

実運用環境に対応した深層学習による電力機器部分放電診断技術

Deep Learning – Based Partial Discharge Diagnosis for Power Equipment toward Practical Application

松山幸太郎*
Kotaro Matsuyama
大竹泰智†
Yasutomo Otake
ソン ホンボ‡
Hongbo Sun

ラグナサン アーヴァインド‡
Arvind Raghunathan

*三菱電機㈱ 先端技術総合研究所

†同研究所(博士(工学))

‡Mitsubishi Electric Research Laboratories (Ph.D.)

要 旨

電力機器で、絶縁劣化が進むと事故・停電につながるため、劣化初期段階で発生する部分放電を検出し発生要因を推定することは安定運用に向けて重要である。近年、機械学習を用いた部分放電診断の有効性が述べられているが、実運用では複数の放電源の混在やノイズ環境に起因する診断精度の低下が課題になっている。これらの課題に対して、深層学習による信号分離モデルであるConv-TasNetを部分放電信号へ適用した複数の放電源の分離手法と、転移学習の一手法である敵対的ドメイン適応を用いたノイズ環境下での診断手法を開発した。

1. ま え が き

高い電気ストレスに曝(さら)される電力機器では、長期的劣化によって絶縁性能が低下し、絶縁破壊に至るリスクがある。その予兆現象である部分放電を検出することは、保守運用に重要である。また、部分放電の発生頻度や強度分布から、部分放電の発生要因の推定が可能であり、近年では、機械学習を用いることで高精度な自動推定が可能になってきている。

この際、運用中の実機の異常データを十分に収集することは困難であるため、教師データに実験室環境で取得したデータを用いて学習モデルが構築される。しかし、実運用時の観測データには、複数の部分放電源から生じる信号や周辺機器からのノイズが混在する。その結果、実験室環境で取得したデータとの間に分布差が生じ、診断精度が低下することが課題となる。

本稿では、これらの課題に対応するため、深層学習手法を活用した診断手法を開発し、その検証結果について述べる。

2. 基本的な機械学習による部分放電診断手法

この章では基本的な機械学習による部分放電診断の構築手法として、学習データの取得、データ前処理、特徴量生成、及び機械学習モデルの構築について述べる。

2.1 学習データの取得

実機器の部分放電データを十分に収集することは困難なため、模擬欠陥を用いて、部分放電データを取得した。模擬欠陥の一覧を表1に示す。これらは電力機器での過去の事故事例⁽¹⁾等を参考に、発生し得る部分放電発生要因を整理し10種類を選定した。さらに、診断対象機器に適用の絶縁媒体5種との組合せを踏まえて、合計36種類の模擬欠陥を対象とし

表1-模擬欠陥の一覧

No.	電極名	実機での放電発生要因	モデル図	No.	電極名	実機での放電発生要因	モデル図
a	浮き電極	高電圧部付近のボルトのゆるみ		h	沿面垂直型	絶縁物表面への導電性異物の付着	
b	針-平板	導体表面への導電性異物の付着		i	自由異物	導電性異物の混入	
c	針-絶縁物	導体表面への導電性異物の付着		j	汚損沿面	絶縁物表面の汚損劣化	
f	沿面平行型 導体付着異物	絶縁物表面への導電性異物の付着		e, o	ボイド	成型時のボイド混入	
g	沿面平行型 浮遊異物	導体表面への導電性異物の付着		m	トリー	固体絶縁物のクラック	

た⁽²⁾。これらの模擬欠陥に交流高電圧を印加し、IEC 60270に基づく部分放電測定法によって、交流電圧1周期分の部分放電信号を取得した。

2.2 データ前処理及び特徴量生成

取得した部分放電信号に対して機械学習に適した入力データを生成するため、データ前処理及び特徴量生成を行った。データ処理の概要を図1に示す。まず、取得した信号にWavelet変換を適用し、Wavelet係数に対するしきい値処理によってノイズ成分を低減した。その後、交流電圧100周期分の部分放電信号を基に、交流電圧位相に対する放電の発生位置及び強度分布を表すPRPD(Phase Resolved Partial Discharge)パターンを作成した。




図1-データ前処理及び特徴量抽出

2.3 基本診断モデル

生成したPRPDパターンを入力データとして、部分放電発生要因を分類する機械学習モデルを構築した。その構成を図2に示す。分類器は画像認識分野で広く用いられている畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)を用いた。CNNは、畳み込み層及びプーリング層によって特徴量抽出を行い、その後フラット化及び全結合層を経ることで、部分放電発生要因を推定する。

取得データを8:2の比率で教師データと評価データに分けて、教師データを基にモデルを学習後、評価用データを用いて分類性能の評価を行った。その結果、正答率100%と高い精度が得られて、モデルの有効性を確認した⁽²⁾。




図2-CNNによる部分放電診断モデル

3. 実適用での課題を踏まえた診断モデル改良

実際の電力機器での部分放電診断では、実験室環境とは異なる様々な条件による課題がある。複数の放電源が同時に存在する場合の信号の重畳や、周辺機器からの電磁ノイズの混入によって、実験室環境で取得したデータとは異なるデータ分布になり、診断精度の低下が生じる。これらの課題への対策として、複数放電源が存在する場合の信号分離手法の適用、及びノイズ環境に対する適応性を高めるための転移学習手法を構築した。

3.1 複数部分放電源の信号分離

電力設備は、多くの異なる部品から構成されており、それぞれが異なる劣化過程をたどる。そのため、運用過程で複数の箇所から放電が発生している場合があり、それぞれの部分放電信号が重畳して観測される。単一放電を想定した診断モデルでは各放電源の特徴を正確に抽出することが難しく、診断精度を得ることが困難になる。そこで、複数の放電信号が重畳した信号から、信号分離によってそれぞれの信号を取り出すモデルを組み込んだ。音声処理分野で実績のある深層学習ベースの信号分離手法であるConv-TasNetを適用した⁽³⁾。図3に複数放電源を想定した部分放電診断の処理フローを示す。入力された重畳信号をConv-TasNetによって分離し、各放電源に対応する部分放電信号を出力する。分離された信号からPRPDパターンを生成し、ベースモデル(CNN)へ入力することで部分放電要因の推定を行う。

検証では、実験室環境で取得した異なる部分放電要因の信号を重ね合わせることで、複数放電源の混合信号を模擬的に生成した。この混合信号を分離モデルへ入力し、分離された信号について部分放電特性の再現性を評価した。その結果、分離後の信号は各放電源の特徴を良好に再現しており、さらに分離された信号から生成したPRPDパターンをベースモデル(CNN)へ入力した。分離モデルを用いずに混合信号をベースモデルに入力した場合の診断精度は0%であり、完全に異なる部分放電要因と誤診断していた。一方、信号分離モデルを用いた際の診断精度は99%になっており、各部分放電要因を適切に診断できることを確認した。




図3-複数放電源を想定した部分放電診断の処理フロー

3.2 転移学習によるノイズ環境への適応

実運用時は据付け環境に応じた多様なノイズが混入し、診断精度に悪影響を及ぼす。これに対して、実験室環境で取得した多量のデータを生かしつつ、少量の現地データを用いて転移学習を施すことによって、低コストで環境に応じた高精度な診断モデルが構築できる。環境が異なっても特徴量は共通である一方、データ分布に差が生じることを踏まえて、転移学習手法の中から敵対的ドメイン適応(Domain-Adversarial Neural Network: DANN)アルゴリズムを導入した⁽⁴⁾。図4にアルゴリズムの構成を示す。特徴量抽出器、パターン分類器及びドメイン識別器から構成される。




図4-敵対的ドメイン適応アルゴリズムの構成

また、分類損失 L_{source} , L_{target} , ドメイン損失 L_{domain} , エントロピー正則化項 $L_{entropy}$ 及び勾配ペナルティ項 L_{gb} の総和を損失関数 L_{total} として式(1)に示す。 α , β , γ はハイパーパラメーターであり、学習過程で最適化した。

$$L_{total} = L_{source} + \alpha L_{target} + \beta L_{entropy} + L_{domain} + \gamma L_{gb} \quad \dots\dots\dots (1)$$

この損失関数 L_{total} が最小になるように最適化することで、ドメイン間の分布差を低減し、転移先データに対する診断精度を向上させるよう学習できる。実験室で取得したデータを転移元データ、実機で取得されたノイズを含むデータを転移先データとして用いて、有効性を検証した。この際、実運用を想定し転移先データの不足を模擬して、データ数を段階的に削減した条件でそれぞれDANNを学習し評価した。

学習前後の特徴抽出器の出力を、t-SNEを用いて二次元平面に投影した結果を図5に示す。学習前では、ソースドメイン(橙(だいだい)色)とターゲットドメイン(紫色)のクラスターが明確に分離しているが、学習後ではソースとターゲットのクラスターが混在しており、ドメイン間の分布差を低減できていることから、転移学習の効果が確認できる。また、DANNとベースモデルであるCNNとの精度の比較結果を図6に示す。ベースモデルCNNと比較して、DANNはデータ数が少ない条件でも高い分類性能が得られ、その有効性を実証した。




図5-t-SNEによるDANNのドメイン不変特徴抽出の確認




図6-DANNとCNNのF1スコアの比較

4. む す び

電力機器での部分放電診断の実機適用を目的として、深層学習を用いた信号分離とドメイン適応モデルの適用について述べた。複数の放電源が存在する場合や、現地ノイズが混入する場合にも、高精度な診断を実現する診断モデルを構築した。今後は、実際の電力設備での実証データを用いた検証を通じてこの手法の有効性を更に確立するとともに、多様な放電形態及び運用環境への適用範囲の拡大を図って、現場展開可能な実用的診断システムの実現を目指す。

参 考 文 献

- (1) 電気協同研究会：密閉型変電設備の劣化保全技術高度化，電気協同研究，**61**，No.3 (2005)
- (2) Matsuyama, K., et al. : Classification of Insulation Defect Type in Power Apparatus Based on Partial Discharge Signals by CNN, 2022 9th International Conference on Condition Monitoring and Diagnosis (CMD), 524~528 (2022)
- (3) Matsuyama, K., et al. : Separation and Recognition of Partial Discharge Signals from Multiple Sources Using Encoder-Decoder based Neural Network, 2024 IEEE 5th International Conference on Dielectrics (ICD), 1~4 (2024)
- (4) 大竹泰智，ほか：敵対的ドメイン適応によるノイズ環境下の部分放電診断精度向上，2025年電気学会B部門大会，10-5-334 (2025)