

ディープラーニングを用いた画像処理による農作物病害診断への Data Augmentationの応用

小林 賢一[†]辻 順平[†]能登 正人[†]神奈川大学工学部電気電子情報工学科[‡]

1 はじめに

農作物における病害の画像診断の研究においては、多様な撮影環境における多量の画像を元にした学習データが必要であるが、現実的にこのような画像を収集することは困難である。一方、ディープラーニングを用いた一般的な画像処理の研究において、既存の学習データを変形・ノイズ印加することで学習データを拡張させる Data Augmentation (以下, DA) と呼ばれる手法が提案されている。

そこで本研究では、ディープラーニングを用いた農作物の病害診断に DA を応用し、少量の学習データに対しても病害診断を可能とする画像診断手法を提案する。

2 関連研究

2.1 農作物病害の画像診断

画像処理による農作物の病害診断においては、二値化により検出部位と検出外部位を分割し対象領域を限定する手法や、検出部位に彩度を強調させ検出精度を向上させる手法など様々なものが提案されてきた [1]。

さらに近年では Mohanty らによる、ディープラーニングを用いた農作物病害の画像診断が提案されている。この手法では、明度、彩度が整った条件で撮影された農作物の画像に対して診断を行った結果、最大 99.34% を超える高い正答率を示している [2]。また一方で、先述の条件よりも実環境に近い条件下、具体的にはインターネット上で公開された不特定な病害画像を用いたケースにおいては、正答率が 36.5% と低下してしまう問題点も報告されている。

2.2 Data Augmentation

ディープラーニングを用いた画像処理の研究では、多量のデータが必要である。そのため、既存の学習データ

Application of Data Augmentation to Image-Based Plant Disease Detection Using Deep Learning

[†]Kenichi Kobayashi, Junpei Tsuji and Masato Noto

[‡]Department of Electrical, Electronics and Information Engineering, Kanagawa University

を加工してデータ数を増加させる手法 (Data Augmentation) が一般的に用いられる。具体的には学習データに対して切り出し、左右反転、変形、ノイズの付加、RGB 値の操作などが行われる [3]。

3 病害画像診断法への DA の適用

ディープラーニングを用いた農作物病害の画像診断において、実環境と近い多様な撮影環境における画像診断が求められる。しかし多様な撮影環境における学習データの収集は困難である。

このような条件下においても十分な精度で病害診断を行うために、本研究では DA に基づいて機械的に病害診断のための学習データを増加させる方法を提案する。

4 実験方法および評価方法

学習用画像に対して 6 種類の DA をそれぞれ適用させた場合の正答率と DA を適用させる前の正答率を比較する。これにより DA の有効性を検討する。

従来研究 [2] と同様の方法で学習データとして用いる画像を取得した。具体的には、Bing Image Search から「りんごの葉」の画像を取得し、取得した画像の中から目視によって 3 種の病害と健康な葉の 4 種の画像 202 枚を判別した。これらが本研究の対象とするデータセットである。この中から、学習用画像 (101 枚) と検証用画像 (101 枚) に分ける。

DA の手法としては、図 1 の 6 種類の方式を用いた。これらを学習用画像 101 枚に適用し、画像数を元の画像と合わせて 1300 枚に増加させた。

また、以下の条件で実験を行った。これは従来研究 [2] と同一の条件である。

- フレームワーク : Caffe
- 学習繰り返し回数 : 13650 回
- 学習率 : 0.005
- ニューラルネットワークモデル : GoogLeNet
- バッチサイズ : 24×24 pixel



図 1: 本研究で用いた 6 種類の DA を同一の画像に適用した結果

以上の環境設定を踏まえ、6 種類の DA をそれぞれ適用した場合と DA を適用していない場合に分けて、学習・検証を行った。

5 結果および考察

6 種類の DA を適用させた場合と DA を適用させていない場合のそれぞれの正答率を表 1 に示す。

表 1: 6 種の DA を適用した場合と DA を適用していない場合の正答率

DA の方式		正答率
DA 適用	回転	60.00%
	ズーム	62.00%
	水平方向移動	61.01%
	垂直方向移動	63.00%
	RGB 変換	59.00%
	シアー変換	45.00%
DA 適用なし		52.00%

表 1 より、垂直方向移動の方式において 11%の精度向上がみられた。図 2 に、垂直方向移動を適用した場合と適用していない場合の二つの正答率の変化を示す。また一方で、シアー変換については精度が 7%低下する結果となった。これは、変換前の画像の特徴量と変

換後の画像の特徴量の差異によるものと考えられる。

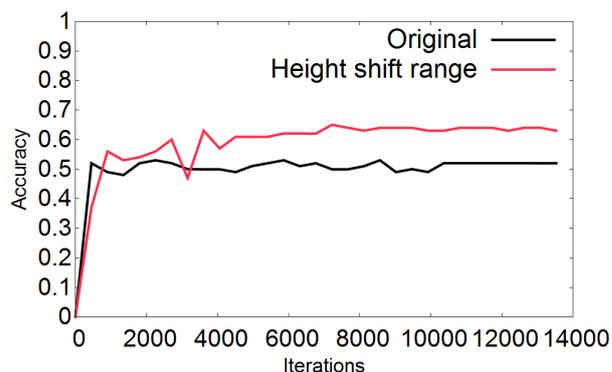


図 2: 学習曲線の推移。横軸は学習回数、縦軸は正答率。赤線は DA（垂直方向移動）を適用した場合、黒線は DA を適用していない場合

6 おわりに

ディープラーニングを用いた農作物病害の画像診断において、DA の応用を試みた。DA を用いた場合、特に垂直方向移動を適用した条件下で最大 11%の正答率の向上が見られた。実験結果より、DA を用いた少量の農作物の学習データに対して、病害画像診断手法の有効性は示すことができた。しかし、この結果は、病害診断への DA の応用の有効性は立証できたが、病害診断において十分な精度とは言えない。今後さらに精度を向上させるために転移学習や DA の手法の発展的な手法を検討していく必要がある。また、なぜ DA によって精度が向上するのか、理由は十分明らかではない。これについても今後検討の必要がある。

参考文献

[1] 小川秀夫, 酒井大輔: 画像処理によるキュウリの葉の病気診断, 愛知教育大学研究報告, Vol. 125, pp. 13–19 (2009).

[2] Mohanty, S. P., Hughes, D. and Salathe, M.: Using Deep Learning for Image-Based Plant Disease Detection, *arXiv preprint arXiv: 1604.03169*. (2016).

[3] Simard, P. Y., Steinkraus, D. and Platt, J. C.: Best Practices for Convolutional Neural Networks Applied to Visual Document Analysis, *International Conference on Document Analysis and Recognition*, No. 9, pp. 958–963 (2004).