

DNN による架空地線画像からの異常検出 Defect Detection from Ground Wire Image Based on Deep Neural Network

野上 貴行[†] 太田 寛志[†] 高谷 健太[†] クルモフ バレリー[†]
Takayuki Nogami Hiroshi Ohta Kenta Takaya Valeri Kroumov

1. はじめに

架空地線は送電鉄塔頂部に架線され、電線への落雷を防ぐために設置されている。この架空地線の点検作業は、これまでは作業員が目視で行うことや、架空地線に自走式のカメラを設置して画像撮影を行うことで、異常の有無を確認していた。近年ではドローンを用いた撮影が行われつつあり、労力とコストの軽減がされてきているが、一方で異常の確認は依然作業員の見視によって行われている。このため、この確認作業を自動化できればさらに作業負担の大幅な削減が期待できる[1]。最近では異常検出に深層学習の利用が考えられてきており、例えばセマンティックセグメンテーションを用いる手法[2]が提案されている。本研究では、深層学習のクラス分類をベースにして、架空地線の部分画像について異常と正常のクラス分類を行うことで、架空地線の異常箇所を検出する方法を提案する。

2. 架空地線画像からの異常検出の方法

架空地線の異常にはアーク痕や素線切れ、腐食などが存在するが、その大きさや形状、色などは多種多様である。そこで提案法では深層学習を用いて、異常と正常のパターンで DNN (Deep Neural Network) を学習して異常と正常の 2 クラス分類を行う。深層学習には大量の学習画像が必要だが、架空地線の異常発生頻度は低いいため十分な学習画像を収集できない。そこで転移学習を利用して既存の学習済み DNN から架空地線の異常を検出する DNN を構築する。

学習画像は、過去に架空地線点検のために空撮された画像から作成する。各画像には点検作業員によって異常箇所がマークされている。これらの画像から異常部分と正常部分を矩形に切り取り、異常パターン画像 608 枚、正常パターン画像 952 枚の計 1560 枚を用意した。図 1, 2 に異常パターンと正常パターンの例を示す。

この学習画像を用いて複数の DNN モデルで学習を行い、異常検出に最も効果的なモデルの選択を行う。また、精度向上には、データ拡張の利用、バッチサイズの調整、ファインチューニングが有効である。これらのパラメータ調整について、精度が向上することを確認した上で学習の過程に組み込んでいく。

3. 使用する DNN モデルの選択

DNN の実装には深層学習フレームワークである Keras を用いる。DNN モデルとして ImageNet の 1000 クラス分類タスクを学習した VGG16, VGG19, Xception, InceptionV3, ResNet50 を扱う。それぞれのモデルの出力層は 2 次元に変更した。各 DNN モデルで転移学習を行い、正解率を比較する。表 1 に各モデルの正解率を示す。

VGG19 が 90.6% と高い正解率になった。一般物体認識の場合と比べると、本研究の対象である架空地線の異常は色

[†] 岡山理科大学 Okayama University of Science




図 1 異常パターンの例




図 2 正常パターンの例

表 1 各モデルの正解率

DNN モデル	正解率 [%]
VGG16	88.4
VGG19	90.6
Xception	69.5
InceptionV3	66.8
ResNet50	38.5

表 2 データ拡張有無による正解率

	拡張有り	拡張無し
正解率 [%]	92.1	90.6

や形状が複雑な特徴ではないためと考えられる。表 1 の結果に基づいて、提案法では DNN のモデルに VGG19 を利用することとする。続いて、精度向上のためにデータ拡張、最適バッチサイズの推定、学習済みの畳み込み層も再学習させるファインチューニングについて検討する。

4. 精度向上アプローチ

4.1 データ拡張の有効性

データ拡張では画像の上下反転、左右反転、180 度回転をそれぞれ施す。データ拡張後の学習画像数は 6240 枚となった。表 2 にデータ拡張の有り・無しの正解率を示す。1.5% とわずかながら、精度の向上が確認できた。

4.2 最適なバッチサイズの推定

学習におけるバッチサイズを 2^n ($n=1,2,3,\dots,7$) とし、それぞれの正解率を比較し最適なバッチサイズを求める。バッチサイズごとの正解率を表 3 に示す。バッチサイズ 8 のとき正解率が 95.4% で最大となり、8 より大きくすると正解率が落ちる傾向が見られる。

表 3 バッチサイズと正解率の関係

バッチサイズ	2	4	8	16	32	64	128
正解率 [%]	94.4	94.4	95.4	94.8	94.2	93.4	92.3




図 3 再学習する畳み込み層数と正解率の関係

表 4 混同行列 (転移学習のみ)

		予測したクラス	
		異常	正常
実際のクラス	異常	439	47
	正常	168	594

表 5 混同行列 (精度向上アプローチ後)

		予測したクラス	
		異常	正常
実際のクラス	異常	479	7
	正常	6	756

4.3 ファインチューニング

ファインチューニングによって、DNNの畳み込み層の重みも学習によって最適化すれば精度向上が期待できる。重みを調整する層の数を 0~16 の間で変えて、それぞれの場合での正解率を求めた。結果を図 3 に示す。全ての畳み込み層を再学習した場合、再学習をしない転移学習と比べて、正解率が 4.6% 高くなることが確認できた。

5. 混同行列による異常検出の評価

転移学習のみを行った DNN と精度向上のアプローチで最適化を行った DNN について、混同行列を用いて精度の比較をする。評価にはテスト画像 1248 枚を用いた。得られた混同行列を表 4, 5 に示す。この結果から、異常と予測した画像のうち実際に異常だった割合である適合率、実際の異常データを正しく異常と予測できた割合である再現率を算出したところ、適合率は 72.3 % から 98.7 %, 再現率は 90.3 % から 98.5% へ向上した。どちらも高確率であり、取りこぼしも少なく、正しく認識できていることがわかった。

6. ドローンで撮影した画像からの異常検出の実験

送電線点検用ドローン[3]によって撮影した架空地線画像の一例を用いて、架空地線の異常が目視で確認される場所と同じ位置で検出されるかを実験により検証する。図 4 の画像から直線検出によって架空地線の位置と傾きを求めて、架空地線の検出及び切り出しを行い、図 5 の画像を得た。これを横方向に 64 画素幅のブロックに分割した。DNN によって得た各ブロックの異常の予測確率を図 6 に示す。図 5 において目視で確認できる異常と同じ場所で、極めて高



図 4 異常を含む架空地線の画像



図 5 画像から切り出した架空地線




図 6 ブロックごとの異常の予測確率



図 7 異常と認識されたブロック画像

い異常予測確率が得られている。この結果より、架空地線の異常箇所の位置特定が可能であることが確かめられた。

7. おわりに

本研究は架空地線の点検作業の負担削減を目的に深層学習の 2 クラス分類を用いて、架空地線上の異常箇所を検出する方法を提案した。DNN モデルには VGG19 を用い、学習パラメータの調整することで、適合率 98.7%, 再現率 98.5% で異常を認識することができた。実験によって、ドローンで撮影した架空地線画像において異常箇所を正しく特定することが確かめられた。今後は、認識に失敗している異常パターンについて分析して、ブロック分割のサイズなどについて検討を行い、異常検出の精度向上を図る。

謝辞

本研究は岡山理科大学及び電源開発株式会社の共同研究“電力施設の保守運用業務における産業用ドローンの安全飛行及び高解像度撮影技術の研究”の一環として行った。架空地線画像を提供頂いた電源開発送変電ネットワーク株式会社に感謝の意を表す。

参考文献

- [1] 石野隆一, 堤富士雄, 上野嘉之, “送電線点検のための空撮映像を使った架空地線の異常検出”, 電学論 B, Vol.126, No.4, pp.407-414 (2006).
- [2] 望月凜平, 原徳幸, 若木晶夫, 浜中秀之, “セマンティックセグメンテーションを用いた送電線上の異常検出”, 電気学会電子・情報・システム部門大会, No.GS6-5, pp.1137-1142 (2019).
- [3] K. Takaya, H. Ohta, V. Kroumov, K. Shibayama, and M. Nakamura, “Development of UAV System for Autonomous Power Line Inspection”, Int. Conf. on System Theory, Control and Computing, pp.762-767 (2019).