

AIによる送電線故障原因分類

Classification of Transmission Line Failures by AI

故障原因物の発見支援により送電線故障の早期復旧を図る

オシロ波形から送電線故障の原因を解析しているが、故障原因の特定は解析者の経験やスキルに依存している。決定木等のツリー系のAIを用いたオシロ波形データ解析に加え、気象情報や土地利用情報等の環境データを使用することで、正解率90%を超える高い精度で故障原因の特定が可能となった。

執筆者
電力技術研究所
電力品質グループ
牛田 一洋



1 背景・目的

送電線故障が発生した際、電気所から故障時の電圧・電流波形を記録したオシロ波形データが送られてくるため、オシロ波形から故障様相を把握し、故障原因を予め予想することで、故障原因物の早期発見につながっている。

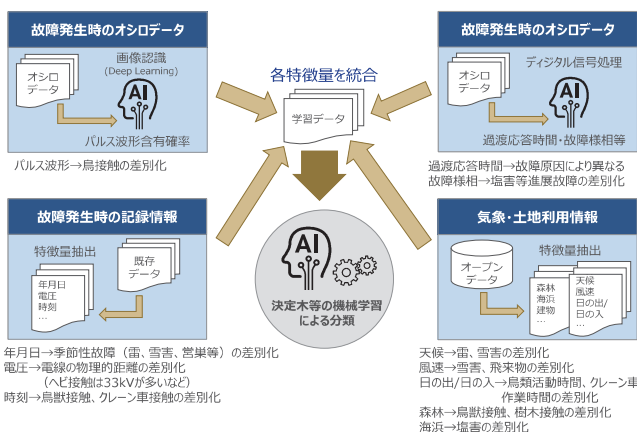
しかし、オシロ解析作業は、担当者の経験値や知識レベル等に依存するため、故障原因の解析結果に個人差が生じてしまう。また、人の手による作業であるため、原因解析に時間を要してしまうことも課題である。

そこで、これらを解消するために、AI技術を用いた送電線故障原因分類手法を検討した。なお、主な送電線故障原因として想定される、雷、雪害、鳥糞、鳥接触、獣類、ヘビ、機動車、塩害、金物、つる草、樹木接触、飛来物の12原因を分類対象とした。

2 送電線故障原因分類AIモデルの概要

(1) 学習データおよび学習手法

学習データとして、中部電力パワーグリッド管内で過去に発生した送電線故障のオシロ波形データを使用し、決定木等の機械学習により故障原因を分類するAIモデルを構築した(第1図)。決定木は、データをツリー状に生成しながら分類する手法であり、分類の過程を容易に把握できるメリットがある。また、量的、質的デー



第1図 送電線故障原因分類AIモデルの概要


タを扱うことが可能であることから、学習手法として採用した。

(2) 特徴量の抽出

機械学習では、データの中のどの特徴に着目し、学習させればよいかを人が指定する必要がある。この特徴を数値データ化したものを「特徴量」と呼び、精度の高いAIモデルの構築には重要な要素となる。今回のAIモデル構築においても、オシロ波形データの中から分類に効果的な(他の故障原因と差別化する)特徴量を検討し、抽出した。以下に、主な特徴量を示す。

① パルス波形含有確率


鳥接触による送電線故障では、故障相電圧にパルス波状の波形が現れやすい(第2図)。これに着目し、Deep Learningによる画像認識技術を利用して、故障相電圧のパルス波形の有無を自動判定し、パルス波形が含まれる確率を特徴量とした。



第2図 故障相電圧波形(上:鳥接触、下:金物接触)

② 過渡応答時間

送電線故障が発生した直後の故障相電圧波形には高周波成分が含まれた急峻な振幅変化が見られるが、この過渡的な応答波形が見られる時間の長さは、故障原因により異なる(第3図)。




第3図 故障時電圧波形(左:鳥接触、右:雷)

これに着目して、過渡応答が見られる時間の長さをデジタル信号処理により定量化し、特徴量として使用した。

③ 故障様相比

故障原因によっては、時間経過により故障様相が変化するものがある。例えば、塩害は、はじめの1線地絡故障で健全相の対地電圧が上昇することで、2線3線故障に進展するケースが多い(第4図)。これに着目し、故障継続時間内における各故障様相の占める割合を故障様相比として定量化し、特徴量とした。



第4図 塩害故障時の電圧波形

(3) 気象・土地利用情報の使用

人がオシロ解析をする際、オシロ波形の形状だけを見て、故障原因を推定しているわけではなく、気象状況や送電線周辺の土地の情報も含めて、総合的に故障原因を判断している。

これを踏まえ、オシロ波形データだけでなく、天候、風速、日の出・日の入時刻などの気象データや森林、海浜、建物などの土地利用区分データも特徴量として組み入れることにより、大幅な精度向上を図った。第1表に、特徴量として使用した気象データと土地利用区分データの一覧を示す。

第1表 気象データ(上)と土地利用区分データ(下)

気象データ											
天候	気温 (°C)	降水量 (mm)	日照時間 (時間)	風速 (m/s)	風向 (16方位)	降雪量 (cm)	積雪量 (cm)	過去18日間の 降雪積分値 (cm)	過去18日間の 積雪最大値 (cm)	故障発生時刻 -日の出時刻 (分)	
※日の出・日の入時刻は、故障発生時刻との差分を取り、特徴量とした。											
土地利用区分データ											
田	その他の 農用地	森林	荒地	建物用地	道路	鉄道	その他の 用地	河川地 及び沼	海浜	海水域	ゴルフ場

3 分類試行

(1) 分類試行の概要

2章で抽出した特徴量を用いて、送電線故障原因の分類を試行した。使用したデータ件数は982件で、これを学習データと検証データに分割して実施した。学習手法は、決定木の他に、決定木を拡張したアルゴリズムであるランダムフォレストおよび勾配ブースティング決定木(以下、GBDT)の合計3種類を使用した。

分類精度指標として、モデル全体の精度については、正解率を用い、故障原因別の分類精度については、適合率と再現率の調和平均であるF値(0~100%の範囲で示され、100%に近いほど性能が良いことを表す)を用いて、評価を行った。

(2) 結果と考察


第2表に分類試行結果を示す。シンプルなモデルの決

定木を拡張したアルゴリズムであるランダムフォレストとGBDTの正解率が90%を超え、故障原因別の分類精度でも、概ね80%を超える結果となり、分類精度の高いAIモデルを構築できたと言える。

第2表 分類試行結果

モデル	故障原因別の分類精度 (F値)											正解率	
	雷	雪害	鳥糞	鳥接触	獣類	へび	機動車	塩害	金物	つる草	樹木接触		飛来物
決定木	0.98	0.92	0.86	0.70	0.86	0.78	0.71	0.96	0.77	0.66	0.88	0.92	0.885
ランダムフォレスト	0.98	0.98	0.93	0.85	0.89	0.86	0.81	0.99	0.83	0.78	0.80	0.99	0.926
GBDT	0.99	0.96	0.88	0.79	0.84	0.83	0.83	0.99	0.81	0.74	0.88	0.98	0.913

次に、最も正解率の高かったランダムフォレストの特徴量の重要度を第5図に示す。特徴量の重要度とは、どれだけ分類に寄与したかを示す値であり、上位ほど分類に使われたことを意味する。



第5図 特徴量の重要度Top25(ランダムフォレスト)

最も重要度の高い特徴量は「天候_雷雨」であり、雷故障の分類に大きく寄与している。鳥接触故障においては、「日の出時刻」「日の入時刻」「パルス波形含有確率」、塩害故障においては、「故障様相比」が分類に寄与していると考えられ、抽出した特徴量が有効に作用していることを確認できた。また、「過渡応答時間」についても、特定の故障原因の分類への寄与ではなく、全ての故障原因に対して寄与していると考えられる。全体としては、気象・土地利用情報が上位に多く入っており、人による解析と同様、故障原因の分類においては、重要な特徴量であると言える。

4 研究成果と今後の展開

送電線故障原因を分類するAIモデルを構築し、分類試行を実施した。その結果、オシロ波形データだけでなく、人がオシロ解析をする際に考慮している気象情報や土地利用情報等の環境データも取り入れることにより、正解率90%を超える高い精度の分類が可能であることが分かった。

今回構築した送電線故障原因分類AIは、送電線故障巡視業務以外にも、自家用設備を保守するお客さまへのサービスや、社外向けの故障原因の速報提供、故障原因物によって自動的に再送電をロックする(例えば、人身災害をもたらすクレーン車はロックする)など、今後、多様な業務・サービスへの展開を図りたい。