

複数部位の画像を用いた実践的な植物病自動診断システムの提案と課題

伊藤 大貴[†]澁谷 将吾[‡]鍵和田 聡[§]彌富 仁[†][†] 法政大学 理工学部 応用情報工学科[‡] 法政大学 理工学研究科 応用情報工学専攻[§] 法政大学 生命科学部 応用植物科学科

概要

画像を利用した植物病自動診断モデルが数多く提案され良好な結果が報告されているが、実環境下での性能はこれに遠く及ばず、改善の必要性が大きく残されている。またほとんどの手法は葉など特定の部位の画像1枚を元に処理を行っているが、専門家は複数の部位の観察によって総合的に診断を行っている。本稿ではより実践的な自動診断システム実現のため、診断時に複数の画像を入力し総合的に判断させる枠組みが診断性能向上に貢献するかの検証を行った。性能の向上が期待されたが、学習済みのCNNをベースにした識別器に、3枚の画像からなるtripletを入力した評価実験では、性能向上は確認できなかった。

1 はじめに

これまで深層学習を用いた植物病自動診断システム手法が多く提案され、極めて高い診断精度が報告されている[1][2]。しかしこれらの結果は、評価用画像が学習画像と同じ圃場から取得されるなど、画像の潜在的な類似性が引き起こす過学習による過大評価であることが近年指摘されている[3][4]。我々は24圃場で撮影された4作物の葉画像計22万枚の大規模実画像データに対して畳み込み63層を有するCNNモデルであるEfficientNet-B4で診断実験を行い、学習画像と同じ圃場の画像に対しては他の論文等と同様のMacro-F1で99%程度の診断能を実現したのに対し、他圃場の画像

表 1: 利用したきゅうりの葉のデータセット

	学習用 [枚]	検証用 [枚]
0_健全	14,383 (5)	5,309
1_うどんこ病	6,211 (4)	1,898
2_灰色かび病	581 (1)	150
7_べと病	6,244 (3)	1,260
8_褐斑病	6,864 (4)	1,813
12_つる枯病	1,320 (2)	374
15_斑点細菌病	3,914 (2)	1,147
17_CCYV	5,339 (1)	179
18_モザイク病	24,209 (1)	1,626
19_MYSV	13,780 (4)	1,004
合計	82,845	14,760

に対しての診断能は平均52-85%程度であることを確認した[4]。こうしたことから実用的な植物病の自動診断技術の確立には、本質的な精度向上が必要である。

また従来の自動診断手法のほぼ全ては、葉や実などの画像1枚の解析により診断を行う。しかしその画像に病徴が含まれているとは限らず、局所的な画像では診断がつかない病害も存在する。実際、専門家は複数の部位の観察を元に診断を行う。そのため自動診断モデルの本質的な精度を高めるためには、専門家のように複数の部位の解析に対応した植物病診断モデルの検討が必要である。

圃場の広域で撮影された画像にEfficientDet[5]などの物体検出と認識を同時に行える学習モデルを適用する手法は、こうした課題に柔軟に適用できるうえ高い精度も期待でき、我々も良好な結果を確認している。しかし診断に必要な解像度、適切な教師ラベルのアノテーションの困難さと手間が深刻な課題となる。また実際にシステムとして公開する際には処理時間が問題となる。こうした背景から本研究では、単一の画像に対して診断するように学習、構築されたCNN識別器に、複数の画像を入力し、各出力を考慮することで精度向上が図れないかについて、いくつかの構成で検証した。

Feasibility study on image-based plant disease diagnosis based on analysis of multiple parts

Daiki ITO[†], Shogo SHIBUYA[‡], Satoshi KAGIWADA[§], and Hitoshi IYATOMI[†]

[†]Department of Applied Informatics, Faculty of Science and Engineering, Hosei University, Tokyo, Japan

[‡]Major in Applied Informatics, Graduate School of Science and Engineering, Hosei University, Tokyo, Japan

[§]Department of Clinical Plant Science, Faculty of Bioscience and Applied Chemistry, Hosei University, Tokyo, Japan
{daiki.ito.6e@stu., syogo.shibuya.5u@stu., kagiwada@, iyatomi@}hosei.ac.jp

表 2: 診断結果 (F1 スコア [%])

	0.健全	1.うどんこ病	2.灰色かび病	7.べと病	8.褐斑病	12.つる枯病	15.斑点細菌病	17.CCVV	18.モザイク病	19.MYSV	Macro F1
Baseline	81.4	62.1	28.3	66.0	65.3	10.8	0.0	57.5	44.5	59.3	47.5
手法 1 (最大)	68.8	50.9	26.7	52.3	57.4	10.7	1.4	58.8	29.5	46.1	40.3
手法 2 (平均)	79.3	56.7	11.5	59.7	55.5	7.6	0.1	40.3	48.9	58.2	41.8
手法 3 (手法 1×手法 2)	72.8	46.3	9.2	58.2	52.7	0.1	0.0	32.8	30.8	52.2	35.9

2 データと手法

2.1 データセットとベースライン

本稿では、きゅうりの葉画像を用いた病害の診断において、学習済みの CNN で複数枚の葉画像を診断し、各画像の診断結果を効果的に取りまとめることで、病気の検出能向上の可能性を検証した。表 1 に本実験で用いるきゅうりの葉画像のデータセットを示す。このデータセットは先行研究 [4] と同じ 9 種の病害と、健全の計 10 種類からなる。学習と評価には、異なる圃場で撮影された画像を用い、カッコ内の数値は画像を収集した圃場の数である。識別モデルには、同様に [4] で用いた CNN モデルである EfficientNet-B4(pre-train 済み)を用いた。各画像の解像度は 512×512 である。このモデルを性能のベースラインとする。ただし今回の実験では、複数枚の画像の利用の効果を確認するため、data augmentation は最低限のリサイズのみにとどめ、診断が難しい病害に対する特別な工夫や処理は行っていない。

2.2 出力の統合による診断精度向上の試み

表 1 の評価データを用いて、3 枚の葉画像からなる triplet を作成し、それらの CNN による診断結果を統合することで得られた結果に対する診断能で評価する。本実験で作成する triplet は、(i) 全て健全、病害については、(ii) 各病害画像 1 枚+健全 2 枚、(iii) 各病害画像 3 枚組とした。各 Triplet に含まれる病害は全て同じとして、その正解ラベルをその病害ラベルとした。各 triplet に含まれる画像は、評価用画像の各病害から復元抽出でランダムに選定し、その数は (i) は 3000triplet、(ii)、(iii) は、各カテゴリで病害 150triplet で、 150×9 病害 $\times 2$ の計 2700triplet とした。Triplet に対する診断結果は、以下が最大になる病害として得た。

手法 1 Triplet 全体での病害推定確率

手法 2 各画像の病害推定の平均確率

手法 3 手法 1 の各データの確率と手法 2 の
平均確率の積

の 3 種類とした。ベースラインの識別能評価には、同様に各病害カテゴリから 150 枚ずつランダムに画像を抽出し、同様に評価した。診断能は、健全および 9 種

の病害についてはそれぞれ、precision, recall の調和平均である F1 スコアで評価した。なお評価は 10 回の試行の平均値とした。

3 実験結果と考察

結果を表 2 にまとめた。本実験のベースラインの CNN による診断において、いくつかの病害 (2,12,15) は、もともと極めて診断精度が悪い。これらの病害は学習用画像と、評価用画像の差が大きく、また CNN には被写体までの距離の差に頑健でないため、類似する他の病害があるためそちらに誤識別してしまったのが原因である。このため、これらの病害に対して複数枚の入力を行っても、精度の向上は期待できないのは妥当であると考えられる。しかしながらそれ以外の、決して良好ではないものの一定の診断精度が得られている病害に対しても今回の triplet を用いた実験では、識別率の向上を得ることはできなかった。このことは、基本となる識別器の性能が不足していることもあるが、学習用画像と評価用画像に大きな違いがある場合は、入力の仕方にも改善の余地があるが同一の識別器に複数枚の画像結果のアンサンブルのみでは改善が難しいことも示唆された。

4 おわりに

病徴があいまいで多様な植物病自動診断において、モデルの頑健性の確保は極めて重要である。CNN による病害診断器は被写体までの距離の変動に脆弱で、精度の面で課題があるが、学習コストの低さ、実行時のリソースの少なさなどの面から実用、普及面で有利である。今後様々な改善を継続していきたい。

参考文献

- [1] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Frontiers in plant science*, vol. 7, p. 1419, 2016.
- [2] M. Zekiwas, A. Bruck *et al.*, "Deep learning-based image processing for cotton leaf disease and pest diagnosis," *Journal of Electrical and Computer Engineering*, vol. 2021, 2021.
- [3] K. Suwa, Q. H. Cap, R. Kotani, H. Uga, S. Kagiwada, and H. Iyatomi, "A comparable study: Intrinsic difficulties of practical plant diagnosis from wide-angle images," in *2019 IEEE International Conference on Big Data (Big Data)*. IEEE, 2019, pp. 5195–5201.
- [4] S. Shibuya, Q. H. Cap, S. Nagasawa, S. Kagiwada, H. Uga, and H. Iyatomi, "Evaluation of a practical automatic plant disease diagnosis system," in *AAAI Workshop 2022*.
- [5] M. Tan, R. Pang, and Q. V. Le, "Efficientdet: Scalable and efficient object detection," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2020, pp. 10 781–10 790.