



Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco
Campus Garanhuns
Curso de Bacharelado em Engenharia Elétrica

Hemilly Sara Plácido de Lima

**Diagnóstico de Conversores CA-CC-CA Através da Aplicação de Redes
Neurais Convolucionais**

Garanhuns - PE
2024

Hemilly Sara Plácido de Lima

**Diagnóstico de Conversores CA-CC-CA Através da Aplicação de Redes
Neurais Convolucionais**

Trabalho de conclusão de curso apresentado a Coordenação do Curso de Engenharia Elétrica do Instituto Federal de Pernambuco, campus Garanhuns, como requisito para obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Diego Soares Lopes.

Coorientador: Prof. Dr. Jair Galvão de Araújo.

Garanhuns - PE

2024

L732d

Lima, Hemilly Sara Plácido de.

Diagnósticos de conversores CA-CC-CA através da aplicação de redes neurais convolucionais / Hemilly Sara Plácido de Lima ; orientador Diego Soares Lopes ; Coorientador Jair Galvão de Araújo, 2024.

61 f. : il.

Orientador: Diego Soares Lopes

Coorientador: Jair Galvão de Araújo

Trabalho de Conclusão de Curso (Graduação) – Instituto Federal de Pernambuco. Pró-Reitoria de Ensino. Diretoria de Ensino. Campus Garanhuns. Coordenação do Curso Superior em Engenharia. Curso de Bacharelado em Engenharia Elétrica, 2024.

1. Energia eólica - Produção. 2. Conversores de corrente elétrica. 3. Redes neurais (Computação). I. Título.

CDD 621.312136

Riane Melo de Freitas Alves –CRB4/1897

Diagnóstico de Conversores CA-CC-CA Através da Aplicação de Redes Neurais Convolucionais

Trabalho aprovado. Garanhuns, 29 de Fevereiro de 2024.

Prof. Dr. Diego Soares Lopes (IFPE)
Orientador

Prof. Dr. Jair Galvão de Araújo (IFPE)
Coorientador

Prof. Dr. Anderson Alves Lopes (IFPE)
Avaliador interno

Prof. Me. João Paulo Silvino Belo da Silva (IFPE)
Avaliador externo

Garanhuns-PE

2024

Dedico a Deus, que me sustentou em toda trajetória.
Aos meus pais, Ana e Rogério, a base sólida para que eu pudesse caminhar.
A minha irmã, Haikella, por acreditar e impulsionar meus passos.
A meu companheiro de vida, Victor, por aliviar os fardos e me acompanhar nessa jornada.

Agradecimentos

Agradeço, primeiramente, à Deus, por plantar sonhos em mim e me dar toda força e coragem que necessito para realizá-los.

Agradeço aos meus pais, Ana e Rogério, e minha irmã Haikella, por serem a forte base na qual construí meu caráter. Vocês são meu apoio em todos os momentos e garantia para que eu nunca desistisse de perseguir meus objetivos.

Agradeço aos meus avós, Josefa e José, meus professores da vida, meus maiores exemplos de caráter, humildade e fé. Aprendi com vocês a ética e resiliência que buscarei exercer em todo meu histórico profissional.

Agradeço à Victor, meu companheiro, por carregar minhas cargas emocionais, me dar as alavancadas necessárias e sempre acreditar no meu potencial. Você me incentiva a ser minha melhor versão.

Agradeço aos meus colegas de curso, vocês foram o alívio nos momentos de dificuldade, não chegaria tão longe se não fossem o companheirismo e amizade de vocês. Agradeço em especial à Mariana Xavier, minha amiga, companheira de estágio e de curso, pela amizade, pelo compartilhamento de experiências e pela prontidão em ajudar.

Aos professores orientadores Diego Lopes e Jair Galvão, pela confiança depositada em mim e por sempre encorajar meu desenvolvimento, propondo melhorias e fornecendo o otimismo, credibilidade e assistência necessárias para que eu possa realizá-las. Sou eternamente grata por todas as lições aprendidas, competência e orientação fornecidas.

Ao CNPq, pelo apoio financeiro para o desenvolvimento deste projeto e ao IFPE, pelo apoio e ensino de qualidade.

“Todas as vitórias ocultam uma abdicação”. (Simone de Beauvoir)

Resumo

Devido à necessidade da redução da emissão dos gases poluentes e à busca por meios mais sustentáveis de produção de energia, a energia eólica tem sido uma das fontes renováveis que mais crescem no mundo. Entretanto, os custos com operação e manutenção podem chegar a 15% do preço da energia gerada, evidenciando a necessidade de aplicação de métodos para diagnóstico correto de falhas, especialmente no sistema de conversão, que é responsável por cerca de 13% das falhas por turbina ao ano. Diante disto, este trabalho busca diagnosticar as falhas apresentadas por conversores de potência em uma planta de geração eólica. Para tanto, foi implementada uma rede neural convolucional (RNC) ResNet50 com os dados de entrada reais da planta representados como gráficos de radar e divididos em 48 classes, sendo: uma delas do sistema em condições normais de operação, outra para outros tipos de falhas e as demais cada uma representando uma falha no sistema de conversão. Quanto aos resultados, delineiam o progresso e os desafios enfrentados no desenvolvimento da rede neural, no qual foi alcançada uma acurácia final de 91,66%, por meio do ajuste dos hiperparâmetros e análise da complexidade dos padrões aprendidos pela rede. Com isso, a partir da observação dos resultados, viu-se que um dos principais ofensores para o aumento da acurácia do modelo é o desbalanceamento de dados, sugere-se o uso de técnicas como *data augmentation* gerando novos exemplos sintéticos visando equilibrar a distribuição. Afora, este trabalho não apenas valida a eficácia do modelo proposto, mas também lança luz sobre direções futuras promissoras, ampliando o debate acerca do uso de redes neurais para diagnóstico de falhas em conversores, a fim de corroborar com o aumento da disponibilidade da planta de geração.

Palavras-chaves: Energia Eólica. Diagnóstico de Falhas. Rede Neural Convolutiva (RNC).

Abstract

Due to the need to reduce emissions of polluting gases and the search for more sustainable means of energy production, wind energy has been one of the fastest-growing renewable sources in the world. However, operation and maintenance costs can reach up to 15% of the generated energy price, highlighting the need for the application of methods for correct fault diagnosis, especially in the conversion system, which is responsible for about 13% of turbine failures per year. Therefore, this work aims to diagnose the faults presented by power converters in a wind generation plant. For this purpose, a Convolutional Neural Network (CNN) ResNet50 was implemented with real input data from the plant represented as radar graphs and divided into 48 classes: one for the system in normal operating conditions, another for other types of faults, and the rest each representing a fault in the conversion system. As for the results, they outline the progress and challenges faced in the development of the neural network, achieving a final accuracy of 91.66% through the adjustment of hyperparameters and analysis of the complexity of the patterns learned by the network. Consequently, from the observation of the results, it was seen that one of the main offenders for the increase in the model's accuracy is data imbalance, suggesting the use of techniques such as data augmentation to generate new synthetic examples aiming to balance the distribution. Furthermore, this work not only validates the effectiveness of the proposed model but also sheds light on promising future directions, expanding the debate on the use of neural networks for fault diagnosis in converters, in order to contribute to the increased availability of the generation plant.

Keywords: Wind Energy. Fault Diagnosis. Convolutional Neural Network (CNN).

Sumário

1	INTRODUÇÃO	13
1.1	Objetivos	15
1.1.1	Objetivos Específicos	15
1.2	Estrutura do trabalho	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	O Aerogerador	16
2.2	Conversores Aplicados à Geração de Energia Eólica	19
2.3	Representação de Variáveis em Gráfico de Radar	21
2.4	Redes Neurais Convolucionais	22
3	METODOLOGIA	26
3.1	Aquisição de dados de operação das turbinas	27
3.2	Criação de Gráficos de Radar	28
3.3	Implementação da rede neural	30
3.4	Treinamento da rede neural	33
4	RESULTADOS	35
4.1	Desenvolvimento de um Gráfico de radar	35
4.1.1	Gráficos em radar para condições normais de operação	35
4.1.2	Gráficos em radar para condições com falhas à parte das do conversor	39
4.1.3	Gráficos em radar para condições de falhas no conversor	40
4.2	Evolução da taxa de acerto	45
4.2.1	Evolução da taxa de acerto pelo o número de falhas	48
4.2.2	Evolução da taxa de acerto pelo o número de épocas	52
5	CONSIDERAÇÕES FINAIS	56
5.1	Trabalhos futuros	58
	REFERÊNCIAS	59

Lista de ilustrações

Figura 2.1 – Desenho esquemático de uma turbina eólica.	16
Figura 2.2 – Esquema simplificado do Hub-Nacele.	17
Figura 2.3 – Esquemático de um gerador de indução com rotor bobinado.	18
Figura 2.4 – Topologia de um sistema de geração eólica. Fonte: Liang et al. (2022).	20
Figura 2.5 – Proporção de falhas por componente de um conversor aplicado a geração eólica.	21
Figura 2.6 – Exemplo de gráfico em radar.	22
Figura 2.7 – Diagrama simplificado de uma rede neural.	23
Figura 2.8 – Rede neural convolucional para processamento de imagem.	24
Figura 2.9 – Estrutura do bloco residual dos modelos ResNet-50, ResNet-101 e ResNet-152.	25
Figura 3.1 – Gráfico de radar com outros tipos de falha.	29
Figura 3.2 – Gráfico de radar com falha de conversor.	29
Figura 3.3 – Gráfico de radar sem falhas.	29
Figura 3.4 – Eixos do gráfico de radar.	30
Figura 3.5 – Arquitetura de uma ResNet50.	31
Figura 4.1 – Gráficos de Radar de um mesmo mês.	36
Figura 4.2 – Sobreposição de Gráficos de Radar no verão.	38
Figura 4.3 – Sobreposição de Gráficos de Radar no inverno.	38
Figura 4.4 – Sobreposição de Gráficos de Radar do padrão mais evidente para outros tipos de falhas.	39
Figura 4.5 – Sobreposição de Gráficos de Radar do segundo padrão mais evidente para outros tipos de falhas.	40
Figura 4.6 – Sobreposição de Gráficos de Radar para um evento no sistema de conversão.	41
Figura 4.7 – Sobreposição de Gráficos de Radar para o mesmo evento da Figura 4.6.	42
Figura 4.8 – Sobreposição de Gráficos de Radar para outro evento no sistema de conversão.	42
Figura 4.9 – Sobreposição de Gráficos de Radar no sistema de conversão sem potência sendo gerada.	43

Figura 4.10–Sobreposição de Gráficos de Radar no sistema de conversão com potência sendo gerada.	44
Figura 4.11–Gráfico das perdas para o cenário inicial.	46
Figura 4.12–Gráfico de perdas e precisão com o novo treinamento.	47
Figura 4.13–Gráfico de perdas e precisão com três classes.	48
Figura 4.14–Pareto das falhas com a recorrência.	49
Figura 4.15–Gráfico de perdas e precisão com a falha mais recorrente do conversor.	49
Figura 4.16–Gráfico de perdas e precisão com as cinco falhas mais recorrentes do conversor.	50
Figura 4.17–Gráfico de perdas e precisão com as dez falhas mais recorrentes do conversor.	51
Figura 4.18–Gráfico de perdas e precisão com 50 épocas.	53
Figura 4.19–Gráfico de perdas e precisão com 100 épocas.	54

Lista de tabelas

Tabela 3.1 – Características técnicas da turbina tipo A.	26
Tabela 3.2 – Características técnicas da turbina tipo B.	26
Tabela 4.1 – Relação da acurácia pelo o acréscimo de classes.	52

1 Introdução

Fortemente motivada pelas discussões sobre mudanças climáticas e da consequente necessidade de redução da emissão dos gases de efeito estufa e de outros gases poluentes, a energia eólica tem sido uma das fontes renováveis que mais crescem no mundo (EPE, 2020). De acordo com dados disponibilizados pelo Operador Nacional do Sistema (ONS), a evolução da capacidade instalada de geração das usinas eólicas em operação comercial, sob o controle do despacho centralizado e programado, tem apresentado um avanço considerável, passando de 11382 GW em janeiro de 2018 à 26079 GW em outubro de 2023 (ONS, 2023).

A parcela de composição da geração eólica vem aumentando com o passar dos anos, no Brasil, corresponde à 11,8% de toda energia elétrica gerada em território nacional, como apontam dados da Empresa de Pesquisa Energética (EPE) (EPE, 2022). E, de acordo com O Plano Nacional de Energia de 2050, existe uma previsão de expansão da porcentagem de participação das Centrais Geradoras Eólicas (EOLs) na matriz energética nacional. Com a maior demanda de carga ao decorrer dos anos, espera-se que a fonte eólica atinja aproximadamente entre 110 a 195 GW em termos de capacidade instalada e entre 50 a 80 GW médios em termos de potência em 2050.

Por se tratar de uma fonte com atividade expressiva no contexto de geração elétrica e ser um ativo crítico na promoção da transição e diversificação energética, a aplicação de métodos para diagnóstico correto de falhas é de suma importância, visto que os custos com operação e manutenção podem chegar a 15% do preço da energia gerada (GUO *et al.*, 2020), além de muitas contratuais associadas à indisponibilidade.

Devido à importância da geração eólica na matriz energética nacional e em vista dos planejamentos de expansão no setor, possíveis falhas que venham a ocorrer devem ser sanadas o mais prontamente possível. Dentre as falhas mais comuns em sistemas de geração eólica, estão problemas no sistema de cicloconversão (Corrente alternada - corrente contínua - corrente alternada) responsáveis por condicionar a energia gerada para ser injetada no sistema de potência.

Esses conversores, CA-CC-CA, são responsáveis por cerca de 13% das falhas por turbina ao ano (SANTELO; MONTEIRO, 2020). Esse fato evidencia a necessidade emergente de estudos envolvendo métodos para que estas interrupções aconteçam com a menor frequência possível e, uma vez que ocorram, que as ações de resolução sejam rápidas e eficazes. A estrutura do conversor é composta por diversos componentes, tais como: capacitor, placa

de circuito impresso, chaves semicondutoras e conectores. Qualquer um desses componentes pode falhar, levando o conversor à falha. A causa da falha também pode ser das mais diversas, dentre elas: sobretensão elétrica, ativação térmica, eletromigração, efeitos de carga e contaminação iônica, degradação da graxa, fadiga da solda, dentre outros problemas elétricos e mecânicos (FISCHER *et al.*, 2012).

Identifica-se que o diagnóstico em conversores CA-CC-CA é complexo, e a ocorrência de uma falha pode resultar em tempo de indisponibilidade elevado até que o problema seja sanado. Esse tempo de indisponibilidade leva a uma série de prejuízos à usina de geração, destacando-se o pagamento de multas contratuais caso a disponibilidade seja inferior à 98%.

Os métodos de diagnóstico de falhas incluem três categorias: métodos baseados em modelo, métodos baseados em sinais e métodos baseados em dados. O método baseado em modelo acontece por meio de um modelo matemático preciso com base no conhecimento físico acerca das estruturas e dinâmica do sistema. O método baseado em sinal avalia o comportamento do sistema a partir de falhas de componentes, gerando variáveis e limites de diagnóstico com base nos sinais medidos. Por fim, o método baseado em dados utiliza numerosos dados históricos de operação para obter estados do sistema. Primariamente, realizando o processamento de sinais medidos e extração de características, e, a partir disto, desenvolvendo um algoritmo de inteligência artificial para treinamento e reconhecimento de padrões de falha (LIANG *et al.*, 2022).

Através dos dados provenientes de um Sistemas de Supervisão e Aquisição de Dados, em inglês *Supervisory Control and Data Acquisition* (SCADA), com o histórico de dados de diversas variáveis presentes no processo de geração de energia eólica, é possível o desenvolvimento de um sistema para diagnosticar as causas das falhas nos conversores.

Nesse contexto, diversos trabalhos acadêmicos vêm propondo sistemas para realização de diagnóstico em conversores baseadas na análise destes dados, (LIU *et al.*, 2020), (KOU *et al.*, 2020), (ZHANG *et al.*, 2020), entre outros. O método de detecção de falhas através de redes neurais convolucionais tem apresentado resultados satisfatórios para classificação do estado normal e anormal de operação, em se tratando de geração eólica com falhas frequentes no sistema do conversor, pitch e gerador, conforme visto em (LIU *et al.*, 2020). Uma característica positiva muito atrativa e que justifica a escolha do método, já que, a classificação entre falhas é objeto principal de estudo deste trabalho.

A partir da expansão da parcela de geração eólica no cenário mundial, verifica-se, em paralelo, os desafios para a garantia de uma geração com ações mais rápidas para resolução das interrupções. Portanto, é de extrema contribuição para o setor, estudos que visem o aumento desta confiabilidade, em especial, com o uso de dados reais da operação de uma planta permitindo uma validação robusta e o desenvolvimento de um software para auxílio à decisão posteriormente.

1.1 Objetivos

Diagnosticar causas de falhas apresentadas por conversores de potência em uma planta de geração eólica, através da aplicação de uma rede neural convolucional (RNC) ResNet50 com os dados de entrada representados como gráficos de radar.

1.1.1 Objetivos Específicos

Os objetivos específicos deste trabalho são:

1. Adquirir os seguintes dados históricos relacionados à velocidade do vento, velocidade do rotor, potência, velocidade do gerador, temperatura ambiente e temperatura do gerador, além de outros dados cedidos pelo o centro de geração eólica;
2. Sintetizar dos dados obtidos através de um gráfico de radar;
3. Implementar uma rede neural convolucional ResNet50;
4. Treinar a rede para classificação de estados anormais de operação e o quanto cada uma das variáveis de entrada diverge da condição ideal de operação;
5. Determinar a taxa de acerto da rede neural convolucional, verificando se apresenta um comportamento satisfatório, bem como a identificação da possível raiz da falha.

1.2 Estrutura do trabalho

No capítulo 2, é apresentada a fundamentação teórica do trabalho, abordando os temas de geração eólica, processo de conversão CA-CC-CA aplicados neste tipo de geração, funcionamento dos sistemas relacionados, representação de variáveis em gráfico de radar e redes neurais convolucionais aplicadas para processamento de imagens.

No capítulo 3, vê-se a metodologia aplicada para a execução da pesquisa e do trabalho de diagnóstico de falhas de conversores utilizando redes neurais convolucionais. São apresentadas informações dos conversores que foram estudados, da forma como os dados foram sintetizados na forma de gráficos de radar e da implementação e treinamento da rede neural.

No capítulo 4, são apresentados os resultados alcançados e análises pertinentes a estes.

No capítulo 5 são descritas as considerações finais do trabalho, bem como sugestões para trabalhos futuros.

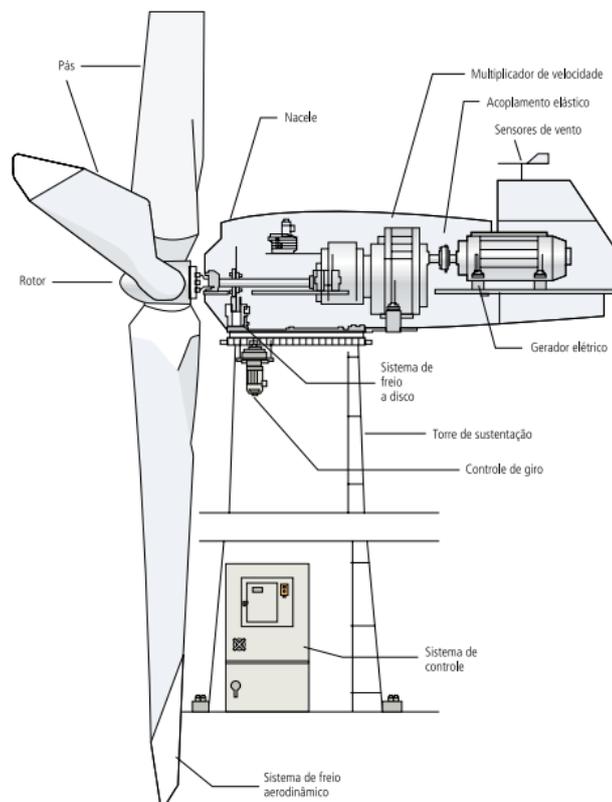
2 Fundamentação Teórica

Nesta seção os conceitos teóricos necessários para o desenvolvimento do trabalho proposto são apresentados.

2.1 O Aero gerador

Sobretudo, antes de propor um método para resolução de falhas, é necessário ter conhecimento acerca da estrutura e funcionamento de um aerogerador. Adicionalmente, é preciso, também, entender quais indicadores são de fundamental análise frente distúrbios de operação da máquina. Os principais componentes de uma turbina encontram-se na Figura 2.1:

Figura 2.1. Desenho esquemático de uma turbina eólica.

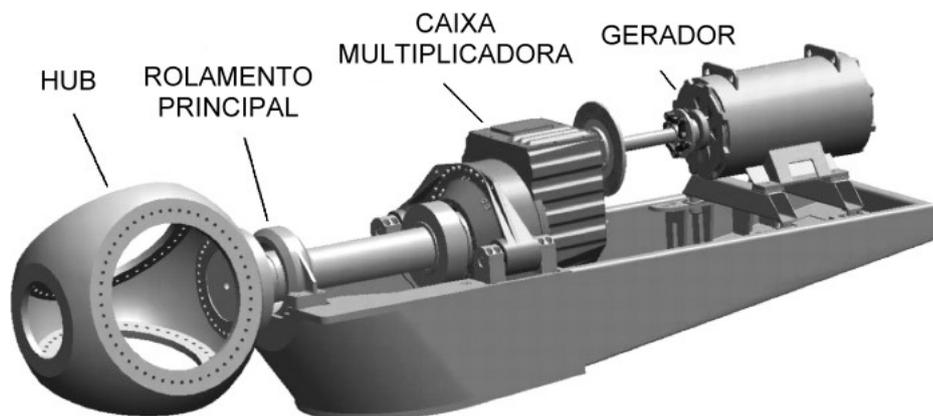


Fonte: (ABEEÓLICA, 2022).

O rotor eólico é o principal componente de um aerogerador. É nele que se perde e se converte boa parte da energia contida dos ventos. É no rotor que se encontra as partes rotativas externas à Nacele, sendo estas: as pás, o cubo (*hub*) e o sistema de controle de passo (*pitch system*) (FADIGAS, 2012).

As pás são os componentes responsáveis por converter a energia dos ventos em energia mecânica de rotação. As turbinas em estudo são compostas por três pás, em comparação a turbinas de uma ou duas pás, este modelo apresenta maior eficiência, devido a razões tais como: maior estabilidade, momento polar de inércia constante com relação ao movimento de orientação do rotor, menor velocidade rotacional para uma mesma produção de energia, menor ruído e sistema menos complexo para absorver os impactos das cargas do rotor com a turbina (FADIGAS, 2012).

Figura 2.2. Esquema simplificado do Hub-Nacele.



Fonte: (REIS, 2020).

O *hub* consiste no componente da turbina responsável pelo o acoplamento das pás ao eixo principal de rotação. Em turbinas que possuem o sistema de *pitch*, esse mecanismo também fica fixo nesta estrutura.

O sistema de *pitch* ajusta o ângulo das pás de uma turbina eólica. Ao passo que esse ângulo é ajustado, o mecanismo de controle de passo comanda o quanto de energia pode ser extraído através das pás (U.S. DEPARTMENT OF ENERGY, 2023). Em adicional, esse sistema é importante pois também atua como um freio desacelerando o rotor da turbina e evitando danos à máquina quando a velocidade do vento é muito alta para uma operação segura (FADIGAS, 2012).

O âmago do processo da geração eólica encontra-se nos componentes presentes na Nacele, onde está presente o sistema de transmissão mecânico do aerogerador (*drivetrain*), composto pelo: rolamento principal, caixa multiplicadora (*gearbox*), acoplamentos, sistema de freio e o gerador. O *drivetrain* converte a rotação de baixa velocidade e alto torque do rotor da turbina em energia elétrica.

O rolamento principal *main bearing* ou eixo principal tem por função fazer a transferência do torque desenvolvido no rotor para o restante dos componentes do sistema de transmissão mecânico (FADIGAS, 2012). As pás e o cubo juntos formam o rotor da turbina.

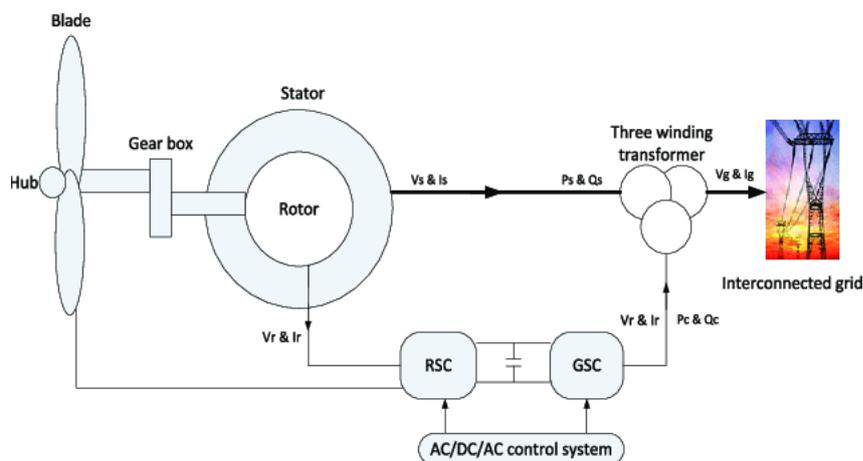
A caixa multiplicadora é responsável por transmitir a energia mecânica do eixo do rotor ao eixo do gerador.(FADIGAS, 2012). O mecanismo mais utilizado para realizar a multiplicação de velocidade e que, inclusive, é adotado no modelo de turbina analisado, é a caixa de engrenagens *main shaft*.

O gerador é acionado pelo eixo de alta velocidade. Os enrolamentos de cobre giram através de um campo magnético no gerador para produzir eletricidade. Alguns geradores são acionados pela *gearbox*, no caso das turbinas em análise, e outros são acionados diretamente, onde o rotor é conectado diretamente ao gerador (U.S. DEPARTMENT OF ENERGY, 2023).

Os geradores utilizados na geração eólica podem ser síncronos ou assíncronos, mais comumente a segunda opção. O gerador síncrono de ímã permanente (PMSG, do inglês *Permanent Magnet Synchronous Generator*) e o gerador de indução com rotor bobinado (DFIG, do inglês *Doubly Fed Induction Generator*) são as tecnologias mais aplicadas para trabalhar com turbinas eólicas.

Em comparação com outros sistemas de turbinas eólicas utilizados atualmente, a evolução acelerada de turbinas de acionamento direto com o gerador síncrono de ímã permanente, pode ser atribuída à sua estrutura simples, baixo custo de manutenção, alta eficiência de conversão e alta confiabilidade. Além disso, seu desempenho de controle de desacoplamento é muito menos sensível às variações dos parâmetros do gerador (WU *et al.*, 2013).

Figura 2.3. Esquemático de um gerador de indução com rotor bobinado.



Fonte: (ELKASEM *et al.*, 2019).

No entanto, *DFIG* é o gerador mais utilizado nesse tipo de aplicação, inclusive é a

estrutura presente nas turbinas em estudo. Porém, devido à diferença de velocidade entre o estator e o rotor, é necessária a presença da *gearbox* para acoplar o rotor ao gerador. Embora exista a necessidade de uma caixa multiplicadora e anéis deslizantes, e isso leve a um nível de confiabilidade média e reduzida longevidade devido à falhas em rolamentos e engrenagens; os ganhos em: faixa de velocidade limitada em torno de 30% da velocidade síncrona, controle total da potência ativa e reativa, alta eficiência e rendimento energético, justificam a escolha (DAHIYA; G, 2019).

Para aumentar o nível de segurança da máquina, é indispensável o uso de freios mecânicos, ou *Brake*. O sistema de freios tem duas funcionalidades: parar o rotor para manutenções e reparos, e auxiliar o freio aerodinâmico, principalmente, em turbinas de menor capacidade de potência quando o sistema está em sobrevelocidade (FADIGAS, 2012). Há dois tipos de freios mecânicos utilizados em turbinas: a disco e a embreagem; no caso das turbinas em análise, os freios são de disco.

Um dos sistemas mais críticos para a garantia da alta disponibilidade de uma turbina é o sistema de controle de orientação do rotor (*Yaw control*). Este mecanismo de controle tem por função orientar o rotor e a Nacele na direção do vento, de forma que o giro das pás fique perpendicular à esta direção. Dessa forma, possibilitando o aproveitamento máximo da força dos ventos.(FADIGAS, 2012)

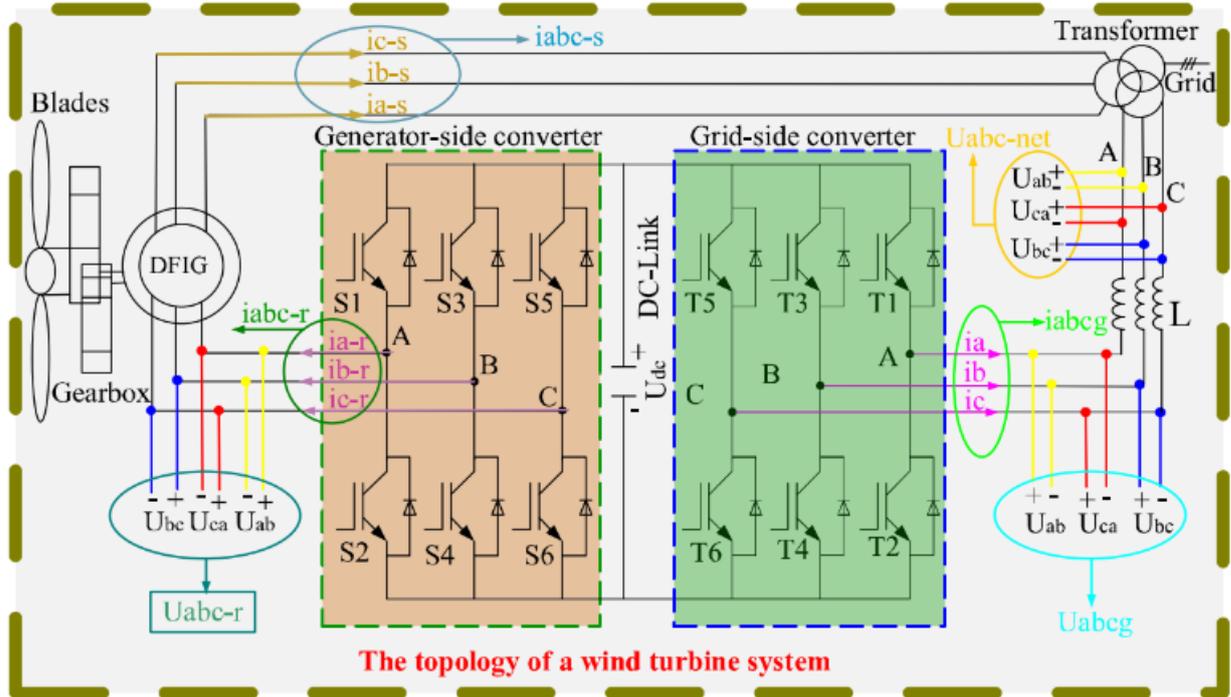
Para que os sistemas supracitados operem de forma coesa, é preciso que exista um sistema de controle. O controlador tem por função principal desligar a turbina na iminência de uma alta velocidade do vento, a fim de evitar danos aos diferentes componentes mecânicos de uma turbina (U.S. DEPARTMENT OF ENERGY, 2023). Esse sistema de controle é dividido em três partes:

- Um controlador da central eólica, frequentemente representado através de um sistema supervisório (*SCADA*), com a possibilidade de operação sobre a máquina de maneira remota;
- Um controle supervisório individualizado para cada turbina, controlando o chaveamento entre os diversos estados de operação e monitoramento de falhas;
- Controles dinâmicos para os vários subsistemas da turbina, com o ajuste de atuadores frente à mudanças no estado de operação.

2.2 Conversores Aplicados à Geração de Energia Eólica

A energia eólica advém do movimento das massas de ar, as quais são variáveis no tempo e espaço. Essa característica faz com que a energia gerada seja alternada e em uma frequência variável, sendo necessário a conversão para contínua, através de um link CC, e posterior conversão para uma tensão alternada com a frequência compatível com a da rede, conforme apresentado na Figura 2.4.

Figura 2.4. Topologia de um sistema de geração eólica. Fonte: Liang et al. (2022).



Fonte: (LIANG *et al.*, 2022)

Esses conversores são responsáveis por controlar a magnetização do gerador e, automaticamente, controlar a tensão dos sinais de geração, realizando a compensação de frequência do sinal gerado frente as variações de velocidade mecânica do rotor da turbina. Além disso, controla o giro mecânico do eixo e o escorregamento do gerador, auxiliando na frenagem mecânica quando necessário, através dos princípios eletromagnéticos. Outro ponto importante, é que o conversor realiza o controle de potência reativa da rede que a turbina alimenta.

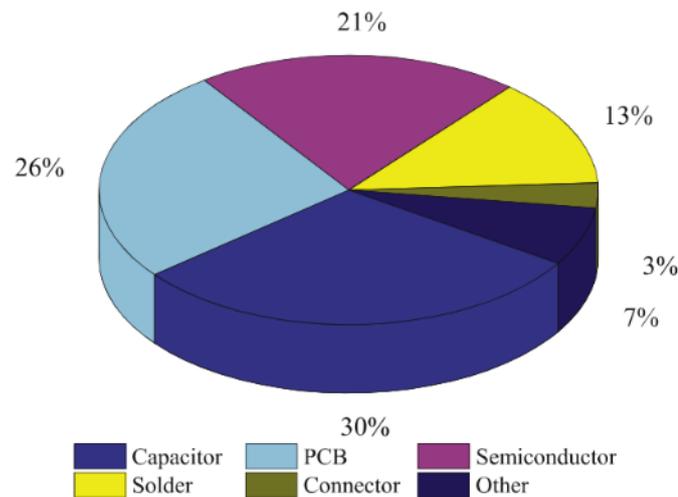
Dependendo do tipo de gerador empregado, eletrônica de potência, controlabilidade de velocidade e da maneira como a potência aerodinâmica é limitada, vários modelos de projeto de conversores para turbinas eólicas estão disponíveis (BLAABJERG *et al.*, 2015). Dentre esses modelos destacam-se: 2L-VSC, 3L-NPC e 3L-MMC. O modelo aplicado é o 3L-NPC-BTB, já que, para lidar com tensões mais altas e maiores classificações de potência, um conversor de vários níveis tem se mostrado uma opção mais vantajosa.

O conversor 3L-NPC-BTB se sobressai ao 2L-BTB por alcançar um nível de tensão de saída a mais com menos esforço, dv/dt , tornando assim possível converter a potência em níveis altos com correntes mais baixas, menos dispositivos associados e sistema de filtragem reduzido. (BLAABJERG *et al.*, 2015)

Na Figura 1, é possível notar que os conversores são formados por grupos de chaves semicondutoras, em geral, são utilizados módulos de transistores bipolares de base isolada (IGBT), em que aos pares formam os braços de chaveamento. Essas chaves podem falhar,

levando o conversor a uma falha crítica, ou a uma má operação. Além das chaves, existe a presença de um capacitor (link CC) que estabiliza a tensão contínua após a fase de retificação do conversor do lado gerador, conectando-o com o lado rede. Existem outros motivos de falhas, além das que ocorrem nas chaves e no capacitor, uma estratificação dos componentes responsáveis por falhas em conversores é apresentado na Figura 2.5.

Figura 2.5. Proporção de falhas por componente de um conversor aplicado a geração eólica.



Fonte: (YANG; CHAI, 2016).

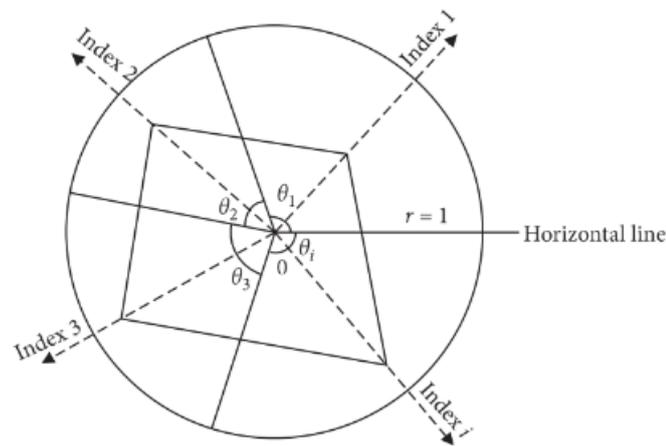
Dado o número de componentes e a quantidade de causas que levam os mesmos à falha, o diagnóstico se torna complexo e demorado. Quanto mais rápido o diagnóstico for feito, mais rápido o problema será resolvido, aumentando a eficiência e confiabilidade do sistema geração. Pelo exposto, métodos de diagnóstico são objeto de estudo de diversos trabalhos, visando o aumento da disponibilidade das turbinas frente à falhas desta natureza.

2.3 Representação de Variáveis em Gráfico de Radar

O gráfico em radar é útil para agregar um conjunto de informações. Consiste em um grupo de eixos equiângulos, em que cada raio representa uma das variáveis, e o comprimento de cada raio é proporcional ao módulo da variável para o ponto de dados em relação à máxima magnitude da variável em todos os pontos, conforme apresentado na Figura 2.6. É um método de representação gráfica, que visualiza dados numéricos da perspectiva do "pensamento de superfície", e converte a informação no espaço invisível de alta dimensão em informação plana intuitiva (CHENG; JIA, 2019). Os valores em cada um dos eixos são conectados formando um desenho, sendo dados normalizados para intervalos condizentes às necessidades de aplicação.

Com base nesse método, os dados numéricos podem ser efetivamente convertidos em dados de imagem, e a representação do gráfico de radar dificilmente levará à perda da informação original, mas aumentará o efeito de visualização dos dados originais (CHENG; JIA, 2019).

Figura 2.6. Exemplo de gráfico em radar.



Fonte: (ZHANG *et al.*, 2020).

Portanto, a partir da conversão dos dados numéricos de quaisquer variável de interesse para o gráfico de radar, é possível aplicá-las como o *Dataframe* no desenvolvimento de uma rede neural convolucional, visando a extração e identificação das informações de borda do gráfico de radar, o que corroborará com melhores resultados de classificação, comprovado por Liu *et al.* (2020) ao obter uma maior taxa de acerto fazendo uso desta ferramenta de representação de dados.

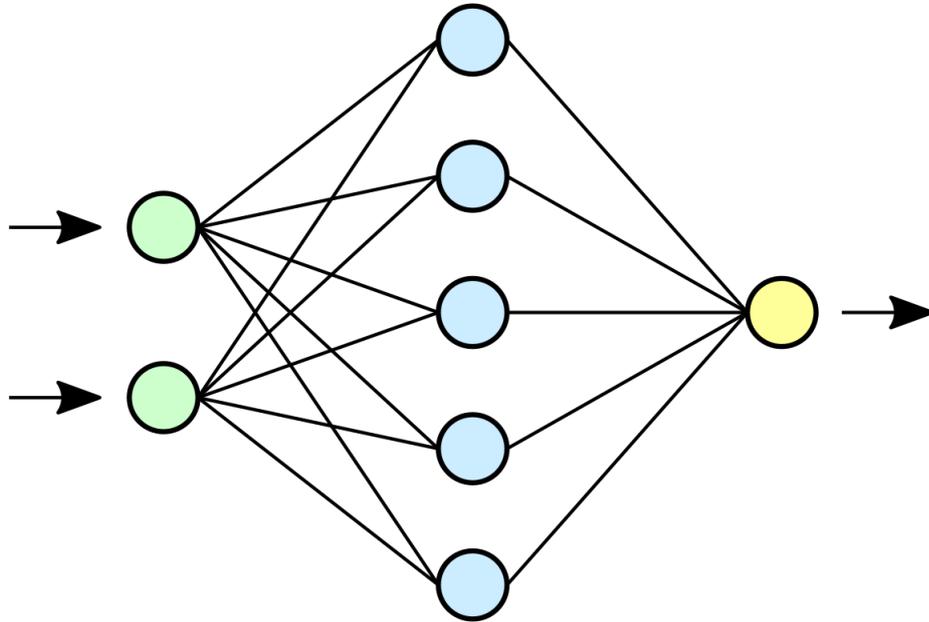
2.4 Redes Neurais Convolucionais

As redes neurais, também conhecidas como redes neurais artificiais (ANNs) ou redes neurais simuladas (SNNs), são um subconjunto de aprendizado de máquina e estão no cerne dos algoritmos de aprendizado profundo (*deep learning*). As redes neurais artificiais (ANNs) são compostas por camadas de um nó, contendo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada nó, ou neurônio artificial, conecta-se a outro e tem um peso e um limite associados. Se a saída de qualquer nó individual estiver acima do valor do limite especificado, esse nó será ativado, enviando dados para a próxima camada da rede. Caso contrário, nenhum dado será transmitido junto à próxima camada da rede (IBM, 2021).

A escolha por um método de aprendizado profundo baseia-se nas seguintes vantagens: capacidade de aprendizado profundo em diversas aplicações, robustez às mudanças usuais

nos dados de entrada, abordagem útil em problemas onde os dados são insuficientes, além de ser um método altamente escalável (ALZUBAIDI *et al.*, 2021).

Figura 2.7. Diagrama simplificado de uma rede neural.



Fonte: (DAKE, 2006).

Para o *deep learning*, existem várias técnicas de aprendizado supervisionado, como redes neurais recorrentes (RNNs), redes neurais convolucionais (CNNs) e redes neurais profundas (DNNs). Redes neurais convolucionais, do inglês Convolutional Neural Networks - CNN, estão na classe de rede neurais de aprendizado profundo sendo uma rede na qual existem camadas ocultas entre as camadas de entrada e saída.

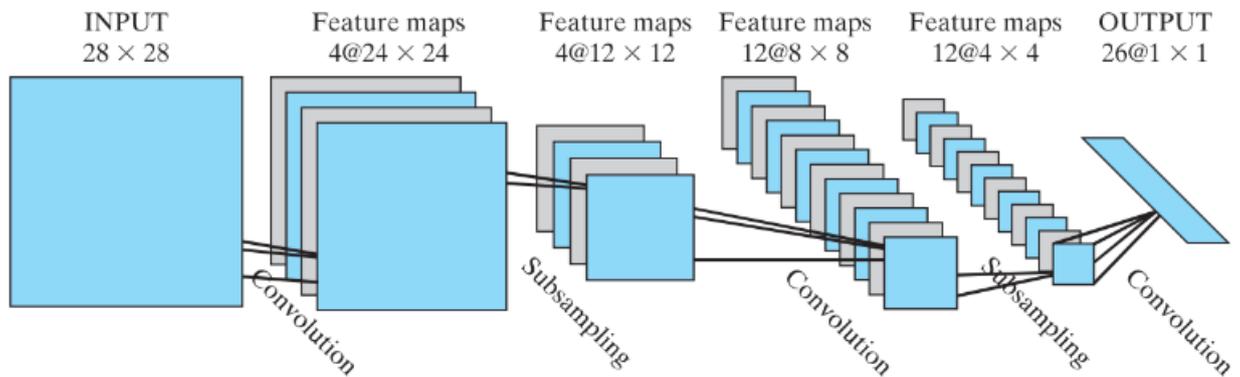
As redes neurais convolucionais são projetadas especificamente para reconhecer padrões bi-dimensionais com alto grau de invariância às diversas formas de distorção da informação (HAYKIN, 2008). Um exemplo de uso clássico para as redes neurais convolucionais é o reconhecimento de números escritos à mão, mas podem ser utilizados em diversas aplicações de processamento de imagem, conforme apresentado na Figura 2.8.

Utilizando as informações compiladas na forma de gráficos de radar, e aplicadas a uma rede neural convolucional, é possível diagnosticar um conversor aplicado a geração eólica. Esse método de diagnóstico foi proposto por Liu *et al.* (2020), o qual obteve diagnósticos com uma acurácia de 94,87% e um falso positivo de apenas 5,13%.

O principal benefício da CNN em comparação com seus antecessores é que ela identifica automaticamente as características relevantes sem supervisão humana. Ao contrário das redes totalmente conectadas (FC) convencionais, pesos compartilhados e conexões locais na CNN são empregados para aproveitar totalmente as estruturas de dados 2D, como

sinais de imagem. Essa operação utiliza um número extremamente pequeno de parâmetros, o que simplifica o processo de treinamento e acelera a rede (ALZUBAIDI *et al.*, 2021).

Figura 2.8. Rede neural convolucional para processamento de imagem.



Fonte: (HAYKIN, 2008)

Entretanto, a rede implementada por Liu *et al.* (2020) diferenciava quando as condições de operação eram normais ou provocariam falhas, sem nenhum indicativo de qual das grandezas do gráfico em radar divergia mais das condições normais de operação em caso de falha. Dessa forma, não era possível indicar a principal causa da falha. Abrindo espaço para a necessidade de identificar qual, ou quais, elementos mais divergem do estado normal de operação, indicando a provável causa da falha, ou pelo menos diminuindo o número de possibilidades a serem investigadas.

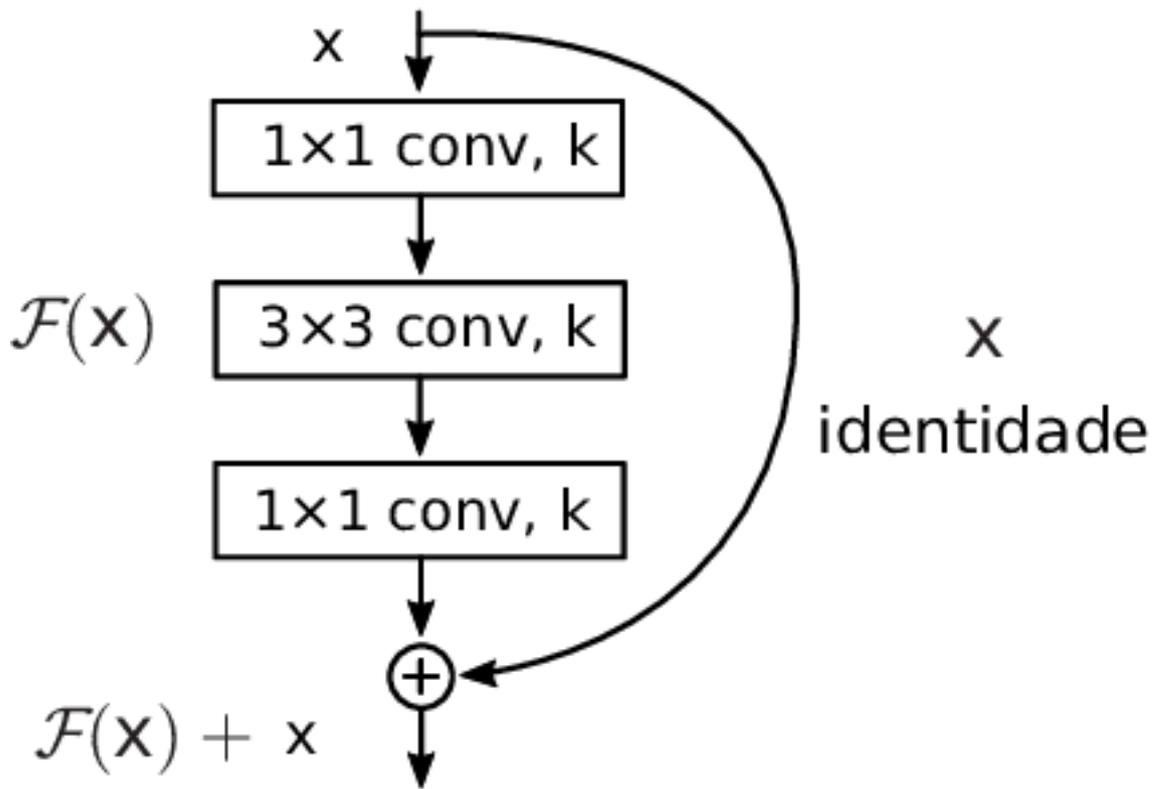
A ResNet surgiu com o objetivo de projetar uma rede ultra profunda, livre do problema do gradiente desvanecente, em comparação com as redes anteriores. Vários tipos de ResNet foram desenvolvidos com base no número de camadas, começando com 34 camadas e indo até 1202 camadas. O tipo mais comum foi o ResNet50, que consistia em 49 camadas convolucionais mais uma única camada totalmente conectada (ALZUBAIDI *et al.*, 2021).

Essa arquitetura foi desenvolvida para superar desafios no treinamento de aprendizado profundo, pois esse treinamento geralmente leva bastante tempo e é limitado a um certo número de camadas. A vantagem do modelo ResNets em comparação com outros modelos arquiteturais é que o desempenho desse modelo não diminui, mesmo quando a arquitetura fica mais profunda. Além disso, os cálculos computacionais são simplificados, e a capacidade de treinar redes é aprimorada. O modelo ResNet é implementado aplicando conexões de atalho em duas a três camadas que contêm ReLU e a normalização em lote entre as arquiteturas demonstraram que o modelo ResNet tem melhor desempenho na classificação de imagens do que outros modelos, indicando que as características da imagem foram extraídas de maneira eficaz pelo ResNet (SARWINDA *et al.*, 2021).

Dada uma entrada x , o mapeamento residual $F(x)$ é denotado por $F(x) + x$, ou seja, esse mapeamento soma a entrada de um bloco residual (x identidade) a saída resultante

desse mesmo bloco, conforme ilustrado pela estrutura do bloco presente na Figura 2.9. Essa soma é realizada enquanto os mapas de características resultantes das camadas de convolução possuem a mesma resolução (BEZERRA, 2018).

Figura 2.9. Estrutura do bloco residual dos modelos ResNet-50, ResNet-101 e ResNet-152.



Fonte: (BEZERRA, 2018).

Com base nos conceitos e teoria discutidos, busca-se agora explorar e validar empiricamente uma ResNet-50 voltada para o diagnóstico de conversores CA-CC-CA, com a avaliação de métodos para a implementação da rede e desempenho da mesma. Na seção de metodologia é demonstrado os meios para a execução da pesquisa.

3 Metodologia

No presente trabalho, foi realizada a análise de falhas de uma central geradora eólica com potência instalada de 142 MW e com dois diferentes modelos de turbinas. Dados mais aprofundados acerca de localização, fabricante e tecnologia implementada na turbina serão preservados por motivos de a empresa dispor de proteção de dados autorais incisiva, não permitindo a explanação detalhada de características intrínsecas dos aerogeradores e sua performance, além de notas de resolução de atividades corretivas na turbina.

O parque em análise está em operação há cerca de 10 anos, sendo este, dividido em aerogeradores tipo A e tipo B. As características técnicas de cada tipo de turbina estudadas são apresentadas nas Tabelas 3.1 e 3.2:

Tabela 3.1. Características técnicas da turbina tipo A.

Parâmetros técnicos da turbina tipo A	
Potência nominal	1,6 MW
Velocidade Nominal do Vento	14 m/s
Diâmetro do rotor	100 m
Tipo de Turbina	Eixo Horizontal
Tensão de Saída	690 V
Frequência de Saída	60 Hz

Fonte: Própria autora.

Tabela 3.2. Características técnicas da turbina tipo B.

Parâmetros técnicos da turbina tipo B	
Potência nominal	2,5 MW
Velocidade Nominal do Vento	12 m/s
Diâmetro do rotor	116 m
Tipo de Turbina	Eixo Horizontal
Tensão de Saída	690 V
Frequência de Saída	60 Hz

Fonte: Própria autora.

Para a execução da pesquisa foram levantadas todas as classificações de falhas nos conversores, sendo elas classificadas nos mais distintos problemas que são relacionados ao sistema de conversão, resultando em um conjunto de 46 problemas que podem ocorrer em conversores CA-CC-CA aplicados à geração eólica.

Generalizando, as falhas de conversores para os modelos de turbina em análise, podem ser por diversas razões: temperatura do conversor atingiu o nível de aviso, excesso de tensão, condições excepcionais da rede, problemas nos semicondutores, entre outros motivos.

De modo semelhante, também foram levantadas outros tipos de falhas que podem ocorrer em uma turbina eólica relacionadas a outros sistemas da mesma. Todas essas outras falhas foram consideradas como um só conjunto de classificação, a fim de diferenciá-las das falhas de conversores.

Devido à política rigorosa de proteção de dados da empresa fabricante, não é possível fornecer informações adicionais sobre os tipos específicos de cada uma das falhas de conversor encontradas e nem os códigos utilizados pela operação de que se refere cada uma delas, sejam elas no sistema de conversão ou em outros sistemas da turbina. O sistema de proteção de dados implementado pela empresa é altamente robusto e visa salvaguardar informações confidenciais e sensíveis. Portanto, em conformidade com as políticas de privacidade e segurança da organização, quaisquer detalhes adicionais sobre as falhas de conversor não podem ser divulgados neste trabalho.

3.1 Aquisição de dados de operação das turbinas

Para o desenvolvimento da pesquisa de aprendizado supervisionado da máquina, a priori, era necessário realizar o levantamento das variáveis mais interessantes para a análise de falhas em conversores. De acordo com Liu *et al.* (2020) para um estudo mais preciso, foram consideradas as variáveis sugeridas pelo autor: potência gerada, velocidade do vento, velocidade do gerador e velocidade do rotor. Adicionalmente, mais algumas variáveis foram obtidas de acordo com a análise de influência dos indicadores em falhas relacionadas ao conversor, sendo elas: temperatura ambiente e temperatura no gerador. A escolha dessas variáveis adicionais para o estudo, justificam-se nos seguintes pontos:

1. **Temperatura ambiente:** a temperatura ambiente afeta não somente a eficiência do conversor, como também, em certo nível, é capaz de levar à degradação de componentes, como: transistores, semicondutores, etc.
2. **Temperatura no gerador:** Conversores e inversores operam de forma mais eficiente em temperaturas mais baixas, portanto, é um indicador de eficiência. Outro tópico a ser destacado é que um aumento súbito e não explicado na temperatura pode indicar um problema em um componente ou sistema de resfriamento.

Os dados foram obtidos através do *WindSCADA* com intervalos de 10 em 10 minutos, sendo os únicos registros disponíveis para consulta dos indicadores no supervisório em situações de falhas prévias e não instantâneas (a leitura de dados é mais recorrente, chegando a intervalos de 10 segundos). O período de análise deu-se entre setembro de

2021 à setembro de 2022, para melhor estimativa do comportamento do aerogerador e seus sistemas frente à mudanças de estações e fatores associados.

Após a tratativa dos dados válidos para a construção da rede, os selecionados foram sintetizados em grupos de matrizes. Na primeira matriz, cada linha representa um estado normal de operação e cada coluna é o respectivo valor do parâmetro relacionado à este estado. Na segunda matriz, cada linha representa um estado anormal de operação, indicando possível mau funcionamento causado por outros tipos de falhas, e cada coluna é o respectivo valor do parâmetro relacionado ao mau funcionamento, semelhante a primeira matriz. Por fim, nas demais matrizes cada linha representa um estado anormal de operação, mas nesse caso, para as falhas de conversor, e cada coluna é o respectivo valor do parâmetro relacionado ao mau funcionamento do conversor.

Cada conjunto de dados contém seis colunas de indicadores e, em média, 200 linhas de dados coletados. A quantidade de linhas varia em alguns casos, porque, a depender da falha, pode ocorrer com menor frequência. De modo geral, procurou-se igualar o espaço amostral de estados de operação das falhas de conversores, sem falhas e com outros tipos de falhas.

3.2 Criação de Gráficos de Radar

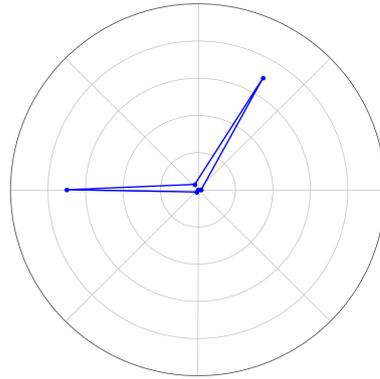
Após a extração e processamento dos dados, todas as linhas, de todas as matrizes supracitadas, foram sintetizadas em gráficos radar de forma a gerar um polígono. Isso foi feito através da linguagem Python, o software é livre sob a licença BSD (Berkeley Software Distribution) e muito útil para manipulação de dados.

Para a execução desta pesquisa, utilizou-se a biblioteca Pandas para organização das matrizes advindas de um arquivo excel e manipulação de dados, alinhado a isso fez-se uso da biblioteca matplotlib para a geração dos gráficos e a biblioteca NumPy para operações matemáticas. Cada gráfico em radar é formado por uma imagem com dimensões de 10x12 polegadas, com o gráfico de radar sendo desenhado com a linha principal em azul para representação da informação de cada estado de operação, como indicam as Figuras 3.1, 3.2 e 3.3.

Os gráficos de radar gerados incluíam seis eixos contendo: potência gerada, velocidade do vento, velocidade do gerador, temperatura ambiente, temperatura no gerador e velocidade do rotor nos instantes de coleta dos dados. As escalas foram ajustadas pensando nos valores máximo e mínimo para cada variável trabalhada, para que os padrões fossem mais evidentes, como pode ser visto no exemplo da Figura 3.4.

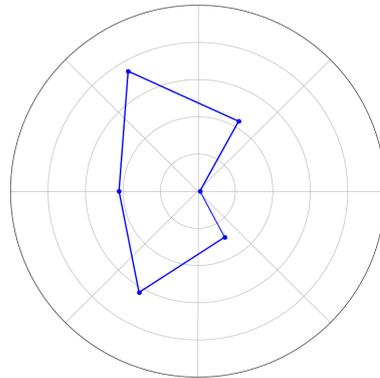
A normalização é realizada para cada coluna (parâmetro) dos dados, e a técnica empregada é conhecida como "*min-max scaling*". Para cada coluna respectiva a uma variável, foram obtidos os valores máximo e mínimo e aplicado uma fórmula de normalização, que assegura que todos os valores estejam no intervalo fechado de 0 a 1.

Figura 3.1. Gráfico de radar com outros tipos de falha.



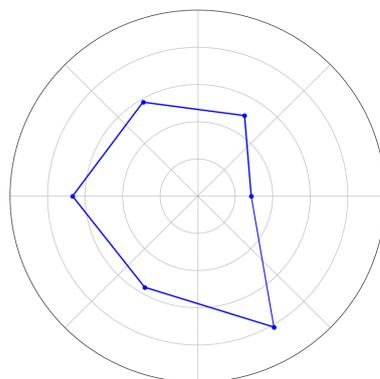
Fonte: Própria autora.

Figura 3.2. Gráfico de radar com falha de conversor.



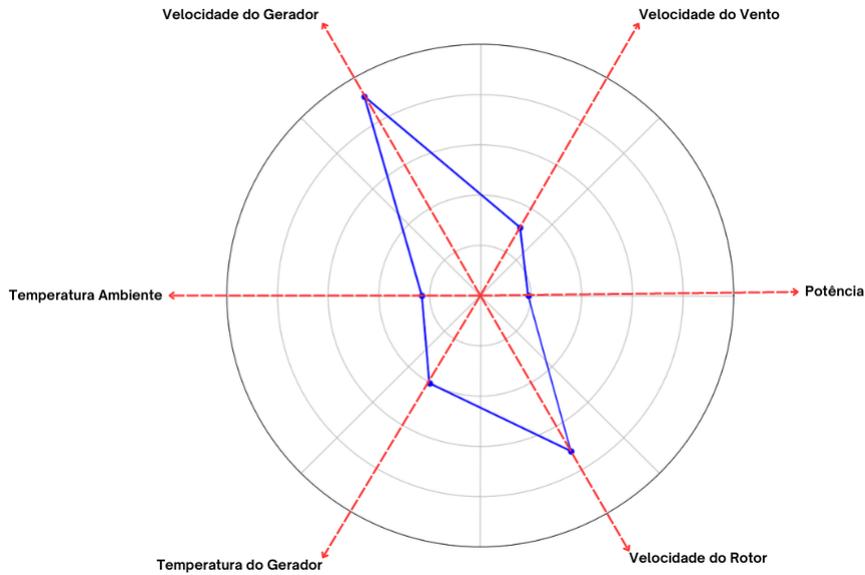
Fonte: Própria autora.

Figura 3.3. Gráfico de radar sem falhas.



Fonte: Própria autora.

Figura 3.4. Eixos do gráfico de radar.



Fonte: Própria autora.

Essa normalização é especialmente útil em casos em que os parâmetros têm escalas muito diferentes, que é o caso dos dados analisados. Um comparativo entre as colunas de dados sem a normalização afetariam significativamente no treinamento da rede, já que este processo torna mais fácil visualizar padrões e comparar as tendências em diferentes parâmetros, aumentando a taxa de acerto da rede.

O código foi implementado para a geração dos gráficos de radar com a biblioteca NumPy. Ela gera valores entre 0 e 2π (ou seja, um círculo completo) dividido pelo número de parâmetros especificados em código. Como foram seis parâmetros, os ângulos dos eixos de radar estarão em 0° , 60° , 120° , 180° , 240° e 300° . Esses ângulos correspondem a direções diferentes nos gráficos de radar, permitindo a visualização dos dados em várias direções.

3.3 Implementação da rede neural

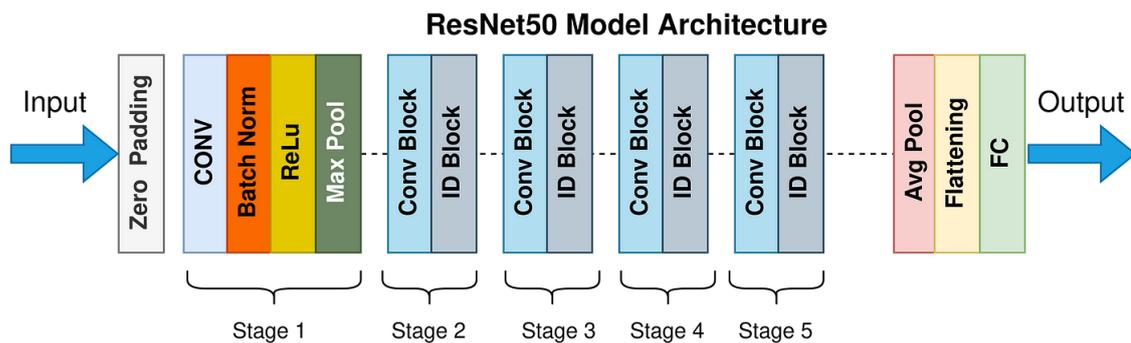
Após o condicionamento das informações, uma rede neural convolucional foi implementada utilizando a linguagem Python. A estrutura escolhida foi uma rede residual com cinquenta camadas (ResNet50), ilustrada na Figura pois esse modelo simplifica o treinamento da rede enquanto, ao mesmo tempo, aborda o problema de degradação da rede (LUYING *et al.*, 2023). A complexidade dos problemas que uma rede consegue resolver aumenta com o aumento da quantidade de camadas que possui.

A necessidade de um modelo como ResNet surgiu devido a uma série de armadilhas nas redes modernas anteriores. Dificuldade em treinar redes neurais profundas: À medida que o número de camadas em um modelo aumenta, uma simples camada de Convolução de kernel 7×7 de 3 canais para 32 canais adiciona 4736 parâmetros. Um aumento no

número de camadas leva a um aumento igual na complexidade para treinar o modelo. O treinamento então requer maior potência computacional e memória (MUKHERJEE, 2022).

Uma rede neural é frequentemente considerada um aproximador de funções. Ela tem a capacidade de modelar funções dadas entrada, alvo e uma comparação entre a saída da função e o alvo. Adicionar múltiplas camadas a uma rede a torna mais capaz de modelar funções complexas. Adicionar camadas pode ser visto como uma expansão do espaço de função (MUKHERJEE, 2022).

Figura 3.5. Arquitetura de uma ResNet50.



Fonte: (MUKHERJEE, 2022).

Entretanto, aumentar o número de camadas pode ser computacionalmente custoso e levar a problemas de treinamento, bem como aumento do erro. Visando solucionar esse problema, as redes residuais foram concebidas e são adequadas para aplicação no estudo proposto. Tendo em vista que, não existem requisitos de tempo para treinar a rede e as imagens a serem processadas possuem um grau intermediário de complexidade.

Um grande ofensor do treinamento em redes neurais é o gradiente desaparecendo, resultado de uma falta de atenção à estabilidade numérica dos parâmetros da rede. Durante a retropropagação, à medida que vai ocorrendo uma transição das camadas profundas para as rasas, a regra da cadeia de diferenciação multiplica os gradientes. Muitas vezes, esses gradientes são pequenos na ordem de 10^{-5} ou mais, à medida que esses números pequenos continuam sendo multiplicados entre si, tornam-se infinitesimalmente menores, fazendo mudanças quase negligenciáveis nos pesos (MUKHERJEE, 2022).

Por outro lado, existem casos em que o gradiente atinge ordens de 10^4 ou mais. À medida que esses gradientes grandes se multiplicam entre si, os valores tendem a se mover em direção ao infinito. Permitir que uma grande variedade de valores esteja no domínio numérico para pesos torna difícil alcançar a convergência (MUKHERJEE, 2022). O modelo ResNet, devido à sua arquitetura, não permite que esses problemas ocorram de forma alguma, devido às conexões de salto (presentes na Figura 2.9), que adicionam a função identidade à saída.

Em termos de arquitetura, se alguma camada acabar prejudicando o desempenho do modelo em uma rede simples, ela é pulada devido à presença das conexões de salto (MUKHERJEE, 2022). Além disso, a ResNet-50 foi pré-treinada em grandes conjuntos de dados, como o conjunto de dados ImageNet, que contém milhões de imagens em mil categorias diferentes. Isso significa que a rede já aprendeu uma representação rica e generalizada de características visuais, o que é benéfico para a aplicação do projeto desenvolvido.

Sendo assim, a rede neural foi implementada utilizando, também, a linguagem Python. Para que isso fosse possível, foi feito o uso algumas bibliotecas durante a construção do código:

- **Pandas:** Através dessa biblioteca foi feito o carregamento de dados de uma planilha no Excel, nessa planilha há a classificação das imagens de acordo com o estado de operação das mesmas. Esse processo é muito importante para que o treinamento de rede ocorra corretamente, já que indica, a partir de como os parâmetros se comportam, um estado normal de operação, com falha de conversor, ou outro tipo de falha.
- **Os:** O módulo 'os' possibilita a interação com o sistema operacional, esta função foi utilizada para a construção de caminhos completos para os gráficos de radar a serem processados.
- **Pillow:** Esta biblioteca é responsável pelo o trato dos gráficos de radar, redimensionando-os, convertendo-os para escala de cinza e aplicando outras transformações necessárias antes de alimentá-las à rede neural.
- **PyTorch:** O PyTorch é uma biblioteca de aprendizado de máquina, fornecendo tensores e operações matemáticas eficientes para o manejo de dados no modelo de aprendizado supervisionado. Desse modo, através dessa função, foi possível criar, treinar e avaliar o desempenho da rede neural.
- **Torchvision:** O Torchvision faz parte do ambiente do Pytorch e foi utilizado para a definição de transformações a serem aplicadas aos gráficos de radar previamente ao treinamento.
- **Torch.utils.data:** Esta função possibilitou, para o presente trabalho, um conjunto de classes e funções para lidar com o conjunto de dados em vista, facilitando a criação de conjuntos de dados através de tensores e criando iteradores que permitem a alimentação eficiente de dados ao modelo durante o treinamento.
- **Scikit-Learn:** A biblioteca Scikit-Learn foi fundamental para a avaliação do desempenho do modelo, sendo utilizada para dividir os dados em conjuntos de treinamento, validação e teste.

- **Torch.nn:** Através do Torch.nn foi possível fornecer classes e funções para a construção da rede neural, definindo a arquitetura da rede, incluindo a definição da última camada para a tarefa de classificação.
- **Torchvision.models:** Também faz parte da ambiente Pytorch oferecendo modelos de rede pré-treinados. No presente trabalho, foi utilizada para o carregamento do modelo ResNet-50 pré-treinado.

Inicialmente, os dados foram divididos em dois conjuntos: treinamento e teste. Neste processo, uma parte dos dados ficaram em reserva para teste posterior, numa proporção de 20% para o conjunto de teste e 80% para o conjunto de treinamento.

Logo em seguida, o conjunto de treinamento foi dividido novamente com a mesma proporcionalidade: 64% dos dados para o conjunto de treinamento e 16% para o conjunto de validação. Esta divisão adicional é muito importante para o aprendizado de máquina, já que, cria um conjunto de treinamento e um conjunto de validação.

Esse conjunto de validação faz o ajuste de hiperparâmetros (taxa de aprendizado, o número de camadas, a função de ativação, etc) e monitora o desempenho do modelo em dados que não foram usados durante o treinamento. Além disso, a divisão ajuda a prevenir o *overfitting*, ou seja, a rede está se ajustando de modo razoável aos dados de treinamento, mas não consegue processar novos dados. Isso é crítico para verificar se o modelo é capaz de generalizar a novos dados, em vez de simplesmente memorizar o conjunto de treinamento e facilita ajustes à medida que o treinamento progride.

A rede neural construída está adaptada pra o treinamento apenas da camada final, mantendo as camadas pré-treinadas, permitindo, assim, a economia de tempo e recursos computacionais. O modelo ResNet-50 pré-treinado e sua adaptação foram estratégias sólidas para que fosse abordado tarefas de classificação de estados de operação com base em gráficos de radar.

3.4 Treinamento da rede neural

O treinamento da rede neural é uma etapa fundamental para a construção da mesma, para o modelo em questão, foi realizado o treinamento em 100 épocas, onde cada época representa uma iteração completa pelo conjunto de treinamento. No decorrer das 100 iterações, também foram levantados os dados das perdas, que é a medida de quão bem o modelo está se saindo no treinamento. Para a garantia de confiabilidade dessa, rede foi crucial a definição de uma função de perda.

A função utilizada para a definição destas perdas foi a CrossEntropyLoss, que mede a diferença entre as previsões feitas pelo modelo e os rótulos reais dos dados. Cada época desta, tem por objetivo a minimização das perdas, servindo de indicador que o modelo está fazendo melhores previsões.

Além disso, para atualizar os pesos da rede durante o treinamento, foi empregado o otimizador Adam. O otimizador é responsável por calcular os gradientes da função de perda e ajustar os pesos da rede de acordo. Este otimizador é uma escolha comum em tarefas de aprendizado profundo, pois adapta automaticamente a taxa de aprendizado.

Para alimentar os dados de treinamento à rede neural, foi utilizado um DataLoader, que age como um facilitador para iterações eficientes sobre os dados durante o treinamento de modelos, principalmente quando se está trabalhando com um grande volume de dados, o que se aplica na situação do estudo desenvolvido.

Sendo assim, foi realizada a criação de um DataLoader com definição do tamanho do lote como 32. Isso significa que a rede neural é atualizada após processar 32 exemplos de treinamento de cada vez. Além disso, os dados são embaralhados a cada época para que sejam evitadas tendências no aprendizado.

No suceder do treinamento, o modelo perpassa por cada lote de dados e realiza as seguintes etapas ciclicamente:

1. O otimizador anula os gradientes acumulados nas camadas da rede;
2. Os dados de entrada do lote são passados pela rede neural;
3. A função de perda faz o comparativo das previsões da rede com os rótulos reais dos dados;
4. O gradiente da função de perda é calculado para ajuste dos pesos da rede;
5. Esse processo é repetido ciclicamente a cada nova época, com a finalidade que o modelo tenha aprendido a tarefa de classificação com a maior precisão possível de acordo a disposição dos dados fornecidos para treinamento.

É importante ressaltar que esse processo de treinamento não foi realizado cruamente, apenas com uma implementação singular da rede neural proposta. Foram realizados testes de desempenho em diversos cenários distintos, inclusive com um menor número de épocas e com a inserção de cada uma das falhas de conversor.

Para o treinamento desses dados, o sistema responde de maneira mais satisfatória com um modelo com mais épocas, já que permite que o algoritmo ajuste os pesos dos neurônios por mais iterações sobre o conjunto de treinamento, de modo a aprender padrões mais complexos e sutis.

À medida que estas falhas eram adicionadas à rede e havendo uma queda na taxa de acerto, iam sendo realizados ajustes no tratamento destes dados, com a finalidade de tornar os padrões mais evidentes: alterando escala de eixos, avaliando a compatibilidade dos dados obtidos para um tipo de falha específica e removendo incongruências que não condiziam com o padrão observado no tipo de estado em questão, além de análise de recorrência de falhas e seu impacto sobre a taxa de acerto da rede.

4 Resultados

Neste capítulo são apresentados os resultados obtidos e análises referentes ao desenvolvimento da rede neural convolucional aplicado a identificação e classificação de falhas em conversores CA-CC-CA em uma usina eólica.

4.1 Desenvolvimento de um Gráfico de radar

A partir do levantamento dos dados, foi possível gerar 48 conjuntos de gráficos de radar descrevendo a usina geradora eólica operando sem falhas, com falhas relacionadas ao sistema de conversão e outros tipos de falhas relacionadas à outros sistemas da turbina. Essas classificações, ao todo, resultaram em um volume de 7729 gráficos que se distinguem entre si revelando os padrões relacionados.

Este grupo de gráficos representam o sistema ao longo de um ano, isto porque o estudo contempla às mudanças climáticas frente às estações, tendo em vista que existem dois fatores que influenciam diretamente na disponibilidade, e, por consequência, na ocorrência de falhas: a velocidade do vento e as variações de temperatura.

A velocidade do vento, porque as turbinas são projetadas para operar dentro de faixas específicas, e em caso de sobrevelocidade, pode levar à falhas relacionadas aos sistemas de ajuste e angulação das pás, entre outros gargalos; e as variações de temperatura, devido à precipitação e umidade decorrentes das diferentes estações do ano, revelando comportamentos específicos nos equipamentos elétricos e mecânicos, dependendo das condições do tempo do local. Informações estas que foram destacadas, visualmente, nos gráficos de radar, já que observando-se os dados obtidos, vê-se que um conjunto específico costuma apresentar uma ou outra variável mais sobressaliente em relação as demais.

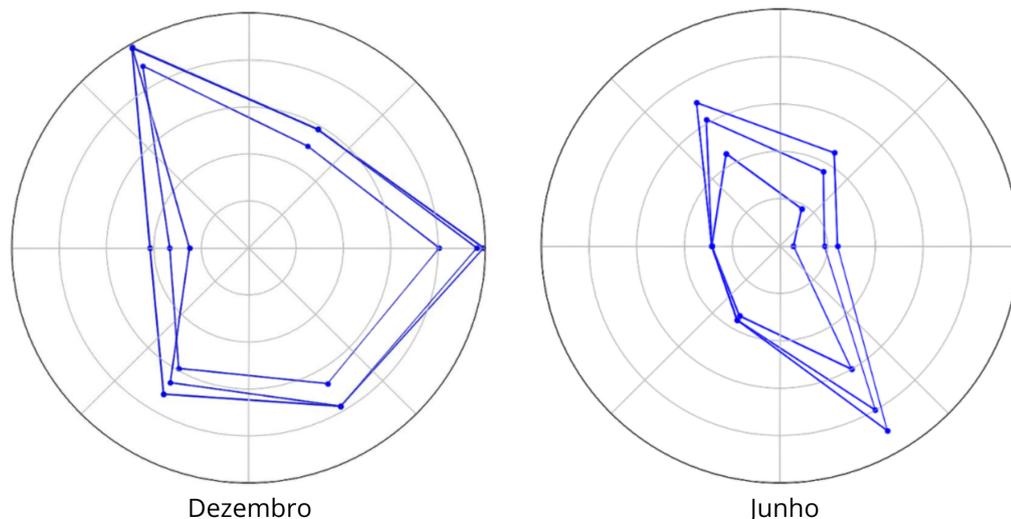
4.1.1 Gráficos em radar para condições normais de operação

Para o primeiro grupo de gráficos de radar, sem nenhum tipo de falha, foram obtidos 3887 gráficos. Analisando-se o conjunto de imagens obtidas, é perceptível que existem diferenças significativas entre cada um deles, não revelando um único padrão para descrever um sistema sem falhas, mas sim, um grupo de padrões. Padrões estes que ficam mais evidentes avaliando-se o comportamento mês a mês.

Os resultados demonstraram que o comportamento de uma turbina em estado normal de operação, para as variáveis analisadas, é volúvel ao longo do ano, demonstrando a influência direta que as condições intrínsecas de cada período causam ao sistema como um todo. No entanto, para cada mês em específico, os valores de cada eixo são relativamente estáveis, em que grande parte dos quadros está sobreposto, tornando a distribuição regular, e por consequência, o padrão que representam.

Tal fato pode ser comprovado nos exemplos presentes na Figura 4.1, no qual foram sobrepostos resultados de três dias diferentes para um mês, sendo o gráfico esquerdo representando o compilado para o mês de dezembro, já o gráfico direito, representando o mês de junho. Observa-se que as representações para o mês de junho e dezembro não apresentam semelhanças suficientes para que exista um padrão claro. No entanto, embora não sejam congêneres, a semelhança entre as sobreposições, para um mesmo mês, é notável. Revelando que, há sim, ramificações de padrões referentes aos meses do ano, que juntos, descrevem o conjunto de dados do sistema sem falhas.

Figura 4.1. Gráficos de Radar de um mesmo mês.



Fonte: Própria autora.

As divergências observadas na magnitude das variáveis medidas pode ser explicada devido, principalmente, como está a velocidade do vento no momento em que foi feito o registro, já que a mesma influencia diretamente três variáveis importantes consideradas na construção do gráfico de radar: a potência gerada, a velocidade do gerador e a velocidade do rotor. Essas grandezas possuem relação proporcional, quanto maior for a velocidade do vento, as pás capturam mais energia cinética, levando o rotor a girar mais rapidamente, que, por sua vez, estando diretamente conectado ao gerador, resulta no aumento da velocidade do mesmo, gerando maior potência.

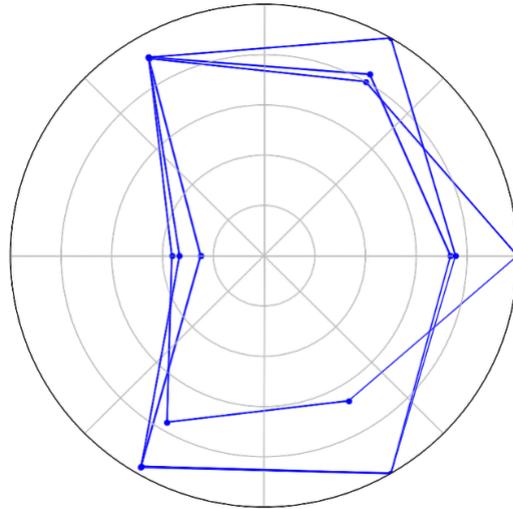
Essas variáveis sofrem influência significativa da velocidade do vento, prova disto, é que são seccionadas em três condições base: a *Cut-in-speed*, ou velocidade de início de rotação, no qual para que a potência comece a ser gerada, o vento precisa atingir uma velocidade mínima e abaixo dessa velocidade o rotor não é capaz de gerar energia significativa; a *Rated Speed*, ou velocidade nominal, onde o rotor e o gerador operam de maneira ótima, gerando a máxima potência que a turbina foi projetada para operar; e, por fim, a *Cut-out speed*, ou velocidade de desligamento, que precisa ser freada na iminência de uma elevada velocidade do vento, a fim de que se evite danos mecânicos.

Em relação aos eixos de temperatura, vê-se que a temperatura ambiente também sofre variações a depender da estação, influenciando na determinação do padrão visto nos gráficos de radar. Em relação a temperatura do gerador, com base em uma análise visual, a mesma acompanha as alterações da temperatura ambiente e da velocidade do gerador, com a elevação destes indicadores, vê-se o aumento também da temperatura no gerador. Tais inferências demonstram que, embora o padrão não seja unitário e disto em condições diversas de tempo e temperatura, as variáveis estão em consonância na análise de um sistema em operação normal e apresentam-se de modo proporcional.

Outra conclusão obtida com a análise dos gráficos de radar para as condições regulares do sistema é que, para uma mesma estação do ano, os padrões também são bastante similares. Isto se deve ao fato de que os padrões de velocidade do vento e temperatura são comuns aos meses de uma mesma estação.

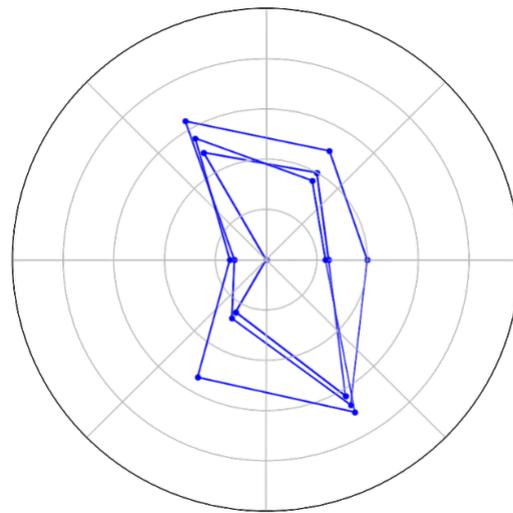
Por exemplo, os eixos de velocidade do vento e potência, mais comumente, são maiores no verão em relação ao inverno, pois é onde se dá o pico de geração eólica, com ventos mais próximos ao da velocidade nominal, e quanto mais próximo desse velocidade nominal, maior é a potência gerada. Essa dinâmica também se reflete nas demais variáveis que compõem o gráfico de radar, com o aumento da velocidade do gerador e temperatura, pelos motivos explicitados anteriormente. Nas Figuras 4.2 e 4.3 são demonstradas as inferências supracitadas.

Figura 4.2. Sobreposição de Gráficos de Radar no verão.



Fonte: Própria autora.

Figura 4.3. Sobreposição de Gráficos de Radar no inverno.



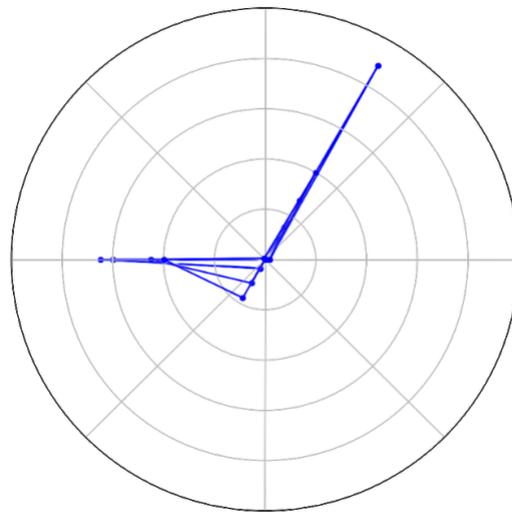
Fonte: Própria autora.

Esse tipo de classificação considerando o espaço amostral de um ano é bastante pertinente, já que para usinas de geração eólica não é possível manter um comportamento sempre constante. A disponibilidade de uma diversidade de amostras evita, posteriormente, que a rede não seja capaz de generalizar novos dados, ou dados não vistos durante a etapa de treinamento. Corroborando, desse modo, na criação de um modelo mais robusto e adaptável, que considera as flutuações sazonais e apresenta melhor desempenho e generalização do modelo.

4.1.2 Gráficos em radar para condições com falhas à parte das do conversor

Em relação ao segundo grupo de gráficos de radar, com outros tipos de falhas, foram obtidos 649 gráficos. Ainda que o espaço amostral englobasse diferentes falhas relacionadas a diversos sistemas da turbina, os diagramas apresentaram semelhanças entre si. O padrão mais frequente exibe um sistema onde as variáveis medidas da velocidade do rotor, velocidade do gerador e a potência estão na origem, como pode ser observado na sobreposição dos resultados, exposto na Figura 4.4.

Figura 4.4. Sobreposição de Gráficos de Radar do padrão mais evidente para outros tipos de falhas.



Fonte: Própria autora.

Os únicos valores descritos por esse grupo, em sua maioria, são da velocidade do vento, temperatura ambiente e temperatura do gerador. Os resultados obtidos são um indicador de que ocorreu uma parada rápida, no qual a potência e velocidade do gerador vão cair à zero muito rápido, pois se entende que é uma situação de emergência, com o sistema operando a vazio por um período muito curto de tempo.

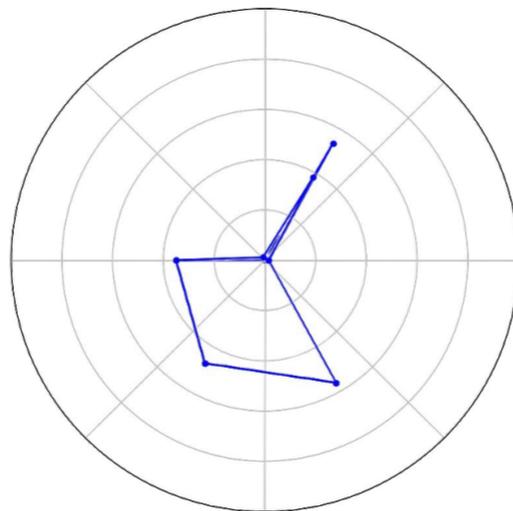
Em se tratando dos demais padrões evidenciados por outras falhas no aerogerador, foi observado um segundo padrão recorrente e bastante similar ao primeiro. A diferença principal entre os padrões se dá pelo eixo de velocidade do rotor que não cai à zero, mantendo-se com valores estáveis. A sobreposição dos gráficos de radar presentes na Figura 4.5 demonstram essa característica, com gráficos tão próximos entre si que se sobrepõem em muitos pontos do eixo.

Esse comportamento pode indicar possíveis falhas no acoplamento mecânico entre o rotor e gerador. Sejam elas: quebras/falhas em acoplamentos ou outros componentes mecânicos, falhas no sistema de transmissão, como por exemplo, na *Gearbox*, ou, até mesmo, uma falha no próprio gerador da turbina, como uma parada no motor que pode levar à

uma interrupção no processo de geração, mesmo com o rotor ainda em funcionamento. Outra possível situação é a de falhas no sistema de frenagem do controle de velocidade do gerador, possíveis problemas nesse sistema são capazes de levar uma queda abrupta da velocidade do gerador.

Em todo caso, ambos os padrões revelam situações mais críticas à turbina, pois a queda abrupta de velocidade do gerador e consequente interrupção de geração da energia, são indicadores bastante alarmantes quando analisamos uma usina de geração eólica. Obviamente que, estas são suposições iniciais de quais falhas poderiam estar relacionadas aos padrões observados. Um diagnóstico mais pontual do problema requer uma análise mais detalhada e com informações adicionais do registro de outros sensores e eventos.

Figura 4.5. Sobreposição de Gráficos de Radar do segundo padrão mais evidente para outros tipos de falhas.



Fonte: Própria autora.

4.1.3 Gráficos em radar para condições de falhas no conversor

Por fim, para o grupo das falhas no sistema de conversor, foram obtidos, no geral, 3194 gráficos, divididos em 48 classificações diferentes respectivamente às diferentes eventos envolvendo a conversão, todos ocorridos no mesmo período de tempo de um ano.

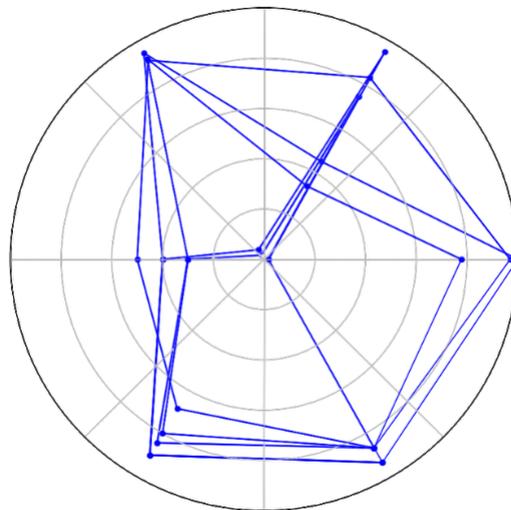
Embora todos descrevessem algum tipo de falha no conversor, cada um apresenta um problema diverso, por exemplo: no sistema de resfriamento do conversor, no sistema de chaveamento, e outras particularidades que, como objetivo principal do trabalho desenvolvido, precisaram ser identificadas como eventos separados para um diagnóstico mais individualista de qual subsistema de conversão apresentava defeito no momento do evento.

Para esse grupo de falhas, é difícil identificar, apenas visualmente, padrões emergentes e semelhanças entre as classificações. Pois alguns eventos apresentaram comportamentos

não repetitivos mesmo se tratando de uma única falha em análise. Prova disto, é a Figura 4.6, em que é exposto um conjunto de gráficos de radar para um só evento, como pode ser visto, os gráficos não coincidem entre si.

Esta variabilidade pode ser explicada pensando na variação de condições operacionais que a falha pode estar ocorrendo, como por exemplo variações na velocidade do vento, temperatura e carga. Outro ponto é que, algumas destas falhas podem sofrer padrões sazonais ou cíclicos, que o fazem variar ao longo do ano analisado. Por exemplo, a fatores externos, como eventos climáticos específicos. Há também a possibilidade do evento ser complexo a ponto de não ocorrerem interações lineares entre suas partes, levando a falha a se manifestar de maneira não uniforme, resultando em padrões de radar variáveis.

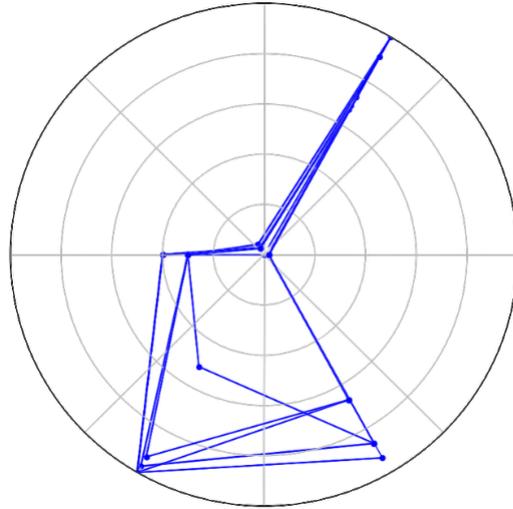
Figura 4.6. Sobreposição de Gráficos de Radar para um evento no sistema de conversão.



Fonte: Própria autora.

No entanto, vale ressaltar que, embora exista diferenças entre os gráficos, nunca é exposto um estado de operação de maneira individual, existe uma repetição bastante similar em alguns pares ainda que não seja em todo o evento analisado, isto pode ser observado na Figura 4.6. É o mesmo evento da Figura 4.5, mas apresenta algumas repetições de padrões, isto acontece, também, para os demais estados de operação vistos na figura anterior.

Figura 4.7. Sobreposição de Gráficos de Radar para o mesmo evento da Figura 4.6.

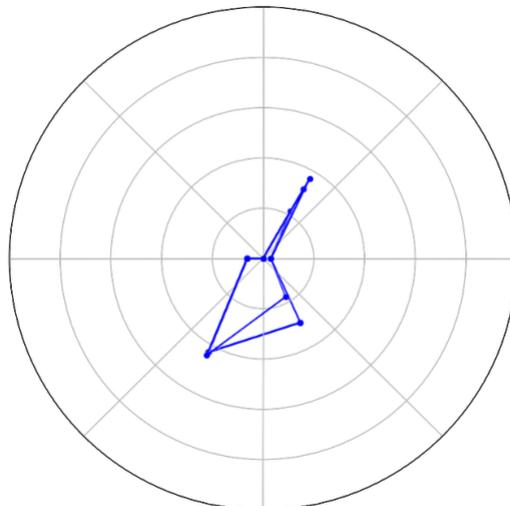


Fonte: Própria autora.

Ainda nas classificações deste grupo, foi possível também identificar eventos com padrões mais claros, como pode ser visualizado na Figura 4.7, permitindo uma distinção mais facilitada dos demais eventos. Vale ressaltar que, embora visualmente alguns eventos pareçam se correlacionar melhor entre si e seja possível identificar padrões, posteriormente, a rede neural possui a capacidade de classificar essas falhas com mais assertividade até mesmo nos eventos com gráficos de radar mais variáveis entre si.

Na Figura 4.8 é descrito um evento de falha em algum subsistema do conversor. Os gráficos estão sobrepostos entre si e é possível observar a semelhança de como o aerogerador opera perante esta falha. Para os demais dados obtidos para esse mesmo evento, percebe-se o mesmo impacto semelhante na resposta do sistema.

Figura 4.8. Sobreposição de Gráficos de Radar para outro evento no sistema de conversão.



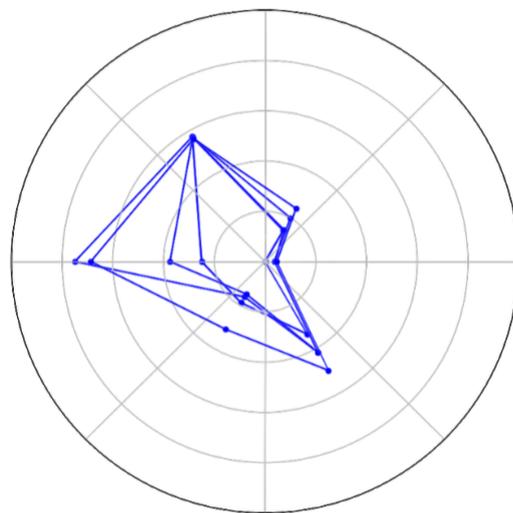
Fonte: Própria autora.

Analisando-se os eventos, de modo superficial, foi inferido que falhas mais complexas ou multifacetadas podem resultar em gráficos de radar mais variáveis, enquanto falhas mais "simples" produzem padrões mais consistentes, isto quando refere-se às falhas de conversores e no espaço amostral analisado, em específico. Pois a gravidade de uma falha é medida de modo bem mais abrangente, considerando as variáveis analisadas e muitas outras mais.

O comportamento das falhas no sistema de conversão é bastante diverso entre si. Porém, é possível diferenciá-lo em relação a outros tipos de falhas e sistema em operação normal com base em duas características: a potência vai à zero, porém o gerador ainda está com velocidade rpm alta; ou ainda, a situação onde a velocidade do gerador cai à zero, mas ainda há potência gerada.

Na Figura 4.9 está descrito um evento com a situação mais observada nas falhas de conversores. Boa parte dos gráficos de radar obtidos, para os mais variados eventos, apresentam uma situação onde a velocidade do gerador está alta, mas a potência cai à zero. Este comportamento indica que são falhas não tão críticas ao aerogerador, nas quais não é preciso uma parada abrupta. A turbina faz a parada mais suavemente, desacoplando o conversor do gerador e com as pás recuando para 90° de modo mais brando.

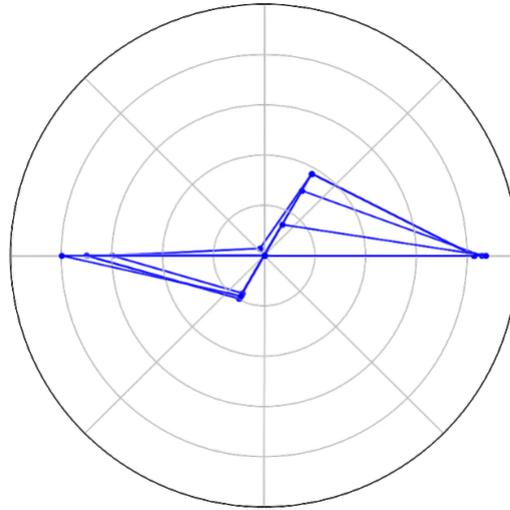
Figura 4.9. Sobreposição de Gráficos de Radar no sistema de conversão sem potência sendo gerada.



Fonte: Própria autora.

Todavia, dentro das 48 classificações, cerca de 13 delas apresentaram um comportamento similar ao visto na Figura 4.10 no que diz a respeito do comportamento da velocidade do gerador estando no eixo do gráfico de radar e a potência, que mesmo nesta situação, ainda é gerada:

Figura 4.10. Sobreposição de Gráficos de Radar no sistema de conversão com potência sendo gerada.



Fonte: Própria autora.

Algumas possíveis explicações para este tipo de cenário são: falha no sistema de retificação que converte a corrente alternada gerada pelas lâminas em corrente contínua, caso ocorra um erro nesse processo, a capacidade do gerador de converter a energia mecânica em eletricidade de forma eficiente é comprometida; isso também pode indicar que o inversor está apresentando problemas que podem resultar em leituras incorretas da velocidade do gerador ou na geração de potência mesmo quando a velocidade do gerador cai a zero.

Além disso, é válido, também, considerar que a falha nos dispositivos de comutação podem levar a um comportamento anômalo. Outrossim, destacam-se o desacoplamento entre o inversor e a rede, problemas no controle de fases e interrupção do fluxo de potência entre o gerador e o inversor como possíveis causas do comportamento visto. No entanto, estas são análises preliminares com base nos dados visualizados, para identificação da causa específica, é crucial uma análise mais aprofundada envolvendo outras verificações imprescindíveis.

Acerca dos dados obtidos, vale ressaltar que o conjunto de outros tipos de falhas possui um volume menor porque foram obtidas falhas no intervalo de um ano. Para o complexo eólico em vista, houveram mais interrupções por falhas no conversor, motivação principal para a realização do estudo voltado à este tipo de ocorrência, do que as demais falhas. Não foram considerados um intervalo maior de tempo devido à complexidade da pesquisa, exigindo mais tempo para análise e tratamento de dados.

De modo geral, os gráficos de radar obtidos já demonstraram padrões específicos a cada modo de operação. Por possuir um grau de complexidade elevado a interpretação e identificação de padrões, métodos tradicionais não possuem tanto êxito. No entanto, sendo aplicadas técnicas de aprendizado de máquina, é possível que seja feita uma abordagem

poderosa e eficaz, detectando relações não triviais e identificando nuances não visíveis em análises tradicionais.

Esta combinação é excelente e bastante útil em se tratando de planejamento de manutenção. Pois ajuda a prever a ocorrência de falhas com base nos padrões identificados no gráfico do radar, permitindo manutenções preventivas necessárias. Ademais, entendendo os padrões associados a diferentes tipos de falhas pelo tempo, é possível priorizar atividades de manutenção com base na gravidade e na probabilidade de ocorrência, alocando os esforços e recursos de maneira mais eficiente.

Ainda acerca das tendências temporais, este tipo de análise pode fornecer informações valiosas acerca da degradação do desempenho de componentes específicos, entendendo e corroborando para a otimização do ciclo de vida dos componentes, além de aprimorar as estratégias de substituição dos mesmos. Todos estes fatores são incisivos para o aumento da disponibilidade, com menores custos por paradas não planejadas e emergências causadas por falta de análise preditiva.

Os gráficos de radar, juntamente com a ResNet-50, utilizada no presente trabalho, oferece uma abordagem inovadora para o planejamento de manutenção em aerogeradores, permitindo uma gestão mais eficiente, proativa e orientada por dados reais do parque eólico. Tendo em vista que, o pré-treinamento de uma ResNet-50 com o conjunto de dados ImageNet implica que este tipo de rede aprende a representação de características visualmente distintas e pode ter uma capacidade de generalização melhor para padrões visuais. Transferindo esse conhecimento para um conjunto de gráficos de radar, podemos obter benefícios sem a necessidade de grandes volumes de dados rotulados.

4.2 Evolução da taxa de acerto

Com o grupo de gráficos de radar obtidos, foi possível realizar a implementação de uma Resnet-50 adaptada para melhor compreensão e extração de padrões significativos para o conjunto. No entanto, é importante notar que os gráficos de radar podem ter características específicas que não são bem representadas por objetos cotidianos presentes no ImageNet. Portanto, para a execução do trabalho, foi preciso realizar o treinamento constante da rede em pauta, ajustando o modelo com dados específicos deste domínio para otimizar o desempenho no contexto dos gráficos de radar.

A precisão de uma rede, descrita pela taxa de acerto, é um indicador da capacidade da mesma de distinguir entre as diferentes classes exploradas neste trabalho por meio dos gráficos de radar. Explorando a evolução da taxa de acerto, podemos traçar não apenas a eficácia do modelo ao longo do tempo, mas também avaliar como ocorre a adaptação e o aprendizado com base nas mudanças propostas. A ResNet-50 implementada passou por diversas modificações para que ocorresse um aprendizado contínuo da mesma, a evolução

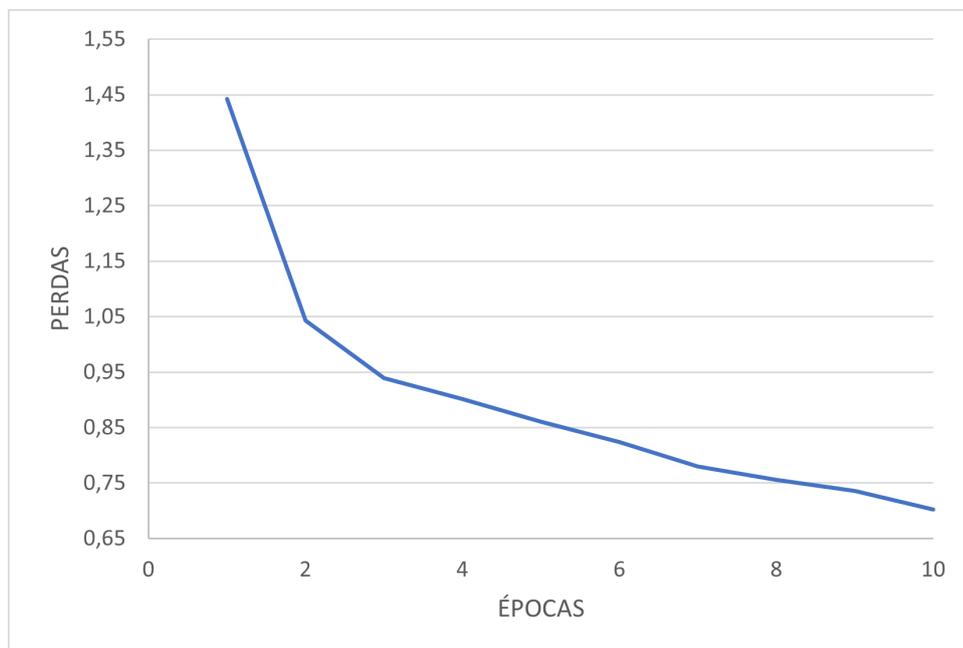
da taxa de acerto reflete esse processo de adaptação e capacidade de generalização do modelo em relação aos padrões identificados nos gráficos de radar.

Inicialmente, foi obtida uma taxa de acerto de 77,03% considerando as 48 classes com o treinamento sendo realizado em 10 épocas. A percentagem alcançada não é considerada satisfatória para a aplicação proposta, tendo a necessidade de meios para evolução da taxa de acerto para que o aprendizado da rede seja mais satisfatório.

A Figura 4.11 demonstra as perdas ao longo das épocas para este resultado inicial. Analisando os resultados, é possível verificar uma diminuição gradual ao longo das 10 épocas, indicando que o modelo estava aprendendo com o conjunto de treinamento. A redução da perda é uma indicação positiva, pois implica que a rede está ajustando seus pesos de maneira a minimizar a diferença entre as previsões e rótulos reais.

No entanto, não exime o fato de que a taxa de acerto não apresentou aumento significativo após as primeiras épocas. Este acontecimento pode ser um indicativo de um possível *overfitting*, demonstrando que o modelo aprendeu muito bem os padrões específicos do conjunto de treinamento, mas não consegue generalizar novos dados com êxito.

Figura 4.11. Gráfico das perdas para o cenário inicial.



Fonte: Própria autora.

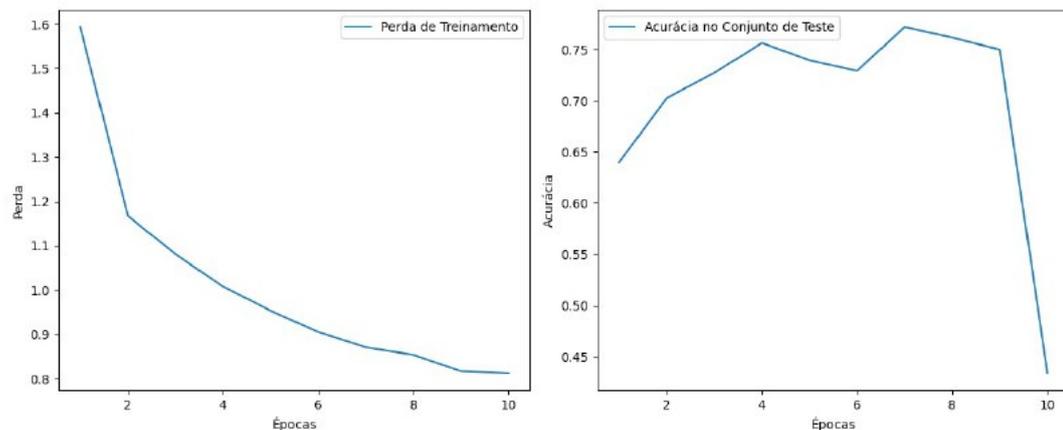
Com o objetivo de compreender o que estava acontecendo durante a aprendizagem da rede, o treinamento foi refeito, adicionando ao código uma métrica de avaliação: o gráfico das acurácias e perdas. Com este novo teste, a taxa de acerto resultante foi de 43,4%. Este resultado, mesmo sem ter feito nenhuma alteração significativa no modelo e nem nos dados, é muito importante de ser avaliado, pois pode ser devido a influência da

inicialização aleatória dos pesos, que são redefinidos na última camada para que fosse feita a adequação à tarefa de classificação proposta. Com o novo teste, os pesos iniciais foram alterados, levando a variação de desempenho, o que é um fator muito recorrente em redes neurais profundas.

Em algumas execuções, os pesos podem começar de maneira que o modelo converge para uma solução que atinge altas taxas de acurácia, enquanto em outras execuções, os pesos podem resultar em um modelo que converge para uma solução menos eficaz. Pelo o resultado obtido, acredita-se que o modelo ainda não tenha convergido completamente, e, muito provavelmente, o conjunto de dados desbalanceados colaborou com esse desfecho. Por isto a importância de ser feito o monitoramento da acurácia no conjunto de validação, ajudando a avaliar se o modelo está convergindo. A Figura 4.12 demonstra o gráfico das acurácias e perdas para a rede em seu estado inicial, mas com um novo treinamento.

Analisando o gráfico exposto na figura 4.12, vê-se que nas primeiras épocas as perdas caem de modo considerável, ao passo que a acurácia no conjunto de teste ascende, indicando um aprendizado eficaz. Por volta da quinta época, o aprendizado é desacelerado, demonstrando que as perdas não diminuem mais no mesmo ritmo, a acurácia também aumenta, porém a partir da oitava época, nota-se que a rede não atinge uma estabilidade, muito pelo o contrário, o aprendizado começa a decrescer, indicando que a rede não atingiu o ápice do potencial requerido.

Figura 4.12. Gráfico de perdas e precisão com o novo treinamento.



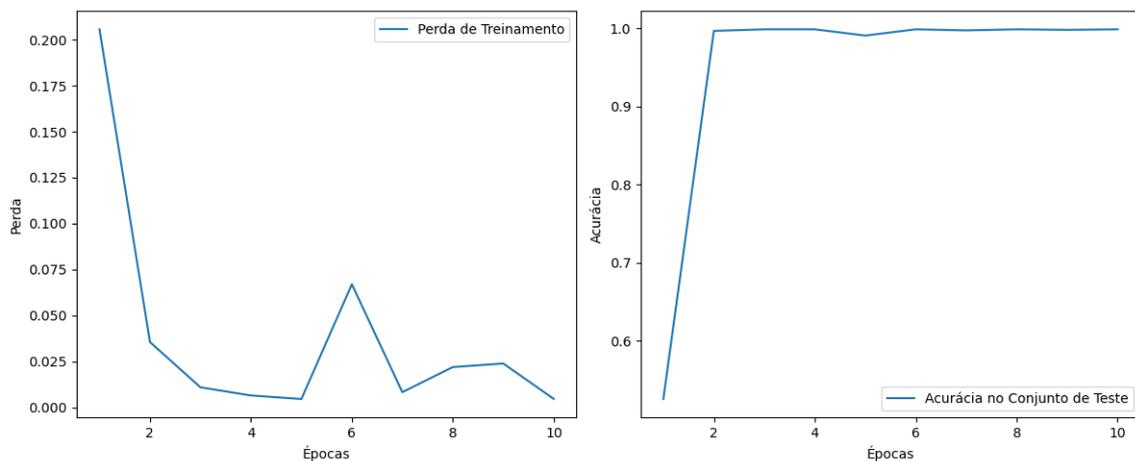
Fonte: Própria autora.

A queda ocorrida por volta da 8ª época pode ser atribuída à complexidade da função de perda e à estocasticidade do treinamento de redes neurais. Além disso, existe uma influência da variedade de padrões do conjunto de dados, que corroboram com oscilações devido à exploração intensiva antes da convergência para padrões mais representativos, especialmente em conjuntos desbalanceados. Sendo assim, para o cenário inicial, com o novo treinamento atingiu-se uma acurácia de apenas 0,4340; sendo um reflexo dos motivos supracitados.

Liu *et al.* (2020) obteve diagnósticos com uma acurácia de 94,87% e um falso positivo de apenas 5,13%, isto para um cenário classificando falhas de conversores, de modo geral, sem a divisão por eventos como é proposto neste trabalho. De modo a validar a escolha da Resnet-50 e da utilização dos gráficos de radar ao invés de simplesmente o carregamento das planilhas, foi realizado um teste considerando apenas três classes de dados: sistema em operação normal, com falhas nos conversores (todas como um único tipo de falha) e com outros tipos de falhas. Para o volume de dados utilizado, foi possível alcançar uma taxa de acerto de 99,87%, mais acurada em comparação ao resultado encontrado pelo autor.

Este resultado, de certa forma, valida a escolha da rede e também do meio para a disposição dos dados, demonstrando que, de fato, o aprendizado da rede via gráficos de radar atende de forma satisfatória para uma situação de falhas em conversores. Com base na Figura 4.13, vê-se que até a segunda época as perdas são reduzidas subitamente da mesma forma que a acurácia do conjunto de teste atinge um ponto de estabilidade, servindo de um indicador que a rede atingiu a convergência, chegando na sua capacidade máxima de aprendizado, alcançando uma acurácia de 0,9987.

Figura 4.13. Gráfico de perdas e precisão com três classes.

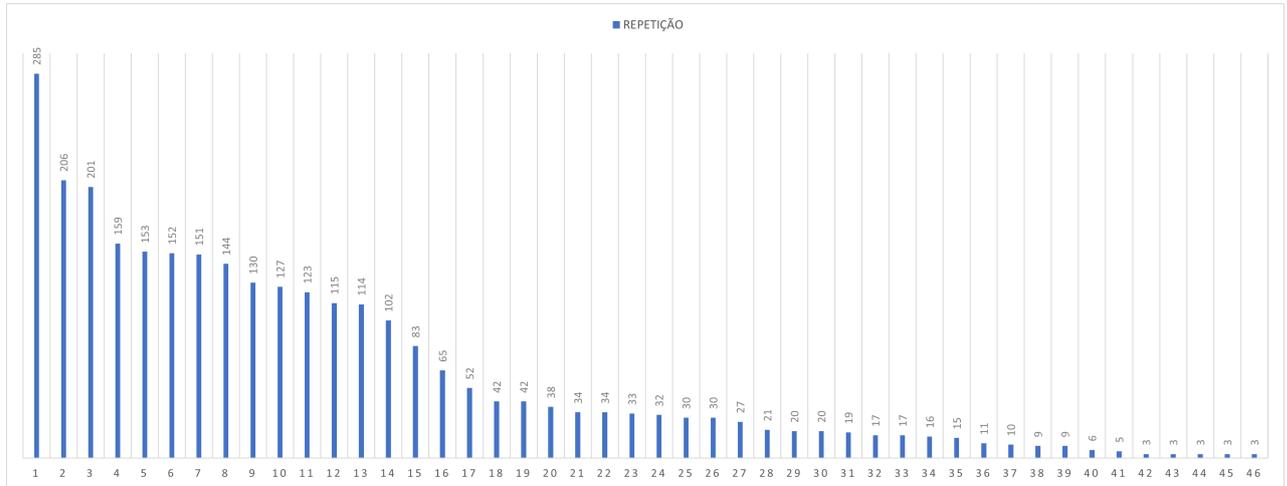


Fonte: Própria autora.

4.2.1 Evolução da taxa de acerto pelo o número de falhas

Devido ao sucesso do teste com apenas três classes, foi pensado na avaliação de como a acurácia se dava com a adição das classes paulatinamente. Admitindo-se que, a recorrência de uma falha pode influenciar no sucesso de treinamento da rede. Os eventos levantados não ocorriam de maneira equivalente, alguns eram mais frequentes que os demais. A Figura 4.14 descreve o pareto dos eventos pela recorrência dos mesmos num intervalo de um ano. A falha mais recorrente se repetiu 285 vezes, enquanto as menos recorrentes repetiram-se 3 vezes apenas.

Figura 4.14. Pareto das falhas com a recorrência.

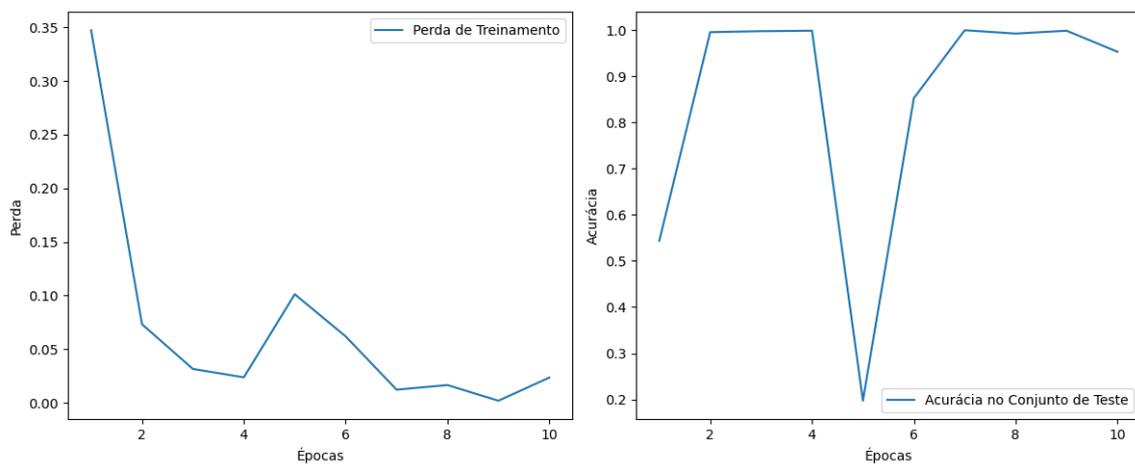


Fonte: Própria autora.

O fato de não haver um balanceamento entre as classes influencia diretamente no aprendizado da rede, pois o modelo acaba tornando-se mais inclinado a prever as classes majoritárias com mais frequência. Isso faz com que o desempenho do modelo varie significativamente entre as classes, com classes menos representadas tendo uma performance inferior devido à falta de dados para aprendizado eficaz.

A influência do desbalanceamento na acurácia do modelo foi demonstrada experimentalmente com a adição da falha mais recorrente à falhas menos recorrentes e a avaliação do aprendizado para cada caso. No primeiro cenário, a rede foi montada com apenas três classes: a da falha de conversor mais recorrente, outros tipos de falhas e a operação em condições normais.

Figura 4.15. Gráfico de perdas e precisão com a falha mais recorrente do conversor.



Fonte: Própria autora.

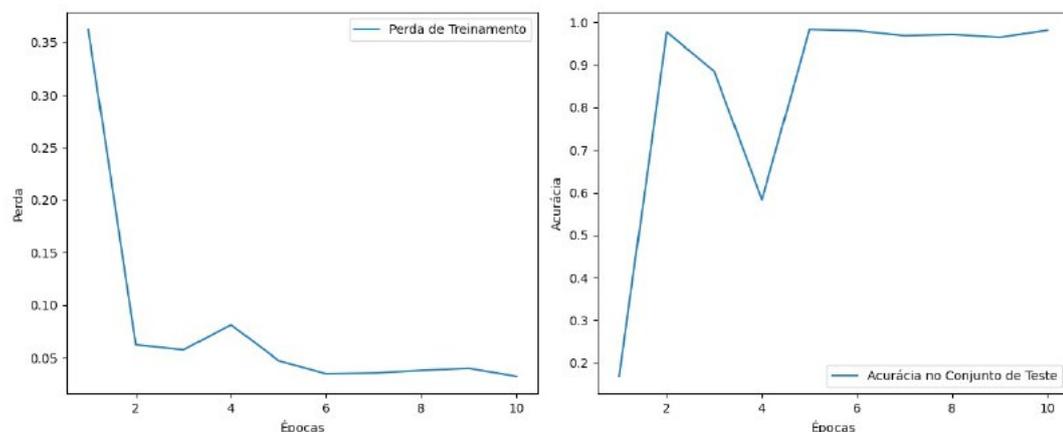
Analisando o gráfico das perdas e precisão, presente na Figura 4.15, é perceptível que

até a quarta época a rede apresenta um aprendizado consistente com as perdas sendo reduzidas a cada novo treinamento, mesmo com a instabilidade na quinta época, a rede volta a reduzir as perdas. Mesmo com uma acurácia de 0,9533; a rede não atinge a estabilidade na décima época, ou seja, ainda há potencial para um melhor aprendizado realizando os devidos ajustes.

Seguindo as análises, foi realizado um novo teste considerando sete classes, sendo cinco delas referentes às cinco falhas de conversor com maior recorrência e as outras duas sendo o sistema sem falhas e com outros tipos de falhas, o resultado obtido está presente na Figura 4.16.

Com o acréscimo das classes, a acurácia no conjunto foi aumentada, atingindo 98,12%. Como já observado em cenários anteriores, a queda brusca nas perdas nas primeiras épocas acompanhadas de aumento na taxa de acerto, é um parâmetro positivo, sinal de que o modelo estava eficazmente ajustando os pesos e adequando-se aos dados de treinamento. A queda na acurácia, juntamente com o aumento das perdas, é um fator crítico, no qual o modelo se ajustou muito rigorosamente aos dados de treinamento e não desenvolveu a habilidade de generalizar novos dados.

Figura 4.16. Gráfico de perdas e precisão com as cinco falhas mais recorrentes do conversor.



Fonte: Própria autora.

O fato de a acurácia se estabilizar após o sexto treinamento pode indicar que o modelo alcançou um ponto em que não mais está aprendendo ou está aprendendo muito lentamente. Ou ainda, que o modelo atingiu a capacidade máxima de aprendizado com os dados disponíveis ou que está preso em um mínimo local na função de perda, onde o algoritmo de otimização não alcança o mínimo global, mas sim uma solução localmente ótima.

Com esse resultado, é possível inferir que o número de classes, por si só, não determina o desempenho de uma rede neural. O que realmente determina é a complexidade dos padrões que a rede precisa aprender para realizar a distinção entre elas. As sete classes utilizadas neste cenário possuíam padrões distintivos entre as classes muito bem definidos.

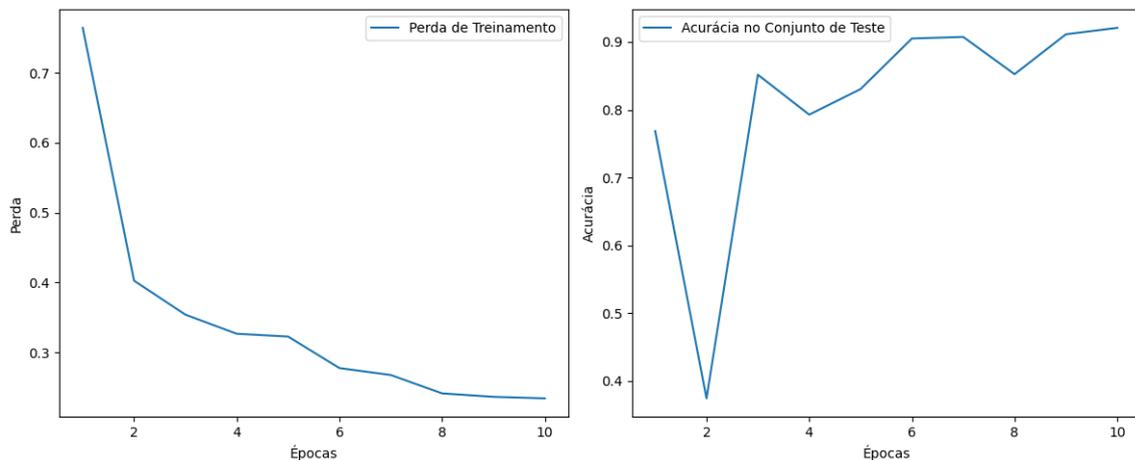
Além disso, o desbalanceamento entre os dados, principalmente entre os eventos não é tão distoante, variando entre 280 à 150 repetições, aproximadamente.

Com a finalidade de evoluir nas análises, acrescentou-se mais cinco classes de falhas de conversores na sequência decrescente de repetições, expondo o modelo a um cenário com maior desbalanceamento já que a recorrência dos eventos é cada vez menor, com a diferença de mais de cem dados entre elas. Desta vez, o taxa de acerto da rede decresceu algumas unidades, alcançando uma acurácia de 92,07%. A Figura 4.17 demonstra a curva de aprendizado do modelo.

Analisando as curvas de aprendizado da rede, é visto que a acurácia no conjunto de teste apresenta mais vales e picos em comparação aos testes anteriores. Este comportamento revela um aspecto relevante, pois pode ser um indicativo de que o treinamento está encontrando dificuldades em épocas específicas, que podem ser resultado de muitos fatores: variação nos dados do treinamento, sensibilidade da otimização a certas configurações, etc.

Acredita-se que um dos fatores principais para essas variações na acurácia são devidas ao desbalanceamento das classes ter aumentado, tornando a rede mais sensível a algumas classes do que outras. Vale ressaltar que, o desbalanceamento não ocorre somente entre as classes de eventos em conversores. O volume de dados sem falhas é muito maior que os outros conjuntos e o de outros tipos de falha também supera qualquer um dos conjuntos de dados para falhas de conversor.

Figura 4.17. Gráfico de perdas e precisão com as dez falhas mais recorrentes do conversor.



Fonte: Própria autora.

No entanto, mesmo com o risco de influência negativa sobre a taxa de acerto, acredita-se que para uma melhor representação da operação de um complexo eólico ao longo de um ano, é essencial que os dados englobem todas as esferas e condições as quais a usina de geração é exposta. Isso justifica o volume aumentado de dados nos outros casos, que foram considerados para que não houvesse chances de algum estado não ser representado.

Apesar dos vales encontrados no decorrer das épocas, o aumento consistente da acurácia é um sinal positivo. Apesar das oscilações, a rede está aprendendo e melhorando seu desempenho global, e a redução consistente das perdas reforça isso, pois o modelo segue ajustando os pesos para minimizar a divergência entre os rótulos reais e as previsões feitas.

Foram realizados outros testes acrescentando mais falhas ao modelo e em cada acréscimo a taxa de acerto, na maioria da vezes, era cada vez mais afetada, com uma acurácia cada vez menor. O que era de esperar, já que à medida que o número das classes aumenta, a tarefa de classificação torna-se mais difícil; ainda mais pelo o fato de o número de dados de treinamento não aumentar proporcionalmente ao número de classes, fazendo com que as novas classes não sejam tão bem representadas quanto as demais.

Os resultados obtidos estão presentes na Tabela 4.1 que relaciona a acurácia do modelo pelo o número de classes utilizados em cada um dos casos. Analisando os valores encontrados, é evidenciada a necessidade de analisar métodos para que a rede performe de modo mais satisfatório.

Tabela 4.1. Relação da acurácia pelo o acréscimo de classes.

Número de classes	Acurácia do modelo
3 classes	95,33%
7 classes	98,12%
12 classes	92,07%
22 classes	74,63%
32 classes	61,26%
48 classes	43,4%

Fonte: Própria autora.

Embora o aumento de classes não tenha conduzido diretamente a uma queda na precisão, a complexidade da tarefa de classificação com o aumento de classes desbalanceadas é intrinsecamente mais desafiador, influenciando diretamente na acurácia do modelo. Todavia, é importante refletir acerca dos resultados e estudar métodos que permitam a rede ter melhor desempenho para tarefas mais complexas. Para isto, testes com um número maior de épocas foram realizados.

4.2.2 Evolução da taxa de acerto pelo o número de épocas

A rede neural ainda pode ser melhorada para que torne-se mais habilidosa no processo de classificação. A trajetória percorrida em cada um dos modelos executados e os resultados obtidos servem de base para a construção de hipóteses de melhorias a serem aplicadas.

Com base nos gráficos de perdas e precisão, nota-se que nenhuma das curvas de aprendizado com mais classificações chega a um ponto de convergência para o número de

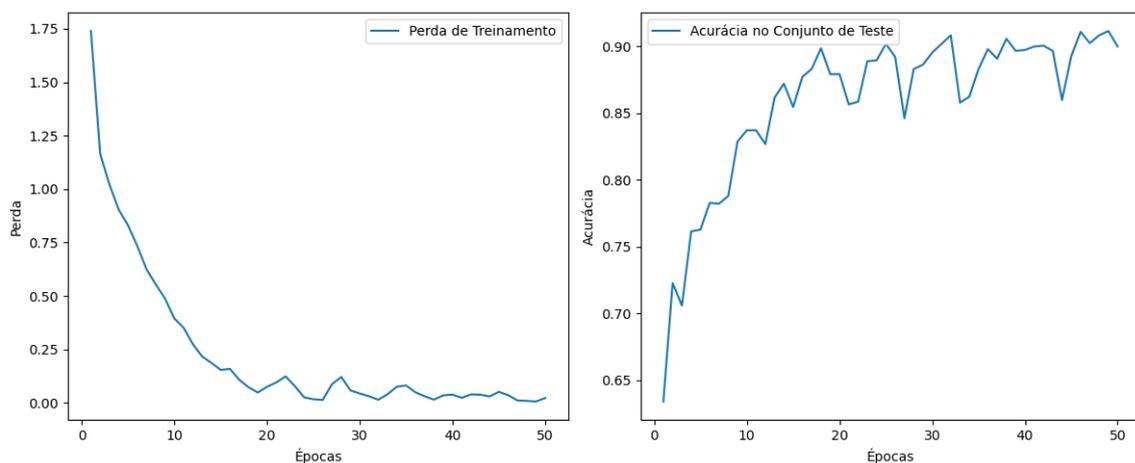
épocas definido (dez épocas), evidenciando a necessidade de refazer o treinamento com ajustes nos hiperparâmetros da rede, sendo um deles, o próprio número de épocas.

Esta estratégia, embora seja simples, é bastante eficaz pois permite que o modelo continue a aprender padrões nos dados por um período mais longo. Como cada época representa uma passagem completa pelo o conjunto de treinamento, isso permite que a rede vá continuamente ajustando os pesos para minimizar a função de perda. Mais épocas implicam em mais oportunidades para o refinamento.

Como está sendo utilizada a ResNet-50, um modelo de aprendizado profundo, é muito vantajoso aumentar o número de épocas porque permite que a rede capture padrões complexos e representações hierárquicas mais profundas nos dados. Logo, o desempenho da rede é superior, ainda mais para o caso em análise onde existe um conjunto de dados de ampla variedade de padrões e características.

Outrossim, *deep learnings* possuem a capacidade de reduzir erros residuais corrigindo previsões incorretas feitas durante as primeiras épocas; continuar o processo de treinamento, permite com que o modelo amenize esses erros. Com base nas vantagens supracitadas, buscou-se a melhoria da rede com o ajuste do hiperparâmetro das épocas, juntamente com os gráficos de radar normalizados. Inicialmente, foi estipulado um aumento para 50 épocas, na Figura 4.18 é demonstrado o desempenho da rede para as dadas condições:

Figura 4.18. Gráfico de perdas e precisão com 50 épocas.



Fonte: Própria autora.

Por resultado, a acurácia alcançou o valor de 89,97% ao longo das 50 épocas, demonstrando o aumento da capacidade da rede neural em aprender padrões com o ajuste deste hiperparâmetro. Como esperado, um maior número de treinamentos permitiu que o modelo explorasse mais profundamente a paisagem da função da perda, permitindo a saída de mínimos locais em busca de soluções ótimas.

Comparativamente, ao considerar treinamentos com um número menor de épocas, observamos um ganho substancial de acurácia ao estender o treinamento para 50 épocas.

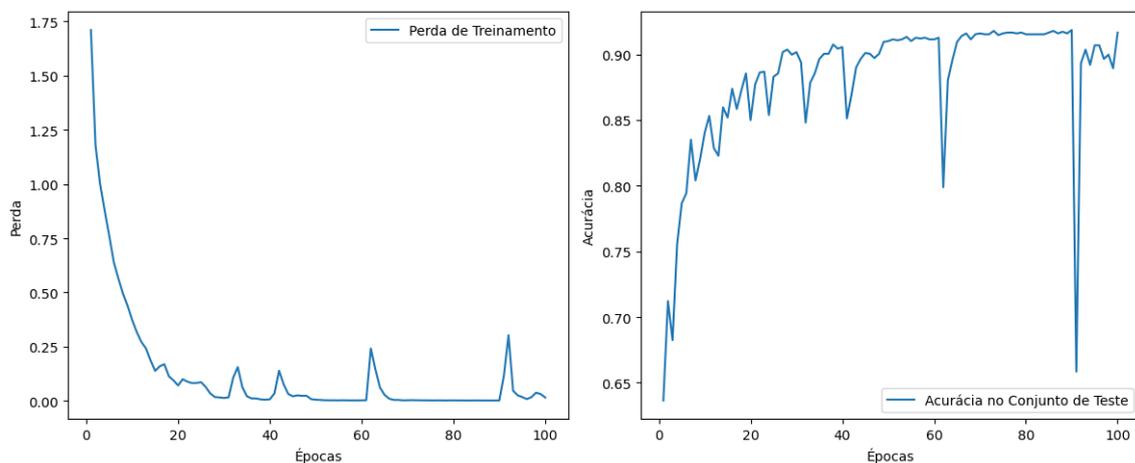
Essa análise ressalta a importância do ajuste adequados dos hiperparâmetros da rede, inclusive, das épocas; destacando como a capacidade da rede evolui significativamente com períodos de treinamento mais longos.

Examinando o gráfico das perdas e precisão, nota-se que as perdas possuem um comportamento consistente de queda, enquanto a acurácia permanece crescendo ao longo das épocas, mantendo-se sem grandes alterações a partir da 30^o época. Todavia, o modelo possui oscilações durante os treinamentos, mas por não se apresentarem de forma muito pronunciadas, acredita-se que não é um indicador de instabilidade no treinamento.

Como o modelo não parecia estabilizar-se nos últimos treinamentos feitos, foi considerado um aumento nas épocas em busca de encontrar um ponto de convergência para o modelo. Sendo assim, um novo modelo de 100 épocas foi configurado, a Figura 4.19 demonstra o desempenho com o ajuste, alcançando uma acurácia de 91.66%.

O aumento do desempenho com o aumento das épocas comprova que, de fato, o ajuste proposto é efetivo. Analisando o gráfico, é possível inferir que a rede poderia aumentar a acurácia com um intervalo maior de épocas, pois o modelo não parece atingir um ponto final de convergência. Todavia, um aumento no número de épocas geralmente resulta em um tempo de treinamento maior, exigindo muito esforço de máquina, o que não foi possível considerar com base nas condições existentes para execução do presente trabalho.

Figura 4.19. Gráfico de perdas e precisão com 100 épocas.



Fonte: Própria autora.

Vale ressaltar, que o desbalanceamento entre as classes é um gargalo considerável na busca de maior acurácia no modelo. Ademais, vale destacar que o conjunto de dados utilizados no treinamento consideram dois modelos distintos de turbina, modelar uma rede que classifique estados de operação simultâneos para dois modelos estruturais diferentes entre si é uma manobra arriscada e que pode ter influenciado negativamente no processo de aprendizagem.

De toda forma, o modelo demonstrou um aprendizado consistente nas últimas épocas de treinamento, a queda ocorrida por volta da 90^o época seguida de uma recuperação na acurácia pode ser atribuída à complexidade da função de perda. A rede neural pode ter saído de um mínimo local ou de uma região de difícil otimização e, posteriormente, encontrado um caminho para um mínimo global ou uma região mais otimizável.

Além disto, devido a variedade de padrões do conjunto de dados, a queda também pode ser um indicador de uma exploração intensiva antes de convergir para padrões mais representativos. Pois este comportamento oscilante, pode sim, ser influenciado pelo tipo de exemplo de dados presentes em um lote específico.

Em adicional, a estocasticidade inerente ao treinamento de redes neurais pode causar flutuações temporárias na acurácia, especialmente em conjuntos de dados desbalanceados, que é o caso do estudo realizado.

Como já comprovado em modelos anteriores, a inicialização aleatória dos pesos leva a diferentes configurações iniciais, afetando a aprendizagem do modelo durante cada treinamento. A seleção estocástica de lotes de treinamento em cada época pode resultar em diferentes conjuntos de exemplos a cada iteração, isso introduz variação no processo de atualização de pesos.

Todavia, os ajustes implementados resultaram em um modelo bastante funcional. Esse desempenho significativo representa não apenas um resultado pontual, mas uma demonstração da estabilidade e confiabilidade do modelo. A elevada acurácia obtida sugere uma detecção mais confiável de falhas, promovendo intervenções mais eficientes e contribuindo para a redução dos custos de manutenção. Por isso, o resultado final obtido foi considerado satisfatório à situação proposta.

No próximo capítulo serão apresentadas as conclusões do trabalho e sugestões de melhorias futuras.

5 Considerações Finais

A rede neural desenvolvida teve como base a classificação de gráficos de radar elaborados com dados advindos do sistema SCADA com finalidade de representar o comportamento de um parque eólico ao decorrer de um ano no que diz respeito a estados de operação: sem falhas, com falhas de conversores e com outros tipos de falhas. Os gráficos de radar condensaram variáveis técnicas de: velocidade do gerador, velocidade do rotor, potência gerada, velocidade do vento, temperatura ambiente e temperatura do gerador a partir de dados registrados em intervalos de 10 em 10 minutos no período de Setembro/21 à Setembro/22

Os resultados apresentados delineiam o progresso e os desafios enfrentados no desenvolvimento da rede neural para diagnósticos de falhas em conversores eólicos. Através da avaliação da acurácia resultante, gráficos de perdas e precisões frente às soluções implementadas, foi possível traçar estratégias que funcionam de modo mais satisfatório no diagnóstico de falhas de conversores CA-CC-CA de turbinas eólicas.

Em se tratando dos gráficos de radar, observou-se que os mesmos são capazes de representar padrões de modo satisfatório e para uma ResNet-50, pré-treinada com o Imagenet, a representação visual rica dos padrões demonstrada por esses gráficos, revelou-se benéfica para o tipo de aplicação do projeto desenvolvido corroborando com um aprendizado mais eficaz. O conjunto obtido revelou características intrínsecas a cada tipo de estado de operação que puderam ser observadas visualmente.

Para o grupo de gráficos de radar sem falhas, viu-se que há ramificações de padrões referentes aos meses do ano, que juntos, descrevem o comportamento no estado normal de operação. Além disto, analisando os resultados, é possível observar a volatilidade das variáveis ao longo do ano, mas que se apresentam de modo relativamente regular para cada mês específico. Também foi possível notar que para a mesma estação do ano, os padrões também são similares. Tais inferências demonstram que, embora o padrão não seja unitário e distoia em condições diversas de tempo e temperatura, as variáveis estão em consonância na análise de um sistema em operação normal e apresentam-se de modo proporcional.

Em relação aos gráficos de radar para outros tipos de falhas, foram observados dois padrões mais recorrentes relacionados a essa classificação. Em ambos os casos, a rápida queda na velocidade do gerador e a interrupção abrupta na geração de energia sugerem

situações críticas e de emergência para a turbina eólica. O primeiro padrão está relacionado a paradas repentinas, onde a potência e velocidade do gerador diminuem rapidamente até atingirem zero, indicando um cenário de emergência com operação a vazio por um curto período. O segundo padrão possui comportamento semelhante, mas se diferencia na estabilidade no eixo de velocidade do rotor.

Já os gráficos de radar para falhas em conversores apresentaram mais nuances em relações a outros grupos, a possibilidade de eventos complexos, com interações não lineares entre suas partes, contribuiu para a manifestação não uniforme dessas falhas, resultando em padrões de radar variáveis. O comportamento diversificado das falhas no sistema de conversão permite diferenciá-las de outros tipos de falhas e do funcionamento normal do sistema, destacando duas características distintas: a potência cai a zero, mas o gerador mantém uma velocidade rpm alta; ou a velocidade do gerador cai a zero, mas ainda há potência gerada. A predominância de gráficos que mostram a velocidade do gerador alta, mas a potência zerada, sugere que essas falhas de conversores são menos críticas ao aerogerador, permitindo uma parada mais suave e com menos danos à turbina.

A partir do conjunto de dados tratados uma rede neural ResNet-50 foi implementada, obtendo uma taxa de acerto inicial de 77,03%; alcançada em 10 épocas e com gráficos não normalizados para um conjunto de 48 classificações de tipos de estado. A escolha da Resnet-50 juntamente com os gráficos de radar sugeridos por Liu *et al.* (2020) foi validada com o excelente resultado de uma taxa de acerto de 99,87% para três classes de dados, evidenciando a eficácia da abordagem. A busca pela construção de um modelo mais funcional permitiu que fossem explorados métodos de adequação de uma rede neural com finalidade de maior taxa de acerto e mapeamento dos possíveis ofensores do sucesso no processo de aprendizagem da rede.

A priori, a análise de adição de classes à rede demonstrou que o número de classes não é o único determinante do desempenho de uma rede neural; a complexidade dos padrões que a rede precisa aprender é que de fato é crucial para a distinção eficaz entre eles. Todavia, a falta de balanceamento entre as classes afeta o aprendizado da rede, tornando-a inclinada a prever as classes majoritárias com mais frequência. Isso resulta em variações significativas no desempenho entre as classes, prejudicando as menos representadas devido à falta de dados. Isso se comprova no decréscimo da acurácia da rede neural ao serem acrescentadas classes com menor índice de recorrência ao longo do ano, no qual a taxa do acerto do modelo cai de 95,33% para 43,4%.

E, por fim, o ajuste de hiperparâmetros foi explorado no processo de melhoria de taxa de acerto, já que os treinamentos anteriores demonstraram não convergir satisfatoriamente com apenas dez épocas. Utilizando a ResNet-50, a vantagem de aumentar o número de épocas é destacada, permitindo que a rede capture padrões complexos e representações hierárquicas mais profundas nos dados. De modo a reduzir erros residuais ao longo das épocas, corrigindo previsões incorretas e refinando o modelo. Ao treinar por 50 épocas,

a acurácia alcançou 89,97%, evidenciando a capacidade crescente da rede em aprender padrões com o ajuste desse hiperparâmetro. Com um modelo configurado para 100 épocas, a acurácia atingiu 91,66%, sugerindo que um intervalo ainda maior de épocas poderia melhorar a precisão.

Apesar da inicialização aleatória dos pesos introduzir variações, os ajustes implementados resultaram em um modelo funcional, demonstrando estabilidade e confiabilidade. A elevada acurácia obtida sugere uma detecção mais confiável de falhas, contribuindo para intervenções eficientes e a redução dos custos de manutenção. Ressalta-se que o desbalanceamento entre os dados de entrada afetou de modo considerável o sucesso do modelo, especialmente considerando o fato de que existia ainda uma subdivisão desses dados entre dois modelos distintos de turbina.

5.1 Trabalhos futuros

Este estudo não apenas valida a eficácia do modelo proposto, mas também lança luz sobre direções futuras promissoras. Como sugestão para trabalhos futuros, considera-se:

1. A importância do estudo para um maior espaço de tempo, a fim de que o problema do desbalanceamento de dados seja evitado;
2. Adotar técnicas como *data augmentation* gerando novos exemplos sintéticos visando equilibrar a distribuição;
3. Explorar arquiteturas adicionais;
4. Ajustes nos hiperparâmetros e técnicas de regularização;
5. Avaliação do desempenho do modelo para além da precisão, com base em métricas apropriadas para dados desbalanceados, como por exemplo: recall, F1-score, AUC-ROC, entre outras.

Referências

ABEEÓLICA. Boletim de geração eólica 2022. São Paulo, 2022.

ALZUBAIDI, L. *et al.* Review of deep learning: concepts, cnn architectures, challenges, applications, future directions. **Journal of Big Data**, v. 8, p. 53, 2021. Disponível em: <<https://doi.org/10.1186/s40537-021-00444-8>>.

BEZERRA, C. **Uma abordagem de segmentação semântica de íris para fins biométricos usando aprendizagem profunda.** Tese (Doutorado), 09 2018.

BLAABJERG, F. *et al.* Power electronics - the key technology for renewable energy system integration. In: . [S.l.: s.n.], 2015. p. 1618–1626.

CHENG, C.; JIA, R. A classification method of cnn for numerical data based on radar chart representation. **INFORMATION AND CONTROL**, v. 48, n. 4, p. 429–436, 2019. ISSN 1002-0411. Disponível em: <<https://xk.sia.cn/en/article/doi/10.13976/j.cnki.xk.2019.8525>>.

DAHIYA, V.; G, L. Comparative study of doubly fed induction generator and permanent magnet synchronous generator in wind energy conversion system. **International Journal of Electrical Engineering and Technology**, v. 10, n. 3, p. 73–79, 2019. Disponível em: <<http://www.iaeme.com/IJEET/issues.asp?JType=IJEET&VType=10&IType=3>>.

DAKE, M. **A simplified view of an artificial neural network.** 2006. Disponível em: <https://commons.wikimedia.org/wiki/File:Neural_network.svg>.

ELKASEM, A. *et al.* Optimal performance of doubly fed induction generator wind farm using multi-objective genetic algorithm. **International Journal of Interactive Multimedia and Artificial Intelligence**, v. 5, p. 48–53, 03 2019.

EPE. Plano nacional de energia 2050. Brasília, 2020.

_____. **Matriz Energética e Elétrica.** 2022. Disponível em <<https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>>.

FADIGAS, E. A. F. A. **Energia Eólica.** [S.l.]: Editora Manole, 2012. ISBN 978-85-204-3004-0.

FISCHER, K. *et al.* **Investigation of Converter Failure in Wind Turbines.** Stockholm, 2012.

GUO, Y. *et al.* A methodology for reliability assessment and prognosis of bearing axial cracking in wind turbine gearboxes. **Renewable and Sustainable Energy Reviews**, 2020.

HAYKIN, S. S. **Neural Networks: A Comprehensive Foundation**. 3. ed. [S.l.]: Prentice Hall, 2008. ISBN 0-13-147139-2, 978-0-13-147139-9.

IBM. **Neural Networks - IBM**. 2021. Disponível em: <<https://www.ibm.com/br-pt/topics/neural-networks>>.

KOU, L. *et al.* Fault diagnosis for open-circuit faults in npc inverter based on knowledge-driven and data-driven approaches. **IET Power Electronics**, v. 13, n. 6, p. 1236–1245, 2020.

LIANG, J. *et al.* A state-of-the-art review on wind power converter fault diagnosis. **Energy Reports**, v. 8, p. 5341–5369, 2022. ISSN 2352-4847. Citado na página 8. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352484722007338>>.

LIU, Z. *et al.* Research on fault detection for three types of wind turbine subsystems using machine learning. **Energies**, v. 13, n. 2, 2020. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/13/2/460>>.

LUYING, Z. *et al.* A transfer residual neural network based on resnet-50 for detection of steel surface defects. **Appl. Sci.**, v. 13, n. 9, 2023. Disponível em: <<https://www.mdpi.com/1996-1073/13/2/460>>.

MUKHERJEE, S. **The Annotated ResNet-50**. 2022. Disponível em: <<https://towardsdatascience.com/the-annotated-resnet-50-a6c536034758>>.

ONS. **Evolução da Capacidade Instalada**. 2023. Disponível em <https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/evolucao_capacidade_instalada.aspx>.

REIS, P. **Principais Causas dos Problemas dos Aerogeradores com Caixa Multiplicadora - Parte 1**. 2020. Disponível em: <<https://www.portal-energia.com/principais-causas-dos-problemas-dos-aerogeradores-com-caixa-multiplicadora-parte-1/>>.

SANTELO, T. N.; MONTEIRO, J. R. B. A. Revisão de falhas e tendências na geração eólica. In: **Simpósio Brasileiro de Sistemas Elétricos (SBSE)**. [S.l.: s.n.], 2020. v. 1, p. 6.

SARWINDA, D. *et al.* Deep learning in image classification using residual network (resnet) variants for detection of colorectal cancer. **Procedia Computer Science**, v. 179, p. 423–431, 01 2021.

U.S. DEPARTMENT OF ENERGY. **How a Wind Turbine Works (Text Version)**. [S.l.], 2023. Acesso em: 21 de Outubro 2023. Disponível em: <<https://www.energy.gov/eere/wind/how-wind-turbine-works-text-version>>.

WU, Z. *et al.* Operation and control of a direct-driven pmsg-based wind turbine system with an auxiliary parallel grid-side converter. **Energies**, v. 6, p. 3405–3421, 2013. Disponível em: <<https://doi.org/10.3390/en6073405>>.

YANG, Z.; CHAI, Y. A survey of fault diagnosis for onshore grid-connected converter in wind energy conversion systems. **Renewable and Sustainable Energy Reviews**, v. 66, p. 345–359, 2016. ISSN 1364-0321.

ZHANG, J. *et al.* Fault diagnosis and monitoring of modular multilevel converter with fast response of voltage sensors. **IEEE Transactions on Industrial Electronics**, v. 67, n. 6, p. 5071–5080, 2020.