

## AIを活用した変電設備の異常診断技術

AI-Based Abnormality Diagnostic Technologies for Substation Equipment

永田 真一 NAGATA Shinichi    山口 晃広 YAMAGUCHI Akihiro    齊藤 暁斗 SAITO Akito

保全業務の経済性向上と効率化のために、ガス絶縁開閉装置や変圧器などに取り付けたセンサーからデータを取得する変電設備のIoT（Internet of Things）化が進んでいる。これらのデータは、設備の異常兆候の早期検知や故障復旧の迅速化への有効活用が期待されており、信頼性と感度の高い診断技術が不可欠である。

東芝グループは、独自のAIを活用することで、設備の正常データを学習するだけで時系列波形データの変化から変電設備の異常を検知する技術、及び対象設備の1DCAE<sup>(注1)</sup>モデルを利用して異常箇所を特定する技術を開発し、基本機能を確認した。

With the progress of Internet of Things (IoT) related technologies in the field of substation equipment, large volumes of data from various sensors attached to equipment, including gas-insulated switchgear and transformers, can now be collected and analyzed to improve economic efficiency and maintainability. To make effective use of these data for early detection of signs of abnormalities and to rapidly recover from equipment faults, highly reliable, high-sensitivity diagnostic technologies have become essential.

The Toshiba Group has developed the following abnormality diagnostic technologies using proprietary artificial intelligence (AI): (1) technology to detect abnormalities based on time-series variations in waveform data by learning only normal operation data from the equipment, and (2) technology to identify the location of abnormalities using a target equipment 1DCAE model. We have confirmed the effectiveness of the basic functionalities.

### 1. まえがき

電力流通の分野では、近年のIoT技術の普及に伴い、設備保全業務の経済性向上と効率化を目的として、開閉装置をはじめとする変電設備にセンサーを取り付けて機器状態を監視・診断するシステムが普及し始めている<sup>(1), (2)</sup>。変電設備は、その役割の重要性や、設備量の多さ、設備の老朽化などの観点から、異常の有無を感度良く、具体的な障害が生じる前に検知し、以降の保守運用・設備維持・更新計画に有効活用できる診断技術の確立が求められている。その中でも重要なアプリケーションは、設備の異常兆候を早期かつ高精度に検知し、更に異常箇所の特定までが可能な診断技術である。

従来の開閉装置では、ガス遮断器（GCB）の電流遮断時の可動接点の行程（ストローク波形）や断路器（DS）モーター電流波形などの時系列波形データから機器の健全性を評価する指標を算出し、事前に設定したしきい値を用いた判定や、センシング結果の長期的な変動から異常兆候を検知するトレンド診断などが行われている。近年のAIの発展

により、多くの特徴量を含む時系列波形自体を対象とした分析が可能になっており、新しい技術を活用した問題解決が望まれている。

変電設備に異常があると、データの確認や機器の点検を行い、異常箇所を特定する必要がある。これが設備の復旧に時間を要する要因の一つになっているため、異常箇所の特定まで実行可能な診断技術が求められている。東芝グループは、培ってきた独自のAIを活用して、変電設備の異常診断技術を開発している。ここでは、正常時の時系列波形データの特徴量を機械学習することで設備異常を検知する技術、及び1DCAEモデルを利用して異常箇所を特定する技術について述べる。

### 2. OCLTSを用いた異常データ不要の異常検知技術

#### 2.1 変電設備の異常検知におけるAI適用時の課題

変電設備にAIを適用するためには、次に挙げる三つの重要な課題を解決する必要がある。

- (1) 判定結果の説明性（判定根拠の提示） AIの判定結果を、専門家の知識と照らし合わせて納得・安心して利用するために、判定根拠の提示などの説明性が求められる。

(注1) システム全体を機能ベースで表現し解析評価を可能とすることで、製品の初期設計やシステム最適化に活用する手法。




図1. OCLTSの概要

正常データの学習だけで、説明性を持って時系列波形データの異常を診断できる。

Overview of one-class learning time-series shapelets (OCLTS)

(2) 異常データの希少性 変電設備は信頼性が高く、ほとんどは正常に稼働している。学習用の異常データを収集するまでに多くの時間を要し、導入が遅れる。

(3) 時系列波形データの不安定性 例えば、モーター電流波形にはインラッシュ電流のように設備が正常でも動作の都度変化する時間的急変部分が含まれる。波形の概形の違いで異常を検知する場合、データの不安定性はAIの正しい判断を妨げる。

## 2.2 OCLTSの特徴と課題の解決

shapelets機械学習法は、異常検知に有効な特徴が時系列波形全体ではなく短い波形パターン（以下、shapeletsと呼ぶ）に表れるというアイデアに基づいて、shapeletsを機械学習で抽出する技術である。正常／異常の高精度な判定だけでなく、判定の根拠になったshapeletsを提示できることが特徴である。東芝グループは、shapelets機械学習法を独自に改良して、正常データを学習するだけで異常判定できるOCLTS（One-Class Learning Time-Series Shapelets）を開発し、2018年に発表した<sup>(3)</sup>。OCLTSにより、2.1節の(1)で述べた判定結果の説明性（判定根拠）と(2)異常データの希少性を、ともに解決できる。

OCLTSの概要を、図1に示す。OCLTSは、学習時に、正常な時系列波形データから異常検知に有効なshapeletsを抽出するとともに、shapeletsと正常な時系列波形データとの間でどの程度類似しているかを学習して、正常領域とそれ以外を分類する1クラス分類器を得る。判定時は、学習したshapeletsを用いて時系列波形データ全体で類似度を

求め、shapeletsから波形が乖離（かいり）した程度から異常度スコアを算出する。これにより、波形の崩れが時系列波形上のどこに現れても判定可能となる。OCLTSは、当該波形部分を根拠として明示し、判定結果として出力する。

2.1節の(3)で示した時系列波形データの不安定性の課題は、データ変動に対するロバスト性を持たせることで解決した。時系列波形データの集団として見た場合、正常範囲内のデータであっても外れ値のような変動の大きいデータが学習データとして選ばれると、学習データの信頼性が低下し、判定性能が劣化する。そこで、Self-Paced Learning (SPL) という学習アルゴリズムを導入し、信頼できるデータを優先的に選んで学習することで、ロバスト性を実現した。

更に、OCLTSの解析条件として、shapeletsの中で不安定箇所とみなすデータ点数や割合を指定すると、shapeletsの中で最も逸脱する不安定な変動箇所を特定し、それらのずれを無視して近似誤差を計算する機能を持たせた。これにより、shapeletsに基づく特徴量が不安定な変動箇所の影響を受けにくくした。

## 2.3 実波形を用いた有効性評価

GCBのストローク波形とDSのモーター電流波形をテストデータとして、異常検知の有効性を評価した。

ストローク波形に異常が現れるGCBの故障モードとして、GCBの駆動リンクのピンが外れかかった状態を実器で模擬した。評価に用いたストローク波形のテストデータを図2に、OCLTSの出力を図3に示す。評価の結果、異常兆候として波形に表れた僅かな変化を検知して、正常と異常を適切に判定できた。






図2. ストローク波形のテストデータの例

100個の正常時の時系列波形データから、20個のshapeletsを抽出した。  
Stroke curve used in evaluation tests



(a) 異常度スコア



(b) 異常のある時系列波形データの判定

図3. ストローク波形のOCLTS出力

正常データとの僅かな違いから波形の崩れを検知し、適切に正常／異常を判定できた。

Discrimination between normal and abnormal operations evaluated by OCLTS

不安定箇所を無視する機能の評価では、インラッシュ電流やスパイクノイズを含むDSのモーター電流波形の中で、周囲温度が20℃のデータを正常、40℃のデータを異常とした。評価に用いたテストデータの例を図4に、OCLTSから出力された異常度スコアを図5に示す。不安定箇所とみなして無視するデータ点数 $r$ の設定を、8、16、32とした結果、 $r$ を設定すると、異常度スコアの跳ね上がり（異常データの異常度スコアの平均値／正常データの異常度スコアの平均値）が、設定なしに比べて大きくなることが確認できた。

### 3. 1DCAEモデルを利用した異常箇所の特定技術

異常箇所の特定には、異常の様相と監視対象のデータの相関関係を見いだすために必要な異常データの収集・蓄積が重要であるが、2.1節で述べたとおり、変電設備は信頼性が高く、異常データは希少である。そこで東芝グループ




図4. モーター電流波形のテストデータの例

正常20回のデータから、60個のshapeletsを学習した。

Motor current waveforms of disconnect switch during normal and abnormal operations




図5. モーター電流波形の異常度スコア

無視するデータ点数を設定することで、異常度スコアの跳ね上がりが大きくなることが確認できた。

Anomaly scores output by OCLTS

は、GCBの応答を十分な精度で模擬可能な1DCAEモデルを利用して、異常を模擬した条件下で測定される時系列波形データを生成し、学習データとして用いることで、異常箇所の特定を可能にした。

#### 3.1 1DCAEによるモデリング

GCBの動作過程には、電磁気や、流体、機構など多くの技術要素が複雑に関わっている。そのため、GCBの動作を精度良く予測するために、マルチフィジックスの計算が容易な1DCAEの適用が進められてきた<sup>(4)</sup>。

ばね操作型GCBの1DCAEモデルを図6に、1DCAEモデルで生成したストローク波形の解析結果と実測データを比較したものを図7に示す。解析結果と実測データの間の誤差は最大で0.03 P.U.（基準値に対する正規化値）とよ




図6. ばね操作型GCBの1DCAEモデル

複数の物理現象を、一つの全体モデルで表現している。

1DCAE model of gas circuit breaker with spring operating mechanism




図7. ストローク波形の解析結果と実測データの比較

二つの値がよく一致しており、モデルの妥当性が確認できた。

Comparison of stroke curves obtained by analysis and actual measurements

く一致しており、モデルの妥当性を確認した。ばね操作型GCBのほかに、油圧操作型GCBの1DCAEモデルも整備している。

### 3.2 shapelets機械学習法に基づく異常箇所特定の動作原理

正常データだけを学習して異常検知することが特徴のOCLTSは、正常領域以外を分類する機能は持たない。そのため、異常箇所の特定には、一般の機械学習と同様に複数のクラス分類が可能なshapelets機械学習法を用いる。図8に、学習時の動作を示す。OCLTSとの違いとしてshapelets機械学習法では、shapeletsの形状を、特徴量が特徴空間上でクラスごとに分離するように学習する。診断時は学習済みのshapeletsとの類似度として特徴量を計算




図8. 学習時の動作

通常はshapeletsの個数と長さは利用者が設定する必要があるが、東芝グループは機械学習モデルの複雑さとクラス分類損失のバランスを考慮して自動的に特定する技術を持っており、利用者の負担を軽減できる。

Condition diagnosis training algorithm

し、特徴空間で学習済みの各クラス領域との位置関係に基づいてクラスを推定する。

### 3.3 テストデータの生成

AI波形診断の評価に用いるテストデータとして、図6の1DCAEモデルから正常と異常のストローク波形を生成した。1DCAEモデルでは、部品の寸法や特性をパラメトリックに設定可能であり、正常の波形を生成する際には各パラメーターを正常範囲内でランダムに変化させてテストデータを生成した。異常は、異常を想定する箇所のパラメーターだけ正常範囲外で変化させて生成した。

### 3.4 クラス分類性能の評価

テストデータを、一つの正常クラスと七つの異常クラスから構成される八つのクラスに分類し、クラス分類性能を評価した結果を表1に示す。表中の適合率は、各クラスに分類されたデータ件数のうち分類が正しかった割合を、再現率は各クラスのデータ件数のうち正しく分類された割合を示す。また、F1スコアは適合率と再現率の調和平均である。F1スコアから、正常クラスは70.4%，異常クラスの異常(レバー1摩擦)は96.6%の精度でクラス分類できたことが分かる。一方で、異常(ソレノイド位置y)はF1スコアが最も低かった。これは、このクラスのテストデータがほかのクラスに誤って分類されて再現率が低くなったためである。再現率を改善するためには、学習するshapeletsの数を増やしてクラス間の差異を検出しやすくすることや、学習データを増や

表1. クラス分類性能の評価結果

Classification performance evaluation results

| クラス               | 適合率 (%) | 再現率 (%) | F1 スコア (%) |
|-------------------|---------|---------|------------|
| 正常                | 54.5    | 99.4    | 70.4       |
| 異常 (ソレノイド位置 $x$ ) | 89.1    | 62.1    | 73.2       |
| 異常 (ソレノイド位置 $y$ ) | 85.3    | 42.6    | 56.9       |
| 異常 (ダンパー位置)       | 71.8    | 71.8    | 71.8       |
| 異常 (レバー 1 摩擦)     | 97.7    | 95.6    | 96.6       |
| 異常 (レバー 2 摩擦)     | 72.5    | 74.4    | 73.4       |
| 異常 (レバー 3 摩擦)     | 100     | 58.8    | 74.1       |
| 異常 (ロッド摩擦)        | 94.1    | 43.2    | 59.3       |

すことが有効であると考えられる。また、全データ件数に対する、正しく分類されたデータ件数の割合を示す正解率は 81.0 % であり、高い性能で正常及び七つの異常クラスに正しく分類できた。

#### 4. あとがき

OCLTSを用いた異常検知技術は、異常データの学習が不要なので、診断を行う必要性は高いが、異常データを収集する時間的猶予のない高経年機器への適用に親和性が高い。

今後は、実用化の検討を深め、効率的で高度な変電設備の保守運用の実現に寄与していく。

#### 文 献

- (1) 内田和徳, ほか. “スマートGIS機器監視システムの実用化”. 令和2年電気学会全国大会講演論文集 (CD-ROM). 2020, 6-001.
- (2) Matsumoto, E. et al. "Recent Digitization of GIS and Sophistication of Equipment Condition Monitoring and Diagnosis applying AI Technologies". CIGRE Session 2022. Paris, 2022-08, A3-10644.
- (3) Yamaguchi, A.; Nishikawa, T. "One-Class Learning Time-Series Shapelets". Proceedings of 2018 IEEE International Conference on Big Data. Seattle, WA, 2018-12, IEEE. 2018, p.2365-2372.
- (4) 小川 慧, ほか. “1D-CAEによる電力用ガス遮断器ばね操作機構の開発”. 日本機械学会 Dynamics & Design Conference. 2020-09, No.223.



永田 真一 NAGATA Shinichi  
東芝エネルギーシステムズ(株)  
グリッド・ソリューション事業部 電力変電技術部  
電気学会会員  
Toshiba Energy Systems & Solutions Corp.



山口 晃広 YAMAGUCHI Akihiro, Ph.D.  
総合研究所 AIデジタルR&Dセンター システムAI研究部  
博士(情報科学)  
情報処理学会・日本データベース学会会員  
System AI R&D Dept.



齊藤 暁斗 SAITO Akito  
東芝エネルギーシステムズ(株)  
エネルギーシステム技術開発センター 機械技術開発部  
日本機械学会会員  
Toshiba Energy Systems & Solutions Corp.