
Tabela 6 – Resultados do MAE para os modelo treinados com o Aerogerador 1.

	LSTM	CNN	CNN-LSTM
Aerogerador 2	0.22276	0.17388	0.18515
Aerogerador 3	0.24529	0.10224	0.20490
Aerogerador 4	0.22434	0.19737	0.21723

Para proporcionar uma análise visual, as Figuras 18 - 20 mostram o prognóstico da RUL ao longo do tempo para cada modelo proposto. É notável que a RUL prevista pelo modelo LSTM tende a acompanhar mais de perto a degradação observada.

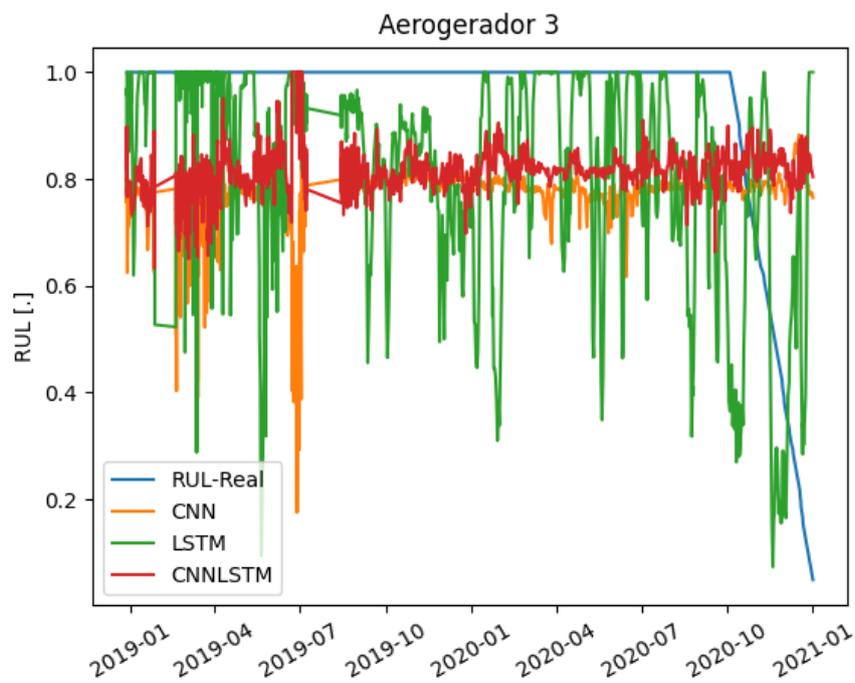
Quanto aos modelos baseados em CNN, é evidente que, em todos os casos, a RUL se estabiliza em uma média de aproximadamente 0,8. Considerando que essa máquina está em operação há um longo período, uma possível explicação para esse comportamento pode estar relacionada à identificação de algum tipo de fadiga no modelo.

Figura 18 – RUL de saída para o Aerogerador 2 considerando o Aerogerador 1



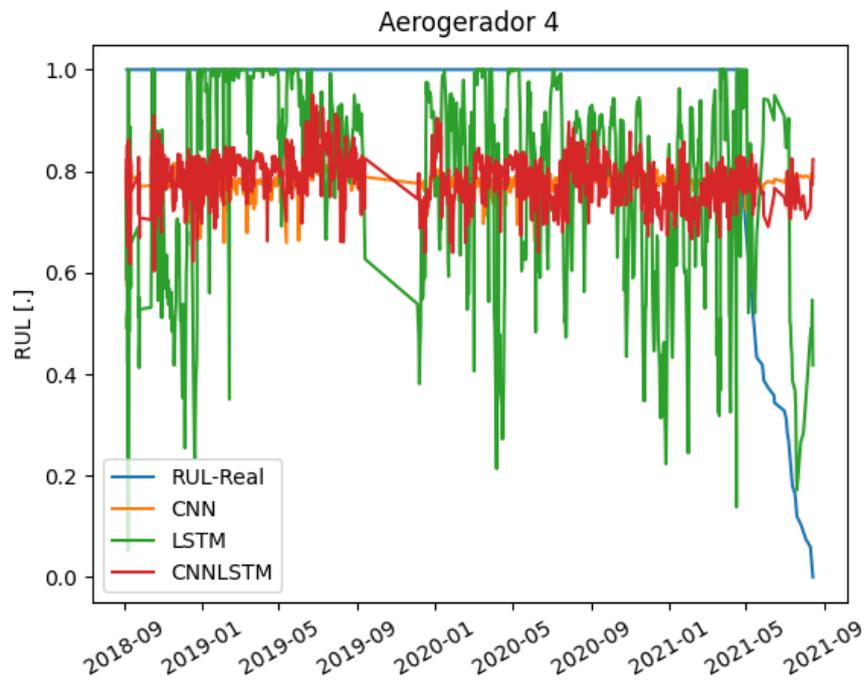
Fonte: o autor (2024)

Figura 19 – RUL de saída para o Aerogerador 3 considerando o Aerogerador 1



Fonte: o autor (2024)

Figura 20 – RUL de saída para o Aerogerador 4 considerando o Aerogerador 1



Fonte: o autor (2024)

Dessa forma, observa-se que os modelos CNN e CNN-LSTM apresentam os menores erros obtidos por meio da metodologia, enquanto o modelo LSTM demonstra uma tendência a seguir a degradação. Nesse contexto, a combinação de ambas as abordagens pode gerar resultados mais acurados.

5.4 ESTUDO DE CASO 2: MANUTENÇÃO DA *GEARBOX*

Ao treinar os modelos com dados das máquinas que realizaram a manutenção após detectar um deslocamento no rolamento do planetário, houve maior dificuldade na identificação da degradação dos aerogeradores. As Tabelas 7 e 8 mostram, respectivamente, o RMSE e o MAE dos modelos associados às previsões da RUL resultantes da implementação do modelo. Nota-se que os RMSE associados às previsões para o Aerogerador 1 foram menores ao utilizar as redes LSTM. Em contrapartida, para os demais aerogeradores, os modelos baseados em CNN-LSTM apresentaram melhores resultados.

Uma análise gráfica das previsões pode ser vista nas Figuras 21-23. Para o Aerogerador 1, observa-se que o modelo LSTM indicou uma degradação maior ao considerar a aplicação dessa metodologia. Nesse caso, a informação sobre a vida útil é observada 5 meses antes da

Tabela 7 – Resultados do RMSE para os modelo treinados com o AeroGerador 2.

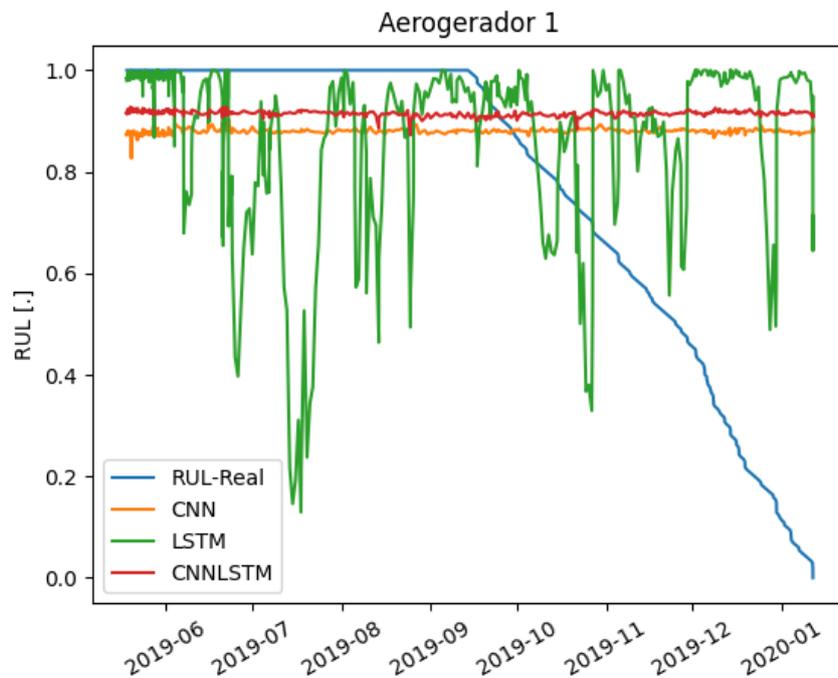
	LSTM	CNN	CNN-LSTM
AeroGerador 1	0.28729	0.32125	0.29363
AeroGerador 3	0.15467	0.23970	0.13185
AeroGerador 4	0.14877	0.14591	0.13301

Tabela 8 – Resultados do MAE para os modelo treinados com o AeroGerador 2.

	LSTM	CNN	CNN-LSTM
AeroGerador 1	0.20837	0.18784	0.19072
AeroGerador 3	0.12746	0.10528	0.09227
AeroGerador 4	0.12488	0.07932	0.09875

data de manutenção. Já para os AeroGeradores 3 e 4, o modelo não foi capaz de acompanhar a degradação. Contudo, para o AeroGerador 3, nota-se um decaimento na RUL entre janeiro e julho de 2019, períodos em que a máquina permaneceu parada por alguns dias. Isso pode indicar que o modelo identificou alguma degradação que não foi sinalizada pelo histórico de manutenção.

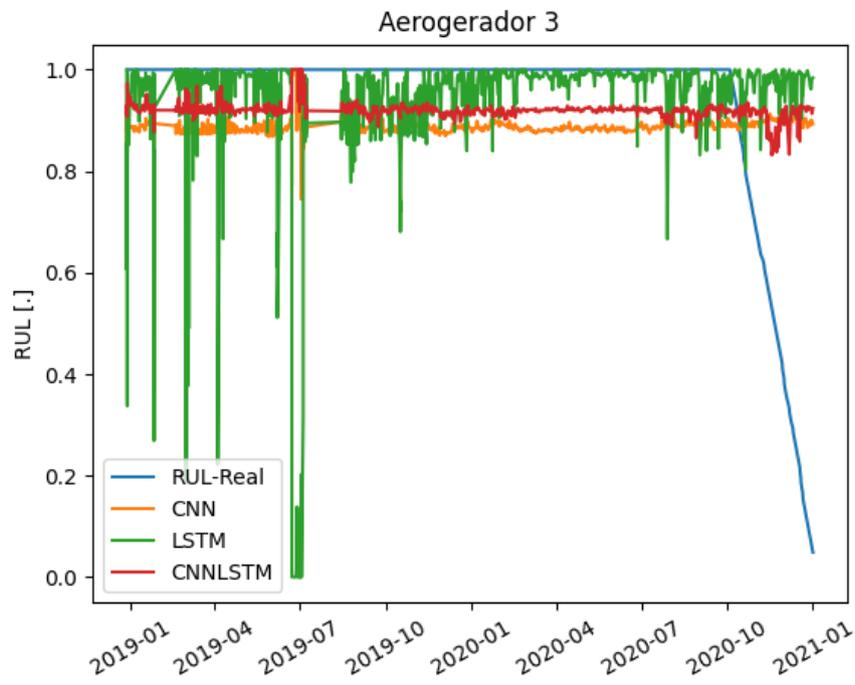
Figura 21 – RUL de saída para o AeroGerador 1 considerando o AeroGerador 2



Fonte: o autor (2024)

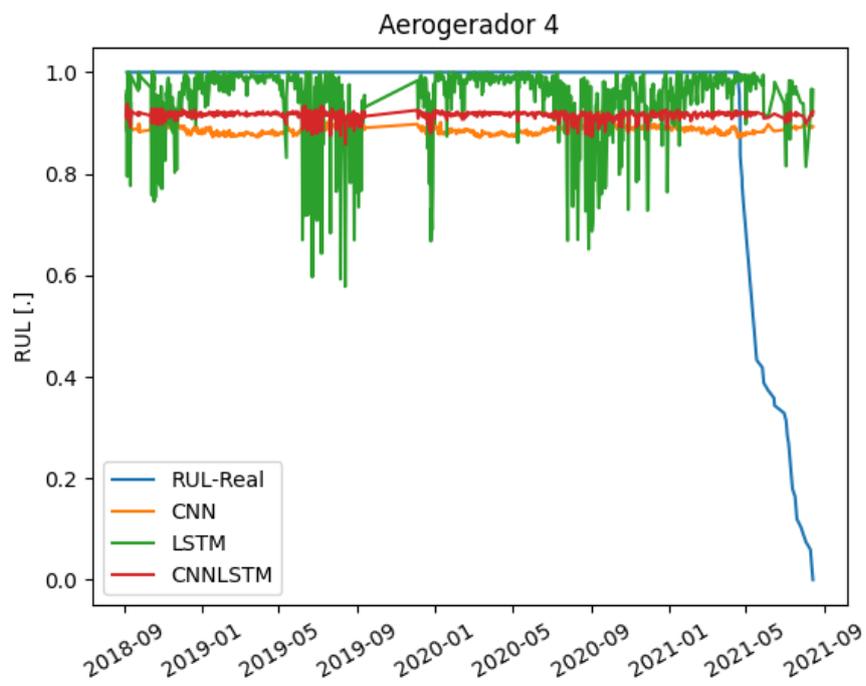
Tomando como referência o AeroGerador 3, as Tabelas 9 e 10 apresentam o RMSE e o MAE, respectivamente, para cada aerogerador. É possível observar que, para esse caso, o

Figura 22 – RUL de saída para o Aerogerador 3 considerando o Aerogerador 2



Fonte: o autor (2024)

Figura 23 – RUL de saída para o Aerogerador 4 considerando o Aerogerador 2



Fonte: o autor (2024)

modelo LSTM se apresentou como o mais promissor dentre eles, enquanto, para os demais, essas informações ficaram a cargo das CNN e CNN-LSTM.

Tabela 9 – Resultados do RMSE para os modelo treinados com o Aerogerador 3.

	LSTM	CNN	CNN-LSTM
Aerogerador 1	0.29958	0.307818	0.29903
Aerogerador 2	0.15317	0.20435	0.15399
Aerogerador 4	0.12149	0.11966	0.12472

Tabela 10 – Resultados do MAE para os modelo treinados com o Aerogerador 3.

	LSTM	CNN	CNN-LSTM
Aerogerador 1	0.17653	0.15705	0.18108
Aerogerador 2	0.08179	0.09333	0.08732
Aerogerador 4	0.07048	0.03541	0.07490

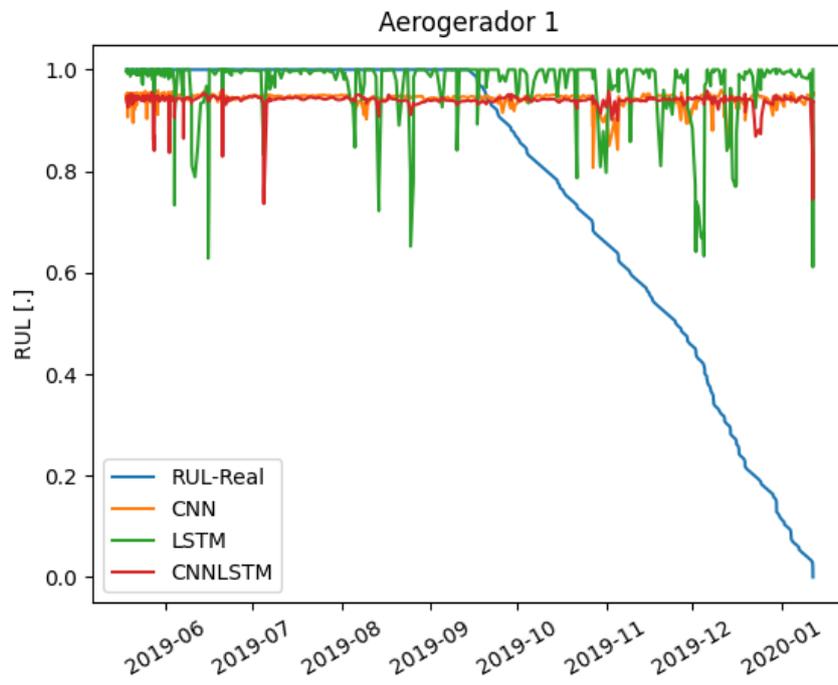
A partir da representação gráfica da RUL, mostrada nas Figuras 24 a 26, nota-se que os modelos apresentaram maior dificuldade em acompanhar o decaimento da RUL. Para o Aerogerador 1, é possível observar uma tendência no decaimento da RUL dois meses antes da falha conhecida, mas seu valor atinge, no máximo, 60% da condição da máquina. Um caso semelhante ocorre ao observar o Aerogerador 2, onde a degradação da RUL tende a acompanhar o decaimento nos 4 meses que antecedem a falha. Para o Aerogerador 4, a degradação observada pelos modelos não foi suficiente para o prognóstico, atingindo uma vida útil de aproximadamente 0,8.

Por fim, a última análise é feita a partir do Aerogerador 4. As Tabelas 11 e 12 apresentam os resultados do RMSE e MAE da RUL para esse caso. Para o Aerogerador 1, o modelo que apresentou menor erro foi o CNN-LSTM, enquanto que, para os demais, os melhores resultados foram obtidos a partir da CNN. Os modelos LSTM mostraram-se os menos eficazes dentre todos os casos. Esse fato pode prejudicar o resultado final, uma vez que esse modelo geralmente acompanha a tendência da degradação dos dados.

Tabela 11 – Resultados do RMSE para os modelo treinados com o Aerogerador 4.

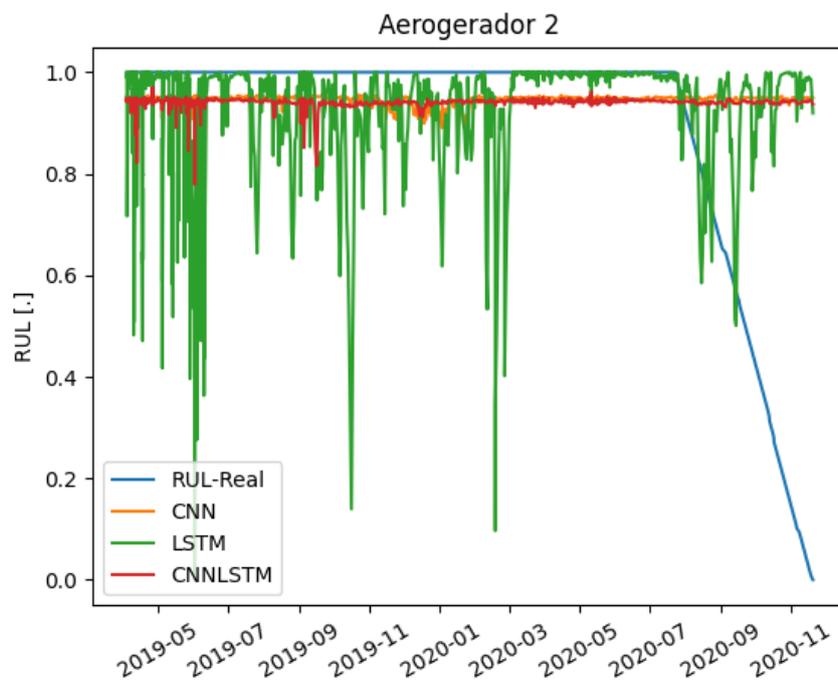
	LSTM	CNN	CNN-LSTM
Aerogerador 1	0.29718	0.32556	0.29144
Aerogerador 2	0.25490	0.156232	0.22715
Aerogerador 3	0.25048	0.12628	0.15144

Figura 24 – RUL de saída para o Aerogerador 1 considerando o Aerogerador 3



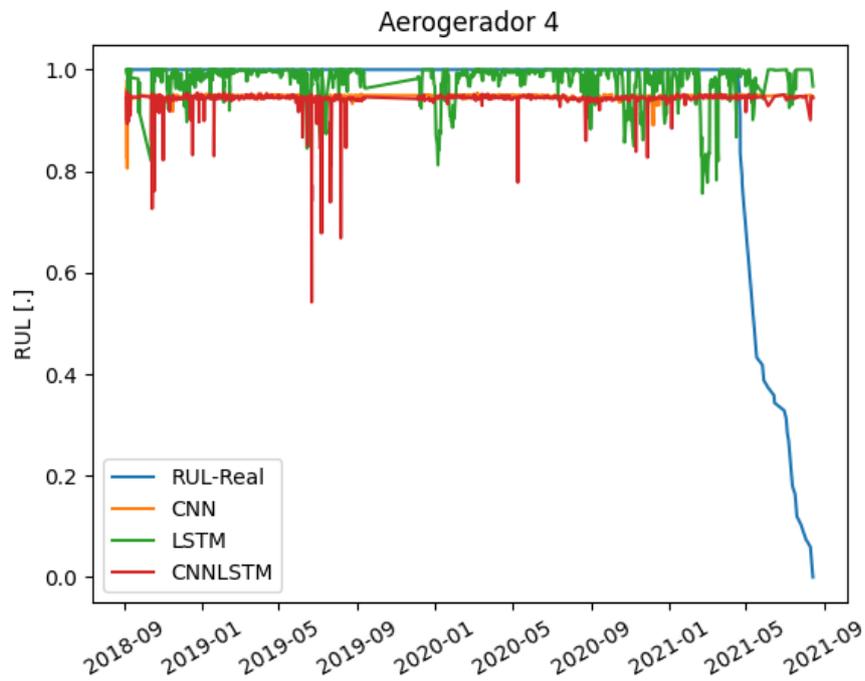
Fonte: o autor (2024)

Figura 25 – RUL de saída para o Aerogerador 2 considerando o Aerogerador 3



Fonte: o autor (2024)

Figura 26 – RUL de saída para o Aerogerador 4 considerando o Aerogerador 3



Fonte: o autor (2024)

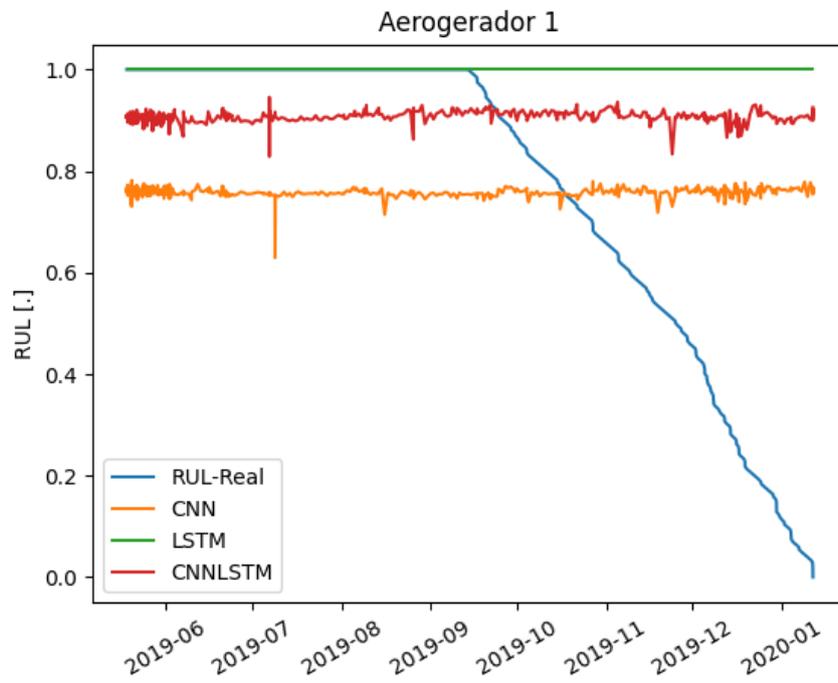
Tabela 12 – Resultados do MAE para os modelo treinados com o Aerogerador 4.

	LSTM	CNN	CNN-LSTM
Aerogerador 1	0.26645	0.15859	0.19618
Aerogerador 2	0.24634	0.036466	0.21279
Aerogerador 3	0.24514	0.02502	0.12472

As Figuras 27-29 mostram a degradação da RUL ao longo do tempo, a partir do treinamento com o Aerogerador 4. Nota-se, inicialmente, que as redes LSTM geraram como saída valores constantes, o que prejudica a previsão, uma vez que a tendência de degradação geralmente é mais facilmente observada por esse modelo. Para os Aerogeradores 1 e 2, as saídas das redes CNN e CNN-LSTM também permaneceram praticamente constantes, com variações mais acentuadas para o Aerogerador 2. Na análise do Aerogerador 3, observa-se que o modelo CNN-LSTM apresenta uma degradação significativa no período próximo a julho de 2019 (antes de uma pausa na operação da máquina), atingindo valores de RUL próximos a 0,7 antes da parada.

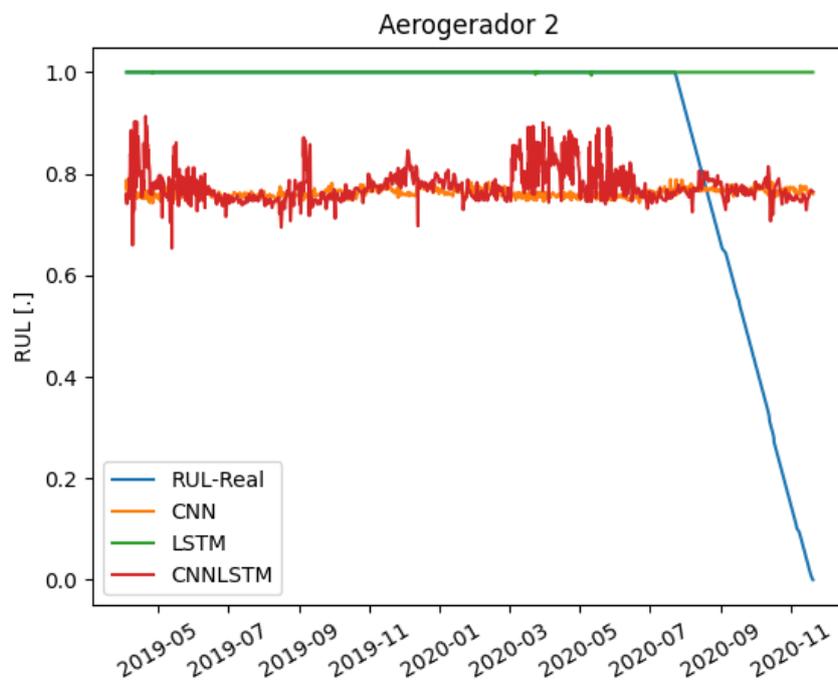
A partir dos resultados obtidos neste tópico, é possível concluir que o treinamento da RUL com máquinas já em operação apresenta um enorme desafio para a previsão da RUL. Devido à ausência de informações provenientes de uma máquina saudável, a identificação da

Figura 27 – RUL de saída para o Aerogerador 1 considerando o Aerogerador 4



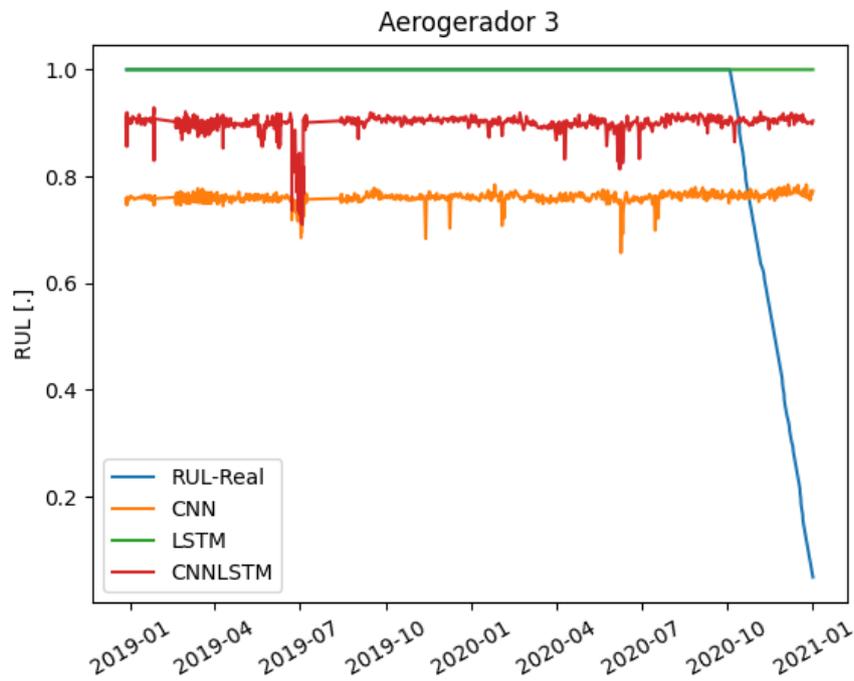
Fonte: o autor (2024)

Figura 28 – RUL de saída para o Aerogerador 2 considerando o Aerogerador 4



Fonte: o autor (2024)

Figura 29 – RUL de saída para o Aerogerador 3 considerando o Aerogerador 4



Fonte: o autor (2024)

degradação da vida útil remanescente dos rolamentos do aerogerador pode rotular partes em que a degradação começou como se fossem de uma máquina sadia.

Apesar disso, nota-se que os resultados obtidos pela aplicação da metodologia conseguiram identificar a degradação dos rolamentos da gearbox quando treinados com os Aerogeradores 2 e 3. Além disso, observa-se que a metodologia de rotulação se mostrou promissora para o treinamento dos modelos de aprendizagem profunda.

5.5 COMBINAÇÃO

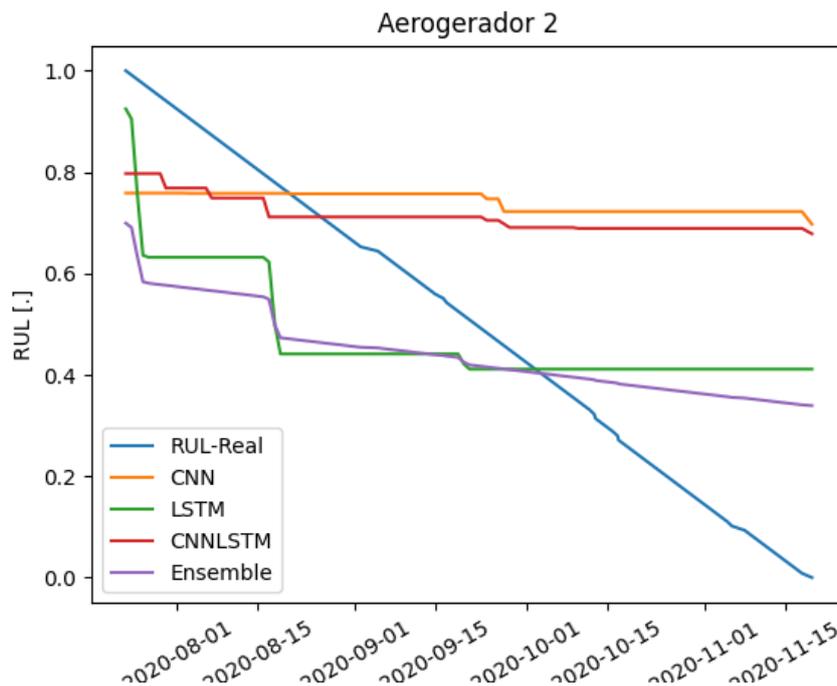
Após o treinamento das redes neurais profundas, foi selecionado um intervalo de tempo que consiste em 120 dias antes da falha até a data de parada. Em seguida, foi aplicada a suavização do decaimento da RUL para cada aerogerador treinado. Por fim, foi realizado o treinamento da MLP considerando o decaimento proposto.

Na Tabela 5.5, são apresentados os resultados da Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE) e do coeficiente de correlação de Pearson. Nota-se que, para o Aerogerador 2, a combinação dos modelos se apresentou como a melhor opção, tendo valores de MSE e RMSE de 0,19516 e 0,22231, respectivamente. Já para os Aerogeradores 3 e 4, apesar

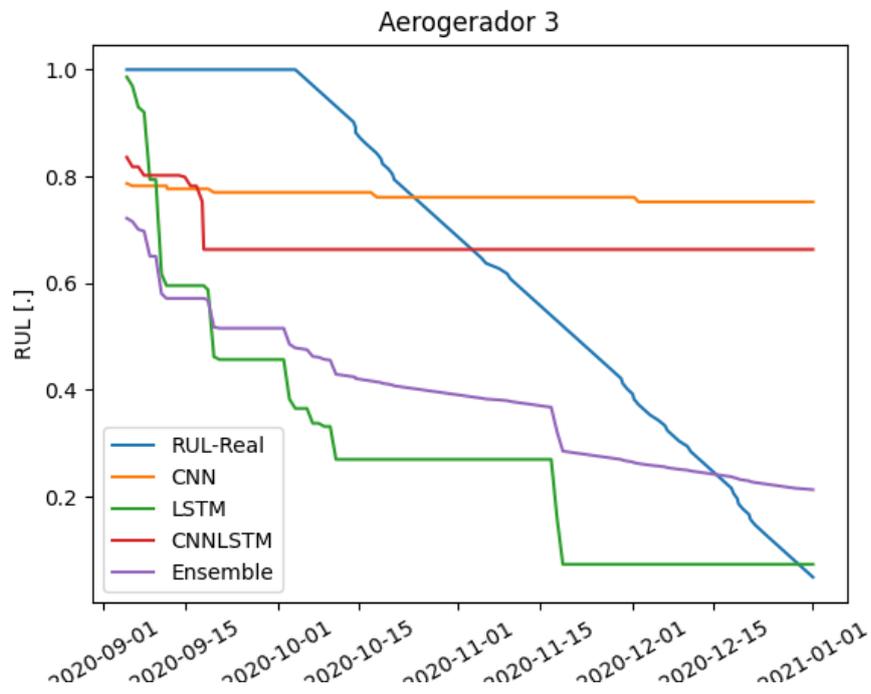
da correlação alta, as combinações ficaram abaixo da CNN-LSTM e da CNN, respectivamente. Além disso, a correlação em todos os casos ficou acima de 0,92, o que indica uma grande relação entre o decaimento da RUL e o predito pelos modelos. Dessa forma, pode-se estimar que a combinação dos modelos conseguiu obter informações sobre a degradação que não foram possíveis com os modelos isolados.

Em relação à análise visual, mostrada nas Figuras 30 a 32, é possível observar que os modelos *ensemble* conseguiram acompanhar o decaimento da RUL em todos os casos, o que está de acordo com o esperado pela correlação descrita anteriormente. Nota-se nas imagens que o decaimento proposto pelas redes CNN e CNN-LSTM isoladas não apresenta um decaimento aparente ao longo do tempo. Contudo, ao combinar os resultados, é possível observar a degradação da RUL em todos os casos apresentados.

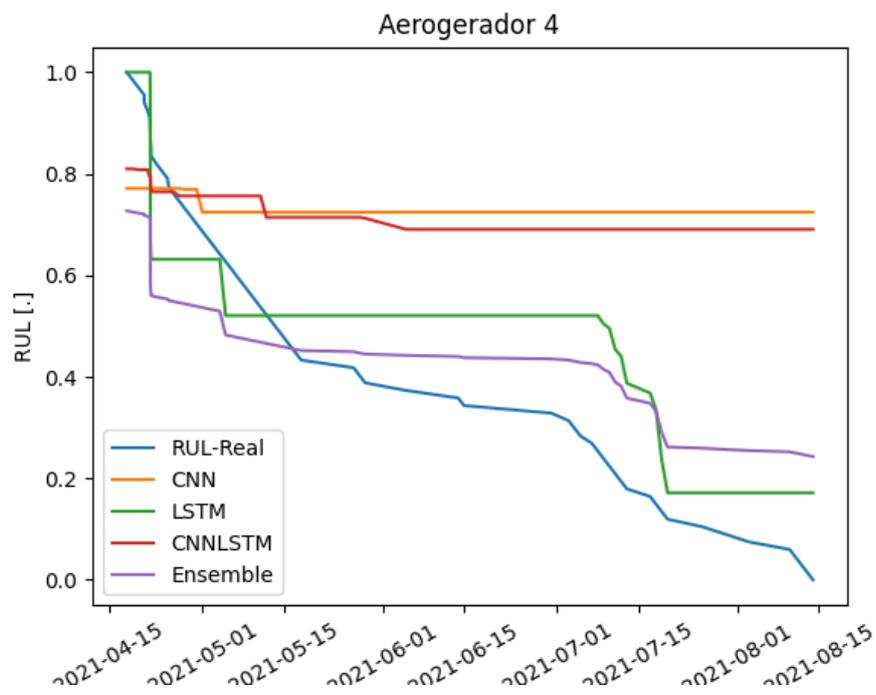
Figura 30 – *Ensemble* para o Aerogerador 2 considerando o Aerogerador 1



Fonte: o autor (2024)

Figura 31 – *Ensemble* para o Aerogerador 3 considerando o Aerogerador 1

Fonte: o autor (2024)

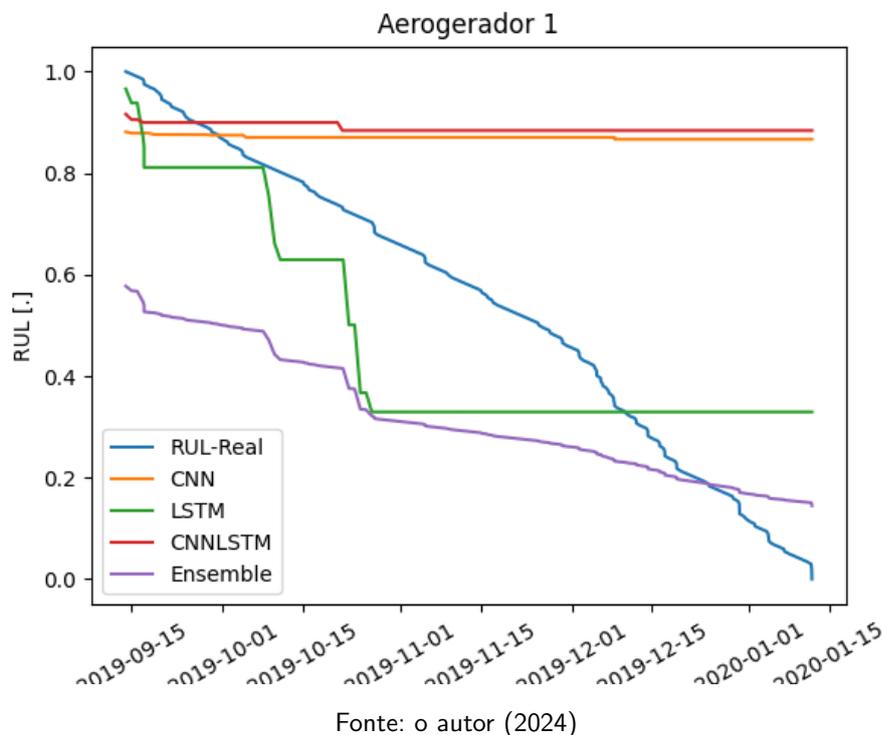
Figura 32 – *Ensemble* para o Aerogerador 4 considerando o Aerogerador 1

Fonte: o autor (2024)

Tomando como estudo o treinamento sobre o Aerogerador 2, os resultados das métricas obtidas a partir dela está apresentado na Tabela 5.5. É possível observar que as máquinas de testes apresentaram os erros mais baixos e maior correlação quando considerado o modelo *Ensemble*. Para o Aerogerador 1, os menores valores de RMSE e MAE se encontram com o modelo LSTM, seguidos pela combinação. Nesse estudo, é possível observar que a correlação obtida está acima de 0,96, o que indica alta relação entre o decaimento da RUL real com o modelo *Ensemble*.

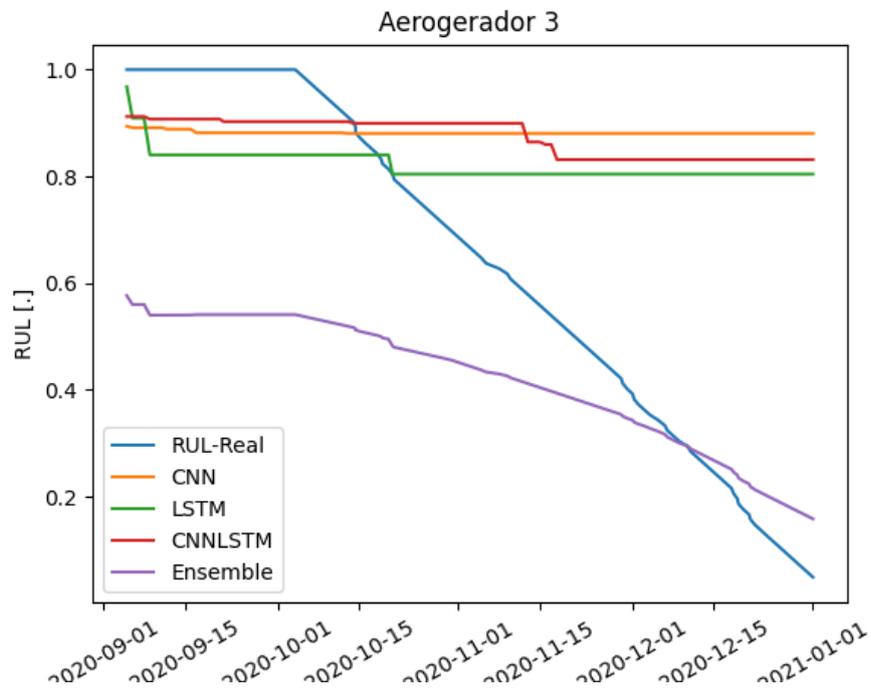
Além disso, a análise visual apresentada nas Figuras 33 - 35 mostram o decaimento da RUL dos modelos com o valor real. Para o Aerogerador 1, nota-se que os modelos LSTM e *Ensemble* decaem de forma acentuada acompanhando a RUL. Já para os Aerogeradores 3 e 4, nenhum modelo puro conseguiu acompanhar o decaimento, sendo tarefa do modelo *Ensemble*. Desse modo, pode-se observar que mesmo que os modelo não apresente decaimento, quando combinados, a resposta se apresenta mais acurada para realizar o prognóstico.

Figura 33 – *Ensemble* para o Aerogerador 1 considerando o Aerogerador 2

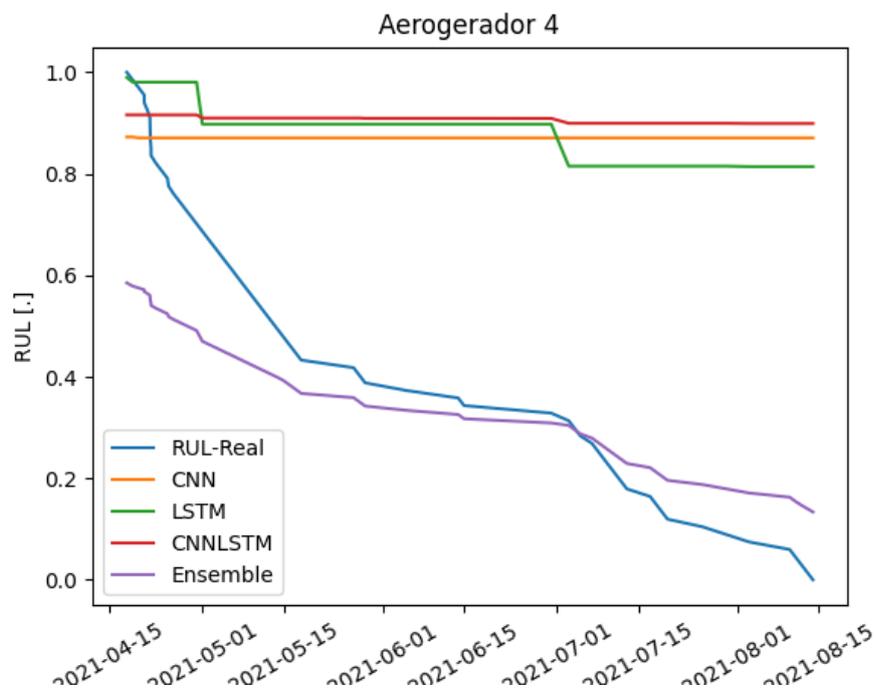


A Tabela 5.5 mostra os resultados das métricas obtidas a partir da aplicação da metodologia do modelo *Ensemble* para o Aerogerador 3. Neste caso, o modelo que apresentou os resultados mais acurados foram proveniente da combinação.

As Figuras 36 - 38 mostram o decaimento da RUL em relação a cada modelo. Apesar da

Figura 34 – *Ensemble* para o Aerogerador 3 considerando o Aerogerador 2

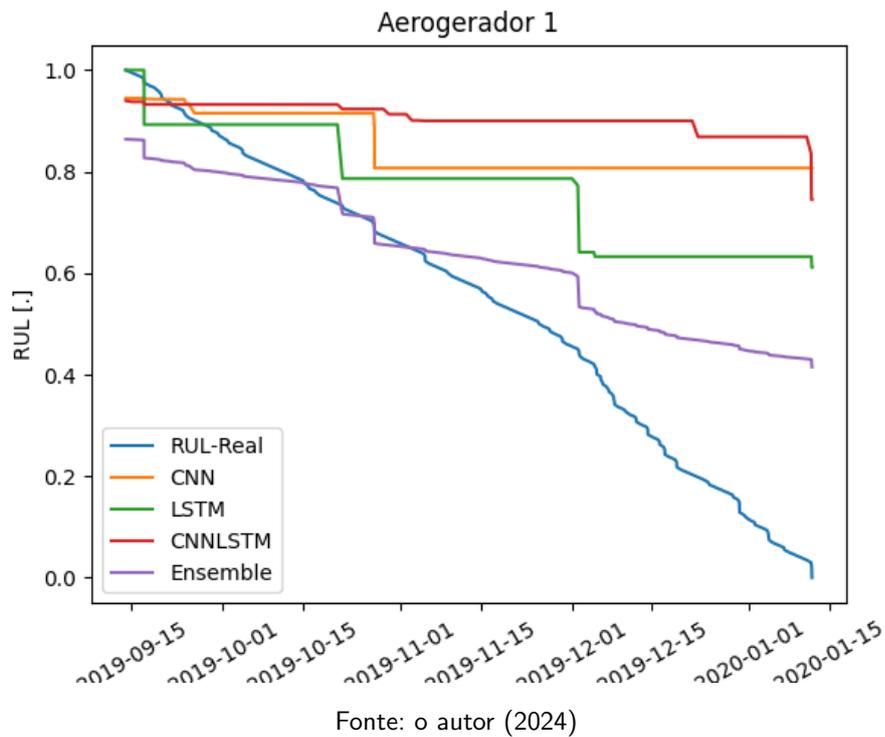
Fonte: o autor (2024)

Figura 35 – *Ensemble* para o Aerogerador 4 considerando o Aerogerador 2

Fonte: o autor (2024)

alta correlação, o decaimento deste caso não decaiu a valores abaixo de 0,4, diferente dos casos anteriores. Isso pode ter ocorrido devido aos modelos isolados não decaírem de forma acentuada antes da suavização das saídas.

Figura 36 – *Ensemble* para o Aerogerador 1 considerando o Aerogerador 3

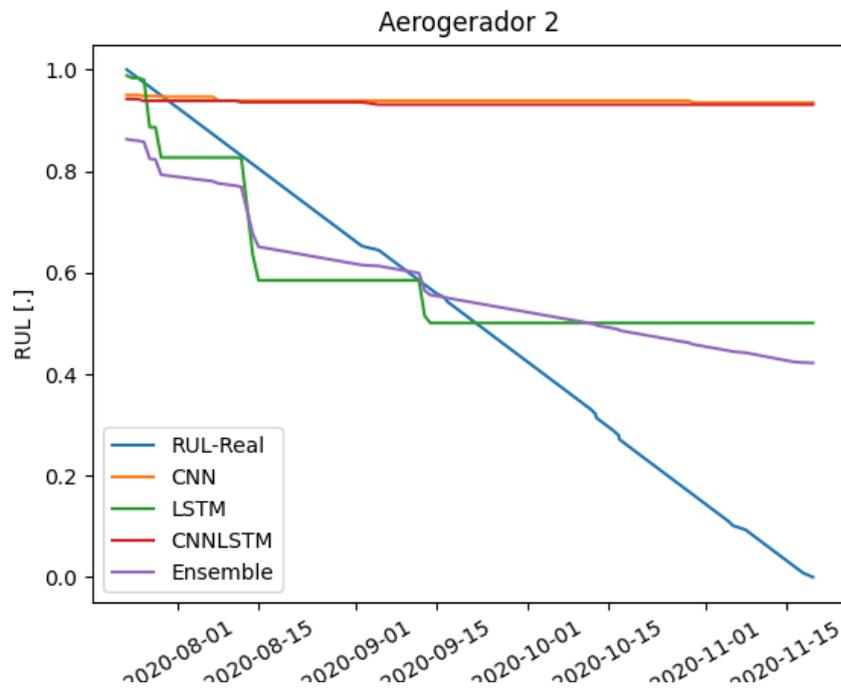


Por fim, a última análise foi realizada sobre o Aerogerador 4. As Figuras 39 - 41 mostram o prognóstico da RUL considerando os modelos propostos. Nesse caso, as saídas de cada modelo se apresentaram de forma praticamente constante. Por esse motivo, mesmo ao observar o decaimento, não foi possível obter uma análise que descrevesse de forma precisa o decaimento da RUL, mesmo para o modelo *Ensemble*. Assim, a análise de erros para este estudo foi descartada, uma vez que não correspondeu ao prognóstico desejado.

Por fim, a última análise foi realizada sobre o Aerogerador 4. As Figuras 39 - 41 mostram o prognóstico da RUL considerando os modelos propostos. Para esse caso, as saídas de cada modelo se apresentaram de forma praticamente constante. Por esse fato, quando observado o decaimento, mesmo para o modelo *Ensemble*, não foi possível obter nenhuma análise que descrevesse de forma acurada o decaimento da RUL. Por esse motivo, a análise de erros para esse estudo foi descartada, uma vez que não correspondeu ao prognóstico desejado.

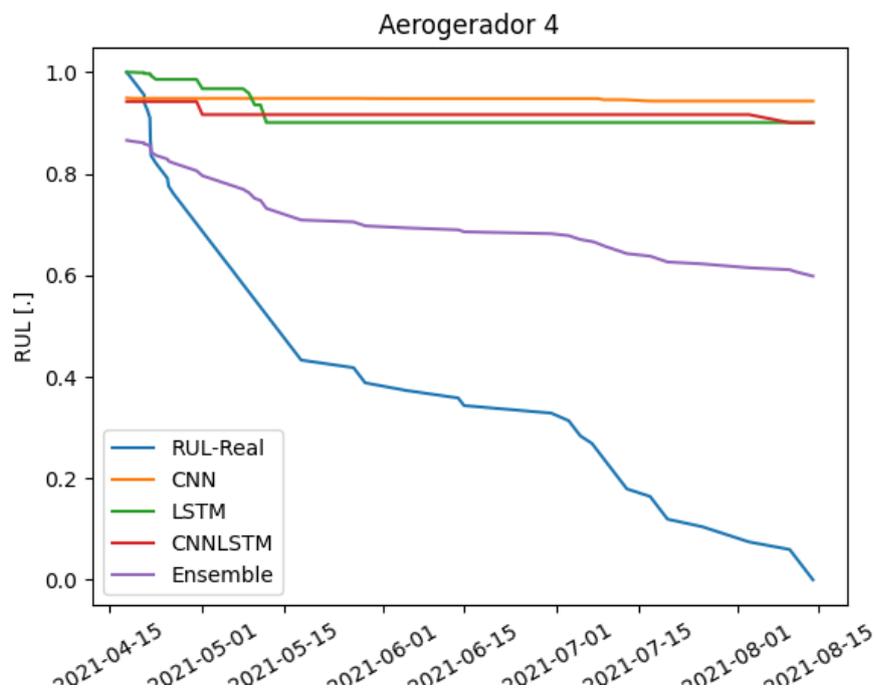
Em suma, observa-se que a aplicação da metodologia proposta para suavização e combinação dos modelos se mostrou bastante promissora, e seus resultados indicam que, a partir

Figura 37 – *Ensemble* para o Aerogerador 2 considerando o Aerogerador 3



Fonte: o autor (2024)

Figura 38 – *Ensemble* para o Aerogerador 4 considerando o Aerogerador 3



Fonte: o autor (2024)

do histórico, é possível estimar a vida útil remanescente dos rolamentos do aerogerador com pelo menos 60 dias de antecedência. Nota-se também que os valores da RUL próximos à falha não atingem o valor nulo. Isso realmente reflete a realidade, uma vez que isso indicaria a falha total do rolamento e geraria custos de O&M bastante elevados.

Figura 39 – *Ensemble* para o Aerogerador 1 considerando o Aerogerador 4

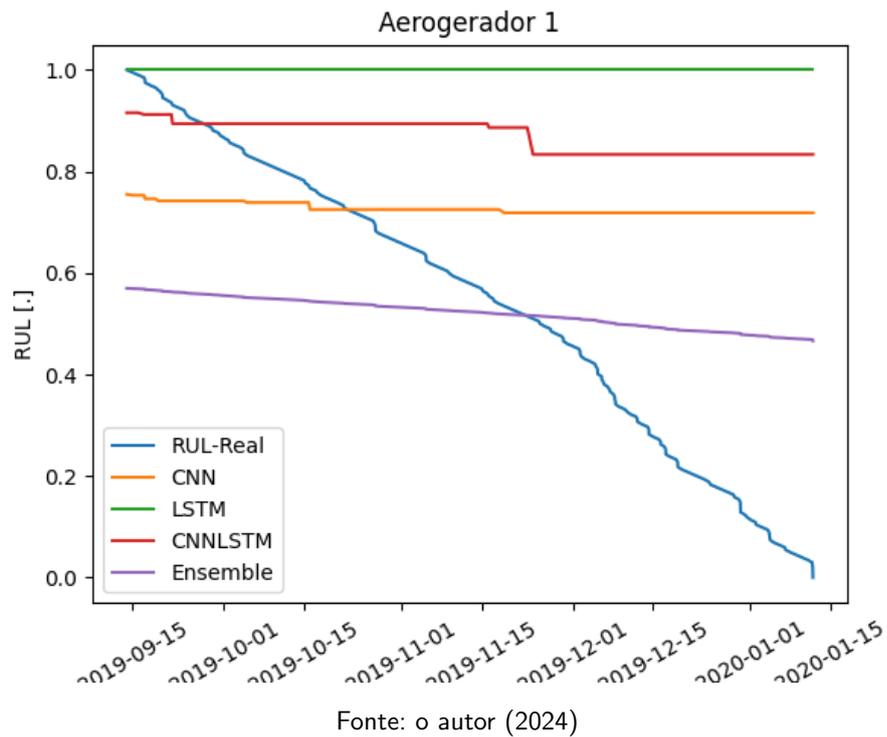
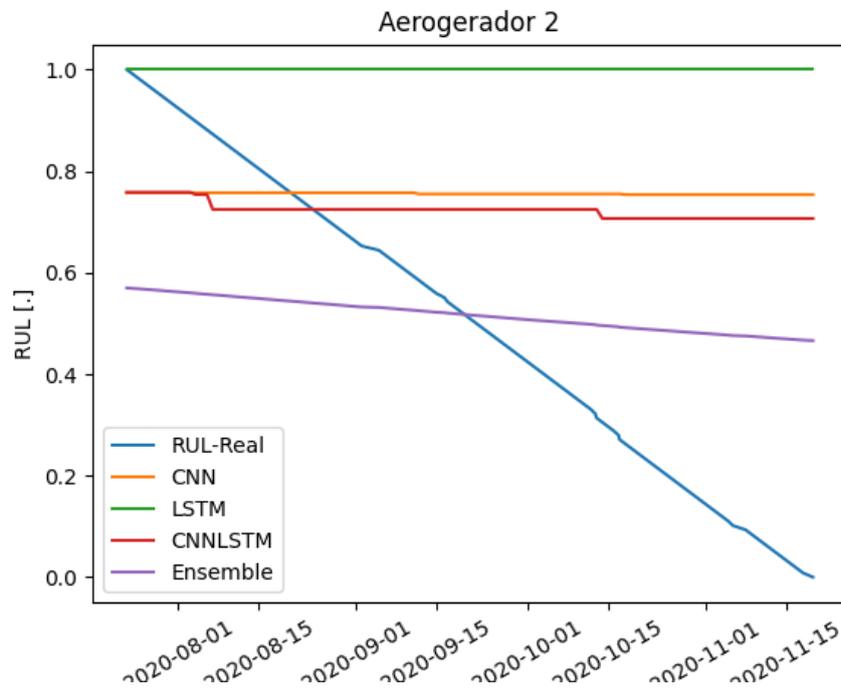
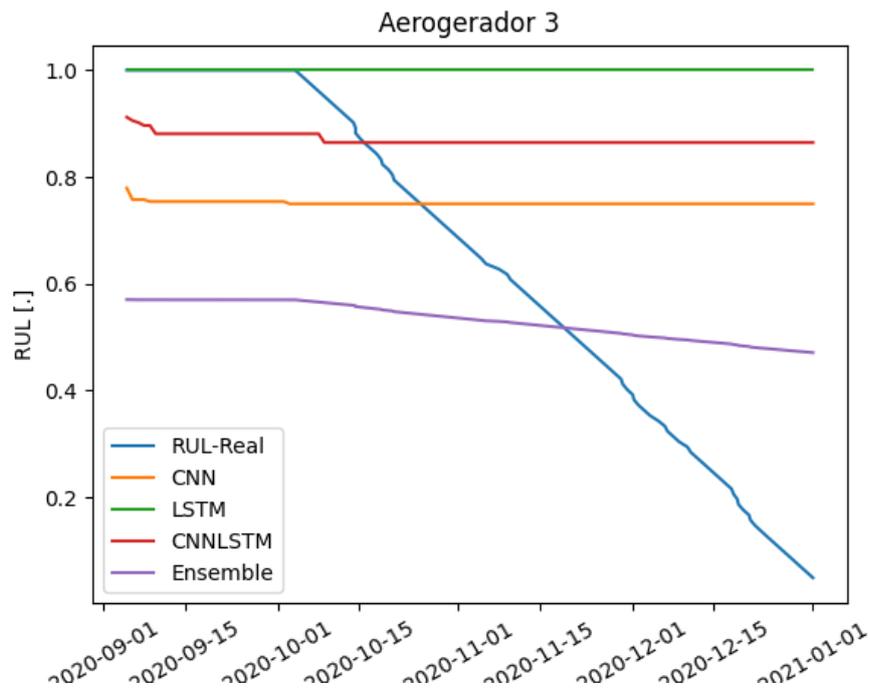


Figura 40 – *Ensemble* para o Aerogerador 2 considerando o Aerogerador 4

Fonte: o autor (2024)

Figura 41 – *Ensemble* para o Aerogerador 3 considerando o Aerogerador 4

Fonte: o autor (2024)

Tabela 13 – Métricas do modelo *ensemble* treinados com o Aerogerador 1.

Modelo Métrica	CNN			LSTM			CNN-LSTM			Ensemble		
	MAE	RMSE	Corr	MAE	RMSE	Corr	MAE	RMSE	Corr	MAE	RMSE	Corr
Aerogerador 2	0.3008	0.3658	0.8826	0.1975	0.2238	0.7571	0.2740	0.3397	0.8570	0.1951	0.2223	0.9433
Aerogerador 3	0.2761	0.329	0.8980	0.3681	0.4119	0.8215	0.2643	0.3037	0.3952	0.284	0.3282	0.9275
Aerogerador 4	0.2937	0.3649	0.8019	0.1189	0.1407	0.9037	0.2795	0.3446	0.9488	0.1560	0.1725	0.9587

Tabela 14 – Métricas do modelo *ensemble* treinados com o Aerogerador 2.

Modelo Métrica	CNN			LSTM			CNN-LSTM			Ensemble		
	MAE	RMSE	Corr	MAE	RMSE	Corr	MAE	RMSE	Corr	MAE	RMSE	Corr
Aerogerador 1	0.3858	0.4684	0.8902	0.1580	0.1863	0.7909	0.3984	0.48134	0.7625	0.2221	0.2616	0.9612
Aerogerador 3	0.3057	0.3931	0.4705	0.2727	0.3468	0.6932	0.2838	0.3648	0.9187	0.2477	0.3007	0.9921
Aerogerador 4	0.3891	0.4725	0.2926	0.3970	0.4592	0.9432	0.4165	0.4988	0.9389	0.1559	0.1958	0.9956

Tabela 15 – Métricas do modelo *ensemble* treinados com o Aerogerador 3.

Modelo Métrica	CNN			LSTM			CNN-LSTM			Ensemble		
	MAE	RMSE	Corr	MAE	RMSE	Corr	MAE	RMSE	Corr	MAE	RMSE	Corr
Aerogerador 1	0.3470	0.4235	0.8176	0.2551	0.3107	0.9367	0.4049	0.7862	0.7625	0.1478	0.1901	0.9842
Aerogerador 3	0.4424	0.5255	0.7676	0.1661	0.2181	0.7980	0.4374	0.5205	0.8395	0.1557	0.1933	0.9567
Aerogerador 4	0.4507	0.5338	0.7845	0.4389	0.5077	0.9123	0.4274	0.5084	0.8559	0.2587	0.3145	0.9968

6 CONCLUSÕES E PERSPECTIVAS

Neste trabalho, foi proposta uma metodologia para o prognóstico da RUL dos rolamentos de aerogeradores, com o objetivo de minimizar os custos de O&M e otimizar o uso dos componentes a partir do monitoramento das condições de operação. De modo específico, realizar o prognóstico no planetário da caixa de engrenagem, componente essa que apresenta quantidade de falhas numerosas.

Em primeiro lugar, observa-se uma dificuldade na rotulação dos dados devido à ausência de informações no início da operação e à impossibilidade de operar a máquina até o fim da sua vida útil. Portanto, a proposta de uma metodologia que analisa a degradação, relacionando-a à quantidade de dias até a falha com base no histórico de manutenção disponível, mostrou-se bastante promissora. A partir dela, foi possível identificar a relação de degradação com mais de 60 dias de antecedência, o que permite uma programação para manutenção com antecedência.

Em seguida, foram aplicados modelos de aprendizagem profunda para o prognóstico da RUL. Nesse sentido, duas estratégias de treinamento foram implementadas. No primeiro caso, utilizou-se como treinamento o aerogerador que, após a manutenção, teve a troca da *gearbox*. Nesse contexto, a RUL para os dados pós-manutenção pode ser considerada saudável. Por esse motivo, os modelos foram capazes de observar o comportamento das máquinas em estado saudável e com falhas, principalmente os resultados provenientes do modelo LSTM. Assim, é possível notar a degradação mais acentuada dos modelos próximos à falha quando testados nas demais máquinas.

Por outro lado, na estratégia que utilizou aerogeradores nos quais a troca da *gearbox* não foi sinalizada, os modelos apresentaram maior dificuldade para realizar o prognóstico. Em alguns casos, a RUL mínima foi de 0,8 (o que indica que a saúde da máquina está em 80% da original) enquanto a máquina se encontrava próxima da falha. Portanto, conclui-se que a falta de observação da vibração de um componente completamente saudável prejudica a previsão dos modelos.

Com o objetivo de contornar esse problema, foi aplicada a estratégia de suavização dos resultados e um modelo de combinação entre eles. Como previsão, observa-se que, mesmo em modelos onde não é possível observar a degradação do rolamento (com RUL constante), quando combinados, a degradação pode ser identificada.

Outro ponto importante da metodologia proposta é que, a partir das informações obtidas

de uma única máquina, é possível realizar o prognóstico da RUL da *gearbox* de diferentes aerogeradores, desde que tenham a mesma configuração de fábrica. Desse modo, o monitoramento constante e a aplicação da previsão a cada amostra podem indicar o comportamento da degradação dos rolamentos.

Como perspectiva futura, busca-se expandir o estudo para demais componentes do aerogerador, como o eixo principal e o gerador, ou mesmo para outros rolamentos contidos na *gearbox*. Além disso, o acoplamento de modelos de prognóstico com estratégias propostas para a detecção de anomalias pode ser bastante promissor para a melhoria da acurácia dos modelos propostos. Outras análises que podem melhorar o desempenho do estudo proposto podem ser encontradas em dados externos à vibração, como os armazenados no sistema SCADA, além de um estudo mais aprofundado nas features que são extraídas pelos modelos.

REFERÊNCIAS

- AHMAD, R.; KAMARUDDIN, S. An overview of time-based and condition-based maintenance in industrial application. *Computers Industrial Engineering*, v. 63, n. 1, p. 135–149, 2012. ISSN 0360-8352. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360835212000484>>.
- BADIHI, H.; ZHANG, Y.; JIANG, B.; PILLAY, P.; RAKHEJA, S. A comprehensive review on signal-based and model-based condition monitoring of wind turbines: Fault diagnosis and lifetime prognosis. *Proceedings of the IEEE*, v. 110, n. 6, p. 754–806, 2022.
- BARU, A.; JOHNSON, M. R. *Three Ways to Estimate Remaining Useful Life for Predictive Maintenance*. 2023. Disponível em: <<https://www.mathworks.com/company/technical-articles/three-ways-to-estimate-remaining-useful-life-for-predictive-maintenance.html>>. Acesso em: 27 jun. 2024.
- BERMEO-AYERBE, M. A.; COCQUEMPOT, V.; OCAMPO-MARTINEZ, C.; DIAZ-ROZO, J. Remaining useful life estimation of ball-bearings based on motor current signature analysis. *Reliability Engineering amp; System Safety*, Elsevier BV, v. 235, p. 109209, jul. 2023. ISSN 0951-8320. Disponível em: <<http://dx.doi.org/10.1016/j.ress.2023.109209>>.
- BEZERRA, C. C. A. Detecção de falhas em rolamentos de turbinas eólicas utilizando modelos de aprendizagem de máquina. *Trabalho de Conclusão de Curso. Universidade Federal de Pernambuco.*, 2019.
- BRIJDER, R.; HELSEN, S.; OMPUSUNGGU, A. P. Switching kalman filtering-based corrosion detection and prognostics for offshore wind-turbine structures. *Wind*, MDPI AG, v. 3, n. 1, p. 1–13, jan. 2023. ISSN 2674-032X. Disponível em: <<http://dx.doi.org/10.3390/wind3010001>>.
- CAMPO, S. M. del; SANDIN, F.; STRÖMBERGSSON, D. Dictionary learning approach to monitoring of wind turbine drivetrain bearings. *International Journal of Computational Intelligence Systems*, v. 14, p. 106–121, 2020. ISSN 1875-6883. Disponível em: <<https://doi.org/10.2991/ijcis.d.201105.001>>.
- CASTELLANI, F.; NATILI, F.; ASTOLFI, D.; VIDAL, Y. Wind turbine gearbox condition monitoring through the sequential analysis of industrial scada and vibration data. *Energy Reports*, Elsevier BV, v. 12, p. 750–761, dez. 2024. ISSN 2352-4847. Disponível em: <<http://dx.doi.org/10.1016/j.egy.2024.06.041>>.
- CORONADO, D.; FISCHER, K. *Condition Monitoring of Wind Turbines: State of the art, user experience and recommendation*. 2015.
- EPE. *Relatório Síntese*. 2024. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-819/topico-715/BEN_S%C3%ADntese_2024_PT.pdf>. Acesso em: 18 jun. 2024.
- GAO, Z.; LIU, X. An overview on fault diagnosis, prognosis and resilient control for wind turbine systems. *Processes*, v. 9, n. 2, 2021. ISSN 2227-9717. Disponível em: <<https://www.mdpi.com/2227-9717/9/2/300>>.

GUO, Y.; SHENG, S.; PHILLIPS, C.; KELLER, J.; VEERS, P.; WILLIAMS, L. A methodology for reliability assessment and prognosis of bearing axial cracking in wind turbine gearboxes. *Renewable and Sustainable Energy Reviews*, v. 127, p. 109888, 2020. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032120301817>>.

HAYKIN, S. *Neural Networks and Learning Machines*. Pearson, 2009. (Pearson International Edition). ISBN 9780131293762. Disponível em: <<https://books.google.com.br/books?id=KCwWOAAACAAJ>>.

HUANG, C.-G.; HUANG, H.-Z.; LI, Y.-F.; PENG, W. A novel deep convolutional neural network-bootstrap integrated method for rul prediction of rolling bearing. *Journal of Manufacturing Systems*, Elsevier BV, v. 61, p. 757–772, out. 2021. ISSN 0278-6125. Disponível em: <<http://dx.doi.org/10.1016/j.jmsy.2021.03.012>>.

HUANG, C.-G.; HUANG, H.-Z.; LI, Y.-F.; PENG, W. A novel deep convolutional neural network-bootstrap integrated method for rul prediction of rolling bearing. *Journal of Manufacturing Systems*, v. 61, p. 757–772, 2021. ISSN 0278-6125. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0278612521000674>>.

KORDESTANI, M.; REZAMAND, M.; ORCHARD, M.; CARRIVEAU, R.; TING, D.; SAIF, M. Planetary gear faults detection in wind turbine gearbox based on a ten years historical data from three wind farms. *IFAC-PapersOnLine*, Elsevier BV, v. 53, n. 2, p. 10318–10323, 2020. ISSN 2405-8963. Disponível em: <<http://dx.doi.org/10.1016/j.ifacol.2020.12.2767>>.

KUMAR, P.; RAOUF, I.; KIM, H. S. Review on prognostics and health management in smart factory: From conventional to deep learning perspectives. *Engineering Applications of Artificial Intelligence*, v. 126, p. 107126, 2023. ISSN 0952-1976. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197623013106>>.

LEITE, G. de N. P.; ARAUJO, A. M.; ROSAS, P. A. C. Prognostic techniques applied to maintenance of wind turbines: a concise and specific review. *Renewable and Sustainable Energy Reviews*, v. 81, p. 1917–1925, 2018. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032117309383>>.

LI, X.; ZHANG, W.; DING, Q. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering System Safety*, v. 182, p. 208–218, 2019. ISSN 0951-8320. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0951832018308299>>.

MA, Z.; ZHAO, M.; LUO, M.; GOU, C.; XU, G. An integrated monitoring scheme for wind turbine main bearing using acoustic emission. *Signal Processing*, v. 205, p. 108867, 2023. ISSN 0165-1684. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165168422004066>>.

MANNA, D. *HEALTH MONITORING FOR WIND TURBINES–DATASETS PROCESSING AND DEVELOPMENT OF RUL PROGNOSTICS*. Tese (Doutorado) — Politecnico di Torino, 2023.

MATHWORKS. *Predictive Maintenance with MATLAB*. 2018. Disponível em: <<https://www.mathworks.com/content/dam/mathworks/ebook/gated/predictive-maintenance-ebook-all-chapters.pdf>>. Acesso em: 07 out. 2024.

- MOHAMMED, O. D.; RANTATALO, M. Gear fault models and dynamics-based modelling for gear fault detection – a review. *Engineering Failure Analysis*, v. 117, p. 104798, 2020. ISSN 1350-6307. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630720307238>>.
- MORONEY, P. D.; VERMA, A. S. Durability and damage tolerance analysis approaches for wind turbine blade trailing edge life prediction: A technical review. *Energies*, v. 16, n. 24, 2023. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/16/24/7934>>.
- NECTOUX, P.; GOURIVEAU, R.; MEDJAHER, K.; RAMASSO, E.; CHEBEL-MORELLO, B.; ZERHOUNI, N.; VARNIER, C. PRONOSTIA : An experimental platform for bearings accelerated degradation tests. In: *IEEE International Conference on Prognostics and Health Management, PHM'12*. Denver, Colorado, United States: IEEE Catalog Number : CPF12PHM-CDR, 2012. sur CD ROM, p. 1–8. Disponível em: <<https://hal.science/hal-00719503>>.
- OWOLABI, O. I.; MADUSHELE, N.; ADEDEJI, P. A.; OLATUNJI, O. O. Fem and ann approaches to wind turbine gearbox monitoring and diagnosis: a mini review. *Journal of Reliable Intelligent Environments*, Springer Science and Business Media LLC, v. 9, n. 4, p. 399–419, jul. 2022. ISSN 2199-4676. Disponível em: <<http://dx.doi.org/10.1007/s40860-022-00183-4>>.
- PANDIT, R. K.; ASTOLFI, D.; CARDENAS, I. D. A review of predictive techniques used to support decision making for maintenance operations of wind turbines. *Energies*, MDPI AG, v. 16, n. 4, p. 1654, fev. 2023. ISSN 1996-1073. Disponível em: <<http://dx.doi.org/10.3390/en16041654>>.
- SAWALHI, N.; RANDALL, R. B. Gear parameter identification in a wind turbine gearbox using vibration signals. *Mechanical Systems and Signal Processing*, v. 42, n. 1, p. 368–376, 2014. ISSN 0888-3270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327013003920>>.
- SEJDIĆ, E.; DJUROVIĆ, I.; JIANG, J. Time–frequency feature representation using energy concentration: An overview of recent advances. *Digit. Signal Process.*, Elsevier BV, v. 19, n. 1, p. 153–183, jan. 2009.
- SHAHEEN, B. W.; NÉMETH, I. Performance monitoring of wind turbines gearbox utilising artificial neural networks — steps toward successful implementation of predictive maintenance strategy. *Processes*, MDPI AG, v. 11, n. 1, p. 269, jan. 2023. ISSN 2227-9717. Disponível em: <<http://dx.doi.org/10.3390/pr11010269>>.
- VELASCO-GALLEGO, C.; MAYA, B. N. D.; MOLINA, C. M.; LAZAKIS, I.; MATEO, N. C. Recent advancements in data-driven methodologies for the fault diagnosis and prognosis of marine systems: A systematic review. *Ocean Engineering*, Elsevier BV, v. 284, p. 115277, set. 2023. ISSN 0029-8018. Disponível em: <<http://dx.doi.org/10.1016/j.oceaneng.2023.115277>>.
- VIEIRA, J. L. d. M.; FARIAS, F. C.; OCHOA, A. A. V.; MENEZES, F. D. de; COSTA, A. C. A. d.; COSTA, J. u. P. da; LEITE, G. de N. P.; VILELA, O. d. C.; SOUZA, M. G. G. de; MICHIMA, P. S. A. Remaining useful life estimation framework for the main bearing of wind turbines operating in real time. *Energies*, MDPI AG, v. 17, n. 6, p. 1430, mar. 2024. ISSN 1996-1073. Disponível em: <<http://dx.doi.org/10.3390/en17061430>>.

WANG, B.; LEI, Y.; LI, N.; LI, N. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings. *IEEE Transactions on Reliability*, Institute of Electrical and Electronics Engineers (IEEE), v. 69, n. 1, p. 401–412, mar. 2020. ISSN 1558-1721. Disponível em: <<http://dx.doi.org/10.1109/TR.2018.2882682>>.

WANG, Z.; GUO, J.; WANG, J.; YANG, Y.; DAI, L.; HUANG, C.-G.; WAN, J.-L. A deep learning based health indicator construction and fault prognosis with uncertainty quantification for rolling bearings. *Measurement Science and Technology*, IOP Publishing, v. 34, n. 10, p. 105105, jun 2023. Disponível em: <<https://dx.doi.org/10.1088/1361-6501/ace072>>.

WANG, Z.; GUO, J.; WANG, J.; YANG, Y.; DAI, L.; HUANG, C.-G.; WAN, J.-L. A deep learning based health indicator construction and fault prognosis with uncertainty quantification for rolling bearings. *Measurement Science and Technology*, IOP Publishing, v. 34, n. 10, p. 105105, jun. 2023. ISSN 1361-6501. Disponível em: <<http://dx.doi.org/10.1088/1361-6501/ace072>>.

WWEA. *WWEA Annual Report 2023*. 2024. Disponível em: <<https://wwindea.org/ss-uploads/media/2024/3/1711538106-40ab83f2-3e01-4c0a-9d28-e0a21bff72e6.pdf>>. Acesso em: 25 jun. 2024.

ZANIBONI, G.; DALLABONA, A.; NIELSEN, J.; PAPAGEORGIU, D. *Condition monitoring of wind turbine blades via learning-based methods*. 2024. Disponível em: <<https://arxiv.org/abs/2406.19773>>.

ZHANG, A.; LIPTON, Z. C.; LI, M.; SMOLA, A. J. *Dive into Deep Learning*. [S.l.]: Cambridge University Press, 2023. <<https://D2L.ai>>.

ZOU, X.; ZHANG, J.; CHEN, J.; OROZOVIC, O.; XIE, X.; LI, J. Oil monitoring and fault pre-warning of wind turbine gearbox based on combined predicting method. *Sustainability*, MDPI AG, v. 15, n. 4, p. 3802, fev. 2023. ISSN 2071-1050. Disponível em: <<http://dx.doi.org/10.3390/su15043802>>.