



DETECÇÃO DE DESCARGAS PARCIAIS USANDO TRANSFORMADA Q-CONSTANTE E REDES NEURAS CONVOLUCIONAIS

Leandro José Duarte¹, Alan Petrônio Pinheiro¹, Alailton José Alves Júnior¹, Andreia Coelho Domingos¹,
Daniel Braga Melo¹, Fabio Romero de Souza Junior¹, Fabrício Augusto Matheus Moura¹,
Gabriel Machado Bernardes¹ e Rafael de Sousa Santos¹

¹FEELT - Universidade Federal de Uberlândia

Resumo - A detecção de descargas parciais (*partial discharge* — PD) é de extrema importância para a manutenção preventiva de sistemas elétricos, pois permite identificar precocemente falhas e anomalias que podem causar danos significativos aos equipamentos. Entretanto, a detecção de sinais de PD com baixa intensidade pode ser prejudicada por ruídos, demandando uma análise minuciosa e, muitas vezes, manual dos dados. Neste artigo, com base em um conjunto de dados de séries temporais contendo descargas parciais deliberadamente curadas para explorar diversos cenários, propomos um método de aprendizado profundo combinando a transformada Q-constante (*constant-Q transform* — CQT) e redes neurais convolucionais (*convolutional neural network* — CNN), para obter um desempenho promissor na detecção automática de descargas parciais. Em nosso método, o sinal de PD é primeiramente transformado em um espectrograma pela CQT e subsequentemente classificado por uma CNN. Em particular, o EfficientNet-B3 e o EfficientNetV2-L são ambos utilizados como *backbones* da CNN para extrair características dos espectrogramas. Após a aplicação de um *ensemble* de média nos dois *backbones* e da técnica de validação cruzada *K-Fold*, nosso modelo alcança uma pontuação de área sobre a curva ROC (*Area under the ROC Curve* — AUC) de 0.96356 no conjunto de testes.

Palavras-Chave - Descargas Parciais, Redes Neurais Convolucionais, Transformada Q-constant

PARTIAL DISCHARGE DETECTION USING CONSTANT-Q TRANSFORM AND CONVOLUTIONAL NEURAL NETWORKS

Abstract - The detection of partial discharges (PD) is of utmost importance for the preventive maintenance of electrical systems, as it allows for the early identification of faults and anomalies that can cause significant damage to equipment. However, detecting low-intensity PD signals can be hindered by noise, requiring thorough, and often, manual data analysis. In this article, based on a dataset of time series containing intentionally curated partial discharges to explore various scenarios, we propose a deep learning method that combines the Constant-

Q Transform (CQT) and Convolutional Neural Networks (CNN) to achieve promising performance in the automatic detection of partial discharges. In our method, the PD signal is first transformed into a spectrogram using CQT and subsequently classified by a CNN. In particular, both EfficientNet-B3 and EfficientNetV2-L are employed as CNN backbones to extract features from the spectrograms. After applying an ensemble averaging of the two backbones and using K-Fold cross-validation technique, our model achieves an Area under the ROC Curve (AUC) score of 0.96356 on the test set.

Keywords - Constant-Q transform, Convolutional Neural Networks, Partial discharges

I. INTRODUÇÃO

A detecção de descargas parciais (*partial discharge* — PD) vem se tornando uma métrica importante para manutenção preventiva de sistemas elétricos, permitindo a identificação precoce de falhas e anomalias que podem causar danos significativos aos equipamentos [1]. O método de detecção pode ser manual ou automatizado, sendo que a última opção tem ganhado interesse nos últimos anos com o avanço de técnicas de processamento de dados e aprendizado de máquina.

A detecção de PD depende da análise de sinais capturados por detectores, que são dados de séries temporais (*time resolved partial discharge* — TRPD) de pequenas descargas elétricas devido à ionização temporária do material isolante. A física da descarga parcial é governada pelas propriedades dielétricas do material isolante, pela geometria da configuração e pelas características da fonte de tensão que causa a descarga [2]. Isso resulta em uma vasta gama de configurações possíveis, o que torna a interpretação desses sinais um desafio considerável. Mesmo que os detectores sejam altamente sensíveis, os sinais de magnitude extremamente reduzida frequentemente se perdem no meio do ruído. Portanto, é essencial possuir conhecimentos avançados em análise de dados e caracterização de ruído para viabilizar a detecção eficaz de descargas parciais.

Nos últimos anos, houve um ressurgimento na aplicação de redes neurais (*neural networks* — NN) em descargas parciais,

sem dúvida impulsionado pelos avanços observados em aprendizado de máquina (*machine learning* — ML) e aprendizado profundo (*deep learning* — DL). Diversos experimentos com NN dotadas de hiperparâmetros variados foram realizados no domínio da frequência [3], com o uso do espectro de potência [4] e para a extração de características de padrões de PD fase-resolvidos (*phase resolved partial discharge* — PRPD) [5]. Os resultados experimentais concordam majoritariamente que NN são altamente precisas no reconhecimento das formas dos pulsos de descarga parcial. Além disso, a adição controlada de defeitos, que visa emular situações reais e, por consequência, produzir sinais com padrões de descargas parciais e ruídos mais complexos, foi conduzida em [6]. No entanto, essa abordagem resultou em uma redução da precisão da detecção.

Por conseguinte, é plausível concluir que as medidas são significativamente afetadas pelo ruído e, portanto, requerem uma avaliação adequada. Reconhecendo a importância de identificar sinais com padrões complexos de ruído em aplicações práticas, estudos usando PRPD foram conduzidos por [7], nesse caso as NN, entre diversos métodos de mineração de dados e ML estudados, foram 10% menos precisas. Motivados por esse resultado, [8] e [9] estenderam esse estudo, onde [8] realizou mais comparações de diferentes seleções manuais de características, e em [9] as características foram extraídas por meio de transformação *wavelet*. Concluiu-se, portanto, que as NN requerem grandes conjuntos de dados para ter bom desempenho, mas são úteis para a identificação de descargas parciais. Em face ao ceticismo geral na aplicação de NN, devido à dificuldade em explicar os bons resultados obtidos no diagnóstico automatizado de descargas parciais trabalhos foram realizados para exibir a visualização da ativação do neurônio [9].

No contexto anteriormente delineado, estudos experimentais anteriores têm se restringido predominantemente à realização de análises em TRPD e PRPD, limitadas a cenários de laboratório, nos quais defeitos são artificialmente recriados ou medições de campo são marginalmente incluídas. Dessa forma, com o objetivo de alcançar um desempenho promissor na detecção de descargas parciais em desafiantes cenários, este trabalho apresenta um método fundamentado no aprendizado profundo. Esse método une a Transformada Q-constante (*Constant-Q Transform* — CQT) [10, 11] e redes neurais convolucionais (*convolutional neural network* — CNN).

Inicialmente, o sinal representativo de descarga parcial passa por uma transformação, sendo convertido em um espectrograma por meio da CQT. Na sequência, esse espectrograma é submetido à classificação por redes CNN, que incorporam *backbones* notáveis, como o EfficientNet-B3 [12] e o EfficientNetV2-L [13]. Além disso, por meio da aplicação de um *ensemble*, que consiste na combinação de dois modelos CNN, e da empregabilidade da técnica de validação cruzada *K-Fold*, nosso modelo alcança um notável valor de Área Sob a Curva ROC (AUC) de 0.96356 em experimentos de teste.

A estrutura subsequente do artigo está delineada da seguinte forma: Na Seção II, apresentamos uma exposição detalhada do conjunto de dados, o qual compreende sinais de descargas parciais. Na Seção III, resumimos o princípio subjacente à transformada Q-constante, bem como os mecanismos característicos do EfficientNet e do EfficientNetV2. Na Seção IV,

introduzimos o fluxo de trabalho inerente ao nosso método de aprendizado profundo. A avaliação do desempenho do modelo é evidenciada na Seção V, seguida pela apresentação das conclusões na Seção VI.

II. DESCRIÇÃO DOS DADOS

O conjunto de dados empregado neste estudo resulta de um meticuloso processo de curadoria, que abrangeu a rotulagem manual dos dados obtidos em ensaios laboratoriais conduzidos em amostras de cabos XLPE de média tensão retirados de operação. A Figura 1 mostra uma representação clássica de um TRPD de descarga parcial. Em certos cabos, dependendo das interferências de ruído tanto interno quanto externo, discrepâncias nas impedâncias das junções, atenuação e dispersão do sinal, bem como o comprimento total do cabo, é possível observar formas de onda mais complexas, as quais representam um desafio para a análise por parte do especialista.

Figura 1: Exemplo clássico de uma TRPD de descarga parcial.





Figura 2: TRPDs com ruído. (a) Ruído distribuído aleatoriamente. (b) Ruído repetitivo.




Como mencionado anteriormente, a interferência de ruído é um fator inevitável nos testes de descargas parciais. Ele apresenta propriedades não estacionárias e pode assumir a forma simples de pequenas perturbações na passagem por zero, grandes picos irregulares, como mostrado na parte superior da Figura 2(a), ou ser repetitivo em frequências e magnitudes aleatórias, como mostrado na parte inferior da Figura 2(b). Portanto, o reconhecimento de pulsos de descarga parcial em ambientes ruidosos é uma tarefa difícil que requer supervisão especializada para selecionar adequadamente um conjunto de dados diversificado e distinto, a fim de que as redes neurais possam reagir com sucesso a novos dados.

A. Aquisição de Dados

Para assegurar a integridade e a confiabilidade dos resultados obtidos, todos os ensaios de descargas parciais foram conduzidos em estrita conformidade com as diretrizes estabelecidas na norma IEC 60270. Esta norma, estabelece os procedimentos que devem ser seguidos para a detecção e avaliação das descargas parciais em equipamentos elétricos, fornecendo uma base sólida para a análise, interpretação, e principalmente a rotulação dos dados coletados e usados no treinamento e validação desse trabalho.

Para a aquisição do sinal PD foi utilizado um transformador de corrente de alta frequência (HFCT), com largura de banda de 20 kHz a 20 MHz, como mostra a Figura 3. O HFCT é instalado na derivação de terra na extremidade do cabo, os sinais são então enviados a maleta de testes Techimp Aquila que realiza a captura e gravação do sinal

Figura 3: Resposta em frequência do HFCT.



O conjunto de dados consistiu em 10000 amostras igualmente distribuídas entre PD e ruído. As formas de onda são cuidadosamente selecionadas de modo que existem poucas duplicatas das assinaturas de PD ou ruído. O conjunto de treinamento e o conjunto de validação foram divididos em 90% e 10%, respectivamente, do conjunto de dados. Os testes foram realizados em diferentes níveis de tensão, com $2,0 \times U_0$ como valor máximo; U_0 foi de 8,7 kV. A faixa de medição de PD varia de 1 pC a 1 nC.

Convencionalmente, o banco de dados é formado por uma combinação de todas as formas de onda de PD e ruído dos cabos, e dividido aleatoriamente em três conjuntos: o conjunto de treinamento influenciando o modelo, o conjunto de validação indiretamente influenciando o modelo e o conjunto de

teste fornecendo uma avaliação imparcial do ajuste do modelo no conjunto de dados. No entanto, a desvantagem desse arranjo é que o conjunto de testes pode conter traços de formas de onda dos mesmos cabos usados para treinar o modelo anteriormente. Embora o modelo não tenha sido exposto diretamente aos dados no conjunto de testes, é importante considerar que durante o treinamento é possível que tenha encontrado padrões ou características semelhantes aos presentes nesse conjunto. Para mitigar essa possibilidade, o conjunto de testes selecionado para este estudo é composto por 3 cabos diferentes (com um total de 2000 amostras de TRPD), os quais não fazem parte do banco de dados de treinamento, garantindo, assim, a independência dos dados utilizados neste caso de estudo.

III. MÉTODOS

O método de aprendizado profundo que utilizamos neste trabalho combina a transformada Q-constante e redes neurais convolucionais. Portanto, nesta seção, apresentaremos brevemente o princípio da CQT e os mecanismos das CNNs escolhidas, ou seja, EfficientNet e EfficientNetV2.

A. Transformada Q-constante

A transformada Q-constante é um método que transforma uma série de dados para o domínio da frequência. Para aplicar a transformada, denotamos f_k como a frequência central do bin k ($k = 1, 2, \dots, K$), que satisfaz:

$$f_k = 2^{\frac{k-1}{B}} \cdot f_1 \quad (1)$$

Aqui, B é o número de bins por oitava e f_1 é a frequência central do bin com menor frequência. Em seguida, o “átomo” tempo-frequência a_k do bin k pode ser definido como:

$$a_k(n) = \frac{1}{N_k} \cdot w\left(\frac{n}{N_k}\right) \cdot e\left(-2i\pi n \frac{f_k}{f_{sr}}\right) \quad (2)$$

onde N_k é o comprimento da janela, $w(t)$ é a função de janela e f_{sr} é a taxa de amostragem. Denotamos $a \cdot N_k$ como o conjugado complexo de $a_k(n)$. Então, a transformada Q-constante $Z(k, n)$ de uma série $z(n)$ pode ser dada por:

$$Z(k, n) = \sum_{j=n-\lfloor N_k/2 \rfloor}^{n+\lfloor N_k/2 \rfloor} z(j) a_k^*(j-n+\lfloor N_k/2 \rfloor) \quad (3)$$

onde $\lfloor \cdot \rfloor$ é a função piso, e a constante Q é dada por:

$$Q = \frac{q}{\Delta\omega(2^{1/B} - 1)} \quad (4)$$

onde $q \in (0, 1]$ é o fator de escala do filtro, $\Delta\omega$ é a largura de banda e depende da função de janela. O comprimento da janela N_k pode ser determinado pela definição de Q ($Q = N_k f_k / \Delta\omega f_s$) baseado na Equação (5), escrita como:

$$N_k = \frac{q f_s}{f_k (2^{1/B} - 1)} \quad (5)$$

Em particular, calcular $Z(k, n)$ em todas as posições n é impraticável. Para resolver essa questão, os átomos sucessivos

podem ser colocados a H_k (tamanho do salto) amostras de distância. Neste trabalho, a CQT é implementada pela função q-transform no pacote Python pyDischarge. Os parâmetros correspondentes são resumidos na Tabela 1. Para clareza, mostramos os resultados representativos da CQT na Figura 4, onde os sinais são normalizados e branqueados [14] antes da aplicação da transformada.

Tabela 1: Parâmetros da função q-transform da biblioteca pyDischarge

Parâmetro	Símbolo	Significado	Valor
sr	f_{sr}	Taxa de Amostragem da entrada	10MHz
hop_length	H_k	Tamanho do pulso	4
fmin	f_1	A frequência do menor bin	0,1Mhz
fmax	/	A frequência do maior bin	5Mhz
bins_per_octave	B	Número de bins a cada oitava	6
filter_scale	q	Fator de escala do filtro	1
window	$w(t)$	Função de janelamento da transformada constant-Q	Hann

B. EfficientNet

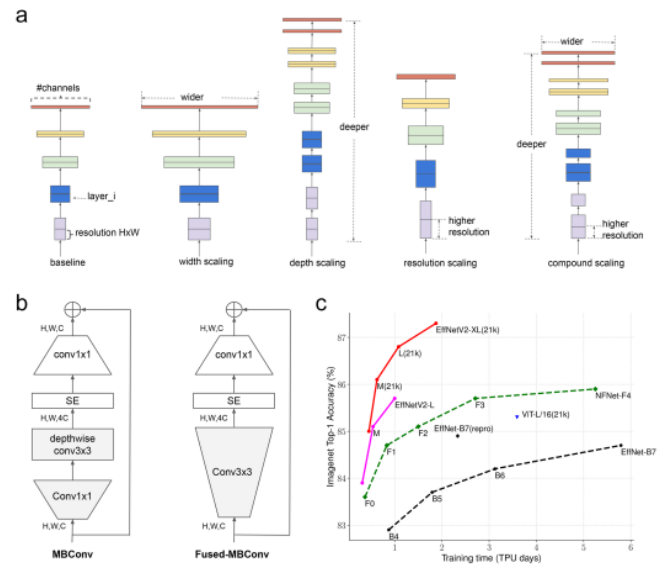


Figura 5: (a) Diagrama esquemático do método de escalonamento composto usado no EfficientNet. (b) Estruturas detalhadas dos blocos MBConv e Fused-MBConv. (c) Comparação do desempenho de classificação do EfficientNet e EfficientNetV2 no conjunto de dados ImageNet.

EfficientNet é uma arquitetura de rede neural convolucional projetada para alcançar alto desempenho em tarefas de visão computacional, como classificação de imagens, enquanto utiliza menos recursos computacionais em comparação com outras arquiteturas mais complexas. A EfficientNet foi desenvolvida por Mingxing Tan e Quoc Le da Google em 2019 [12, 13] e é composta por módulos escalonáveis que permitem ajustar o tamanho da rede para diferentes necessidades de recursos computacionais. Além disso, a arquitetura usa uma técnica chamada aprendizado de largura e profundidade para alcançar um equilíbrio ideal entre a profundidade da rede e a largura das camadas convolucionais, conforme mostrado na Figura 5(a). A EfficientNet utiliza um conjunto de coeficientes de escala fixos w (largura), d (profundidade) e r (resolução), que satisfazem:

$$\begin{aligned} d &= \alpha^\phi, w = \beta^\phi, r = \gamma^\phi \\ \alpha \cdot \beta^2 \cdot \gamma^2 &\approx 2 \\ \alpha \geq 1, \beta \geq 1 \text{ e } \gamma \geq 1 \end{aligned} \quad (6)$$

onde o coeficiente composto ϕ determina o tamanho da rede. Após isso, um modelo de linha de base EfficientNet-B0 é proposto, onde a estrutura detalhada é resumida na Tabela 2. Aplicando uma pesquisa simples em grade, as constantes de escala para EfficientNet-B0 podem ser obtidas $\alpha=1,2$; $\beta = 1,1$ e $\gamma = 1,15$. Com base nisso, a família de EfficientNet pode ser construída aumentando ϕ , onde o inteiro $\phi \in [0, 7]$. Neste trabalho, utilizamos a rede com $\phi = 3$, ou seja, EfficientNet-B3, como um dos *backbones* dos modelos CNN adotados.

Tabela 2: Estrutura detalhada do EfficientNet-B0

Estágio	Operador	Resolução	Canais	Camadas
1	Conv3x3	224×224	32	1
2	MBCConv1, k3x3	112×112	16	1
3	MBCConv6, k3x3	112×112	24	2
4	MBCConv6, k3x3	56×56	40	2
5	MBCConv6, k3x3	28×28	80	3
6	MBCConv6, k3x3	14×14	112	3
7	MBCConv6, k3x3	14×14	192	4
8	MBCConv6, k3x3	7×7	320	1
9	Conv1x1 & Pooling & FC	7×7	1280	1

C. EfficientNetV2

O EfficientNetV2 é uma arquitetura de rede neural convolucional desenvolvida pela Google em 2021 como uma evolução do EfficientNet. Seu propósito é aprimorar ainda mais o desempenho em tarefas de visão computacional. A arquitetura combina convoluções e transformadores para processar imagens em diversas escalas, permitindo a captura de padrões complexos. Adicionalmente, utiliza uma técnica de treinamento denominada "estocasticidade explícita", que contribui para a melhoria da generalização da rede em relação a dados não observados durante o treinamento. O EfficientNetV2 aborda três desafios que também afetavam o modelo original do EfficientNet: 1. Lentidão no treinamento de imagens de tamanho muito grande; 2. Lentidão das convoluções *depth-wise* nas camadas iniciais; 3. Escalonamento igual em todas as etapas é subótimo.

Utilizando o método de busca de arquitetura neural (NAS) [16], o modelo de linha de base EfficientNetV2-S foi obtido, cuja estrutura é resumida na Tabela 3. Em comparação com o EfficientNet-B0, o EfficientNetV2 substitui os blocos MBConv por blocos Fused-MBConv nas camadas iniciais, como mostrado na Figura 5(b). Ademais, o EfficientNetV2 reduziu a taxa de expansão e o tamanho do kernel para acelerar o treinamento. Utilizando um método de escala composta semelhante ao apresentado na Seção B, é possível obter o EfficientNetV2-L, que é uma das *backbones* de CNN utilizadas neste trabalho, a partir do EfficientNetV2-S. De acordo com os resultados mostrados na Figura 5(c), o EfficientNetV2 superou o EfficientNet em termos de precisão do ImageNet top-1, com um tempo de treinamento menor.

Figura 4: Amostra de dados representativa no conjunto de dados. Cada amostra de dados consiste em um TRPD. (a) Espectrograma correspondente a (b), obtidos por meio da transformada de constante-Q. Os dados da série temporal são normalizados e branqueados antes que a transformação seja aplicada.


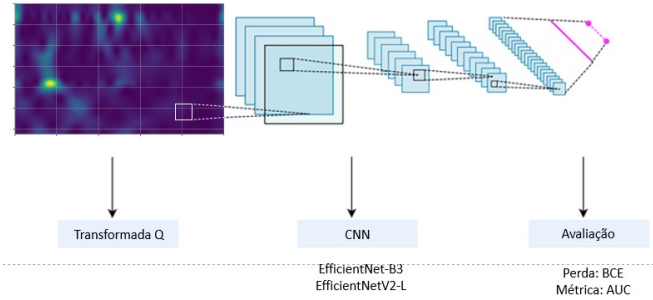


Tabela 3: Estrutura detalhada do EfficientNetV2-s

Estágio	Operador	Largura	Canais	Camadas
1	Conv3 × 3	2	24	1
2	Fused-MBConv1, k3 × 3	1	24	2
3	Fused-MBConv4, k3 × 3	2	48	4
4	Fused-MBConv4, k3 × 3	2	64	4
5	MBConv4, k3 × 3, SE0,25	2	128	6
6	MBConv6, k3 × 3, SE0,25	1	160	9
7	MBConv6, k3 × 3, SE0,25	12	256	15
8	Conv1 × 1 & Pooling & FC	-	1280	1

Figura 6: Diagrama esquemático do fluxo de trabalho do nosso método. Espectrogramas obtidos pela rotina q-transform do pacote pyDischarge são empilhados e depois processados pelos modelos de CNN (EfficientNet-B3 e EfficientNetV2-L). A função de perda é a perda de entropia cruzada binária (BCE) e a métrica de avaliação é a AUC.



IV. FLUXO DE TRABALHO E MÉTODO DE TREINAMENTO

O fluxo de trabalho do nosso método é esquematicamente demonstrado na Figura 6. Após transformar os dados de série temporal em espectrogramas por meio da rotina q-transform do pacote python pyDischarge, a imagem é processada por dois modelos de CNN, cujos *backbones* são EfficientNet-B3 e EfficientNetV2-L, respectivamente. O vetor de características extraído pela backbone da CNN é então classificado pelas posteriores camadas totalmente conectadas, onde a função de perda é a perda de entropia cruzada binária (BCE) e a métrica de avaliação é a AUC.

O método de treinamento pode ser resumido da seguinte forma: a backbone da CNN é inicialmente inicializada com

pesos pré-treinados (ImageNet). Depois disso, o modelo é treinado usando o gradiente descendente em mini-lotes com um tamanho de lote 4. O otimizador é o Adam [16] com uma taxa de aprendizado inicial de 0,001. O agendador de taxa de aprendizado é o agendador de ajuste de coseno [17], onde a taxa de aprendizado ηt em cada etapa é dada por:

$$\eta_t = \eta_{min} + \frac{1}{2} (\eta_{max} - \eta_{min}) \cdot \left[1 + \cos \left(\frac{T_{cur}}{T_{max}} \pi \right) \right] \quad (7)$$

Onde, T_{cur} é o número de épocas e η_{max} é a taxa de aprendizado inicial. Neste trabalho, definimos $\eta_{min} = 10^{-6}$ e $T_{max} = 24$. Para mitigar o risco de *overfitting*, o processo de treinamento é prontamente interrompido caso não ocorra melhoria na AUC válida após apenas 3 épocas.

A técnica de validação cruzada *K-Fold* foi aplicada para melhorar ainda mais o desempenho do modelo. Para isso, o conjunto de dados foi dividido em $K = 5$ *folds*. Cada *fold* foi utilizada como conjunto de validação enquanto as outras foram usadas para treinamento. A saída do modelo quando o i -ésima *fold* é usada para validação foi denotada como $p^{(i)}$ e a predição dessa técnica pode ser dada como $p = \sum_{i=1}^K p^{(i)} / K$. A predição final p_s de uma amostra de dados s é obtida por uma combinação linear das saídas de dois modelos de CNN, escrita como:

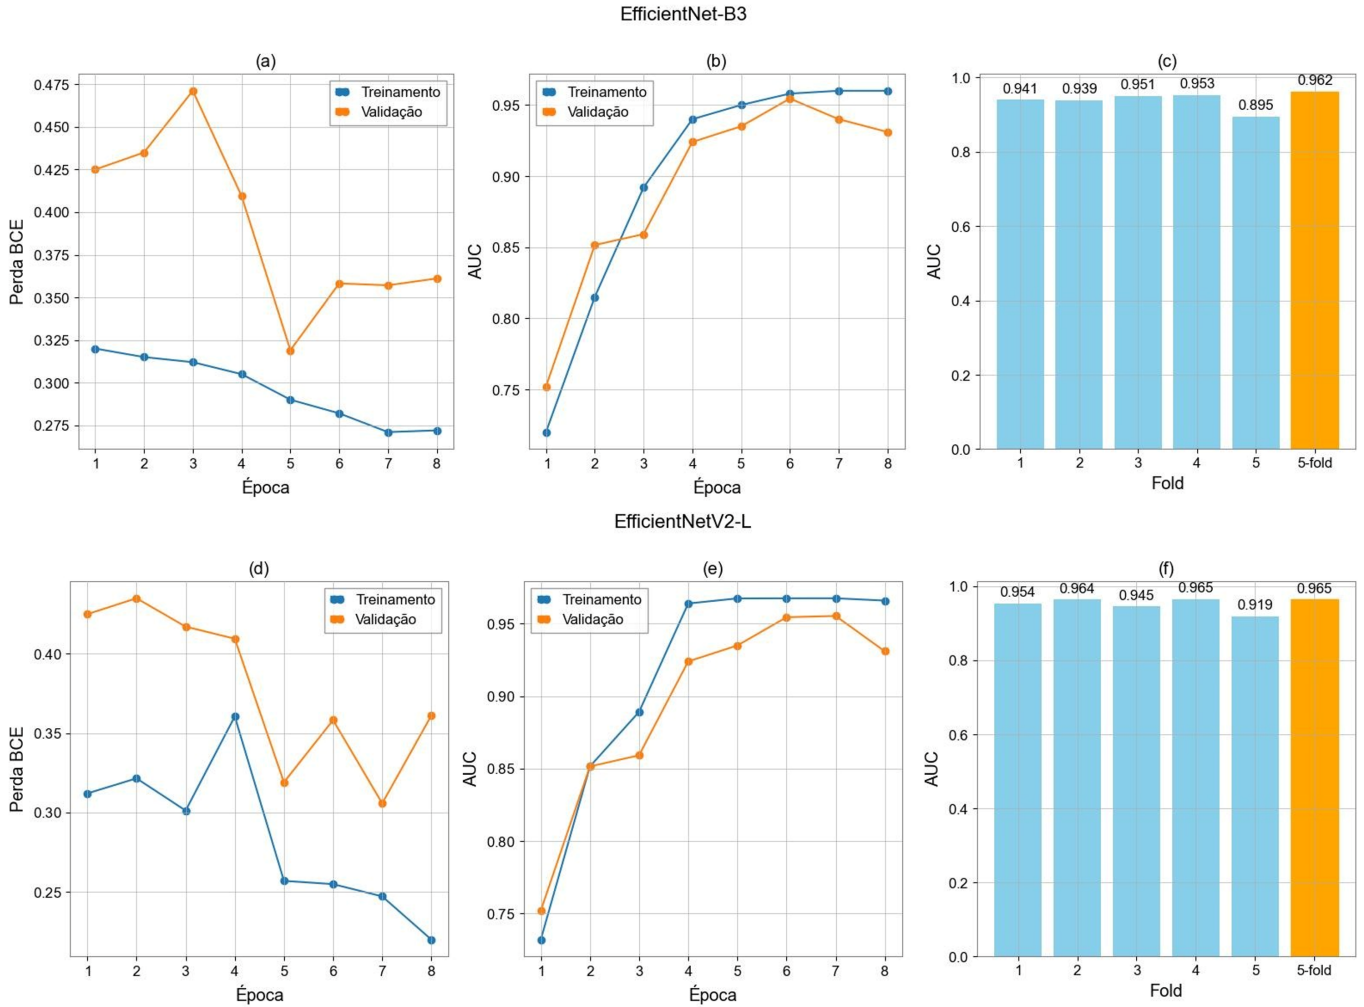
$$p_s = \varepsilon p_{v_1} + (1 - \varepsilon) p_{v_2} = \frac{1}{K} \left(\varepsilon \sum_{i=1}^K p_{v_1}^{(i)} + (1 - \varepsilon) \sum_{i=1}^K p_{v_2}^{(i)} \right) \quad (8)$$

onde, p_{v_1} e p_{v_2} denotam as previsões de EfficientNet-B3 e EfficientNetV2-L, respectivamente.

V. RESULTADOS E DESEMPENHO DO MODELO

Para avaliar a convergência do modelo e analisar seu desempenho de classificação, apresentamos as curvas representativas das perdas de treinamento e validação do EfficientNet-B3 na Figura 7(a). Observa-se claramente que a redução da perda de treinamento ocorre de maneira eficaz durante o processo. Entretanto, no caso da perda de validação, é notório

Figura 7: Desempenho do modelo EfficientNet-B3 (a-c) e EfficientNetV2-L (d-f): (a, d) Evoluções representativas da perda de treinamento e perda de validação; (b, e) Dependência por época do AUC de treinamento e AUC de validação; (c, f) Pontuações de AUC no conjunto de teste privado para uma *fold* (azul) e validação cruzada de 5 *folds* (laranja), respectivamente.



que ela diminui inicialmente, mas a partir da sexta iteração, começa a aumentar, sugerindo a possibilidade de *overfitting*.

A relação entre a iteração e a métrica de avaliação AUC também é ilustrada na Figura 7(b). A época que resulta no melhor desempenho é determinada pelo valor máximo do AUC de validação, indicado pela seta preta (que aponta para a sexta iteração na Figura 7(b)). O desempenho da melhor época no conjunto de teste para cada *fold* único é mostrado na Figura 7(c), onde o valor AUC é próximo de 0,95. Após a aplicação da técnica de validação cruzada *K-Fold*, a pontuação final do EfficientNet-B3 é impulsionada para 0,962. Por outro lado, o desempenho do modelo EfficientNetV2-L é resumido nas Figuras 7(d) e 7(f), que é semelhante ao do EfficientNet-B3.

A pontuação final do EfficientNetV2-L é de 0,965 (Figura 7(f)), o que é ligeiramente melhor que a do EfficientNet-B3. Por fim, por meio de uma busca em grade, o coeficiente ε na Equação (8) é definido como 0,48, levando a um AUC de 0,96356 no conjunto de testes privado.

VI. CONCLUSÃO

Em resumo, combinando a transformada Q-constante e as redes neurais convolucionais, propomos um método de aprendizado profundo para detectar descargas parciais a partir dos dados brutos. Após a aplicação de um *ensemble* de média e da técnica de validação cruzada *K-Fold*, os resultados mostram que este modelo híbrido baseado em EfficientNet-B3 e EfficientNetV2-L alcançou um desempenho promissor para a detecção de descargas parciais.

A previsão final do nosso método atinge um score AUC de 0,96356. No entanto, é importante notar que a transformada Q-constante apresenta uma complexidade computacional ligeiramente superior, e as CNNs não garantem total invariância espacial em relação aos dados de entrada, exigindo ainda uma considerável quantidade de dados de treinamento. Diante desses desafios, direcionar nossos esforços futuros para a otimização da eficiência desse método revela-se crucial, bem como avaliar sua eficácia em cenários de campo mais diversificados.

REFERÊNCIAS

- [1] N. Rosle, A. Muhamadn, M. H. Rohani, M. K. M. Jamil, "Partial Discharges Classification Methods in XL-PECable: A Review". *IEEE Access*, vol. 9, pp. 133258-133273, 2021.
- [2] L. Niemeyer, "A generalized approach to partial discharge modeling", *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 2, no. 4, pp. 510-528, 1995.
- [3] A. Hirata, S. Nakata, Kawasaki, Zen-Ichiro. "Toward automatic classification of partial discharge sources with neural networks", *IEEE Transactions on Power Delivery*, vol. 21, no. 1, pp. 526-527, 2006.
- [4] T. Boczar, S. Borucki, A. Cichon, D. Zmarzly, "Application Possibilities of Artificial Neural Networks for Recognizing Partial Discharges Measured by the Acoustic Emission Method", *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 16, no. 1, pp. 214-223, 2009.
- [5] H. Ma, J. C. Chan, T. K. Saha and C. Ekanayake, "Pattern recognition techniques and their applications for automatic classification of artificial partial discharge sources", *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 20, no. 2, pp. 468-478, Apr. 2013.
- [6] H. Song, J. Dai, G. Sheng and X. Jiang, "GIS partial discharge pattern recognition via Deep convolutional neural network under complex data source", *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 25, no. 2, pp. 678-685, Apr. 2018.
- [7] X. Peng et al., "Rough set theory applied to pattern recognition of partial discharge in noise affected cable data", *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 24, no. 1, pp. 147-156, Feb. 2017.
- [8] X. Peng et al., "Random forest based optimal feature selection for partial discharge pattern recognition in HV cables", *IEEE Transactions on Power Delivery*, vol. 34, no. 4, pp. 1715-1724, 2019.
- [9] X. Peng et al., "A convolutional neural network-based deep learning methodology for recognition of partial discharge patterns from high-voltage cables", *IEEE Transactions on Power Delivery*, vol. 34, no. 4, pp. 1460-1469, 2019.
- [10] C. B. Judith, "Calculation of a constant Q spectral transform", *The Journal of the Acoustical Society of America*, vol. 89, pp. 425-434, 1991.
- [11] C. B. Judith, S. P. Miller, "An efficient algorithm for the calculation of a constant Q transform", *The Journal of the Acoustical Society of America*, vol. 92, pp. 2698-2701, 1992.
- [12] M. TAN, Q. V. LE, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", Eprint: 1905.11946, 2020. Disponível em: [arxiv.org](https://arxiv.org/abs/1905.11946)
- [13] M. TAN, Q. V. LE, "EfficientNetV2: Smaller Models and Faster Training". Eprint: 2104.00298, 2021. Disponível em: [arxiv.org](https://arxiv.org/abs/2104.00298)
- [14] Cuoco, Elena et al. "On line power spectra identification and whitening for the noise in interferometric gravitational wave detectors." *Classical and Quantum Gravity* pp. 1727-1751, 2000.
- [15] T. Elsken, J. H. Metzen, and F. Hutter. "Neural Architecture Search: A Survey", *Journal of Machine Learning Research* 20, pp. 1-21, 2019.
- [16] D. P. Kingma and J. Ba. Adam, "A Method for Stochastic Optimization", *ICLR*, 2015.
- [17] I. Loshchilov and F. Hutter, "SGDR: Stochastic Gradient Descent with Warm Restarts", *ICLR*, 2017.