

物体検出・認識技術を効果的に組み合わせた 2段階の植物病害診断法の検討

岩野 滉平[†] 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

画像を用いた植物病害の自動診断において、深層学習に基づく物体検出技術を適用した手法が複数報告されている。これらの技術は被写体までの距離差に頑健で、病害部位の検出能が高い一方、各領域の病害診断能が低い、領域の誤検出が多い、ラベル生成が高コストなどの課題が残されている。本研究では、物体検出手法を用いて病害領域の検出を行い、その周辺に対して病害診断に特化した識別器で診断を行う2段階の診断モデルを試作した。病害9種と健全の計約13万枚のきゅうりの葉画像を用いた評価実験において、試作した2段階モデルは物体検知モデル単体に総合的な診断能で及ばなかったが、健全データに対するF1-scoreで8.7%の向上が確認できた。

1 はじめに

近年、植物病害自動診断システムは多く研究されており、畳み込みニューラルネットワーク(CNN)を用いた診断システムは、学習が容易でありながら高い精度が報告されている[1]。しかし、ほとんどの手法は適切な評価データの分離が行われておらず、学習画像と異なる圃場で撮影された画像において病害診断精度が大きく低下することが、近年の大規模解析により明らかとなった[2]。これはCNNに被写体までの距離変動に頑健性がないことが大きな原因の1つである。一方、深層学習に基づく物体検出技術を適用した手法は、被写体まで

の距離差に頑健で、微小な病変の検出性能も高く、診断精度に加え結果の可読性など付加価値の高い結果が報告されている[3][4]。しかし、教師データ用のアノテーションコストが極めて高く、結果として学習に利用できる画像が制約され、全体の病徴を捉える必要のある病害の診断が苦手な傾向がある。また、この手法の最大の問題は、健全データを明示的に学習に活用できない点にある。本研究では、物体検出モデルと識別モデルを効果的に組み合わせた2段階からなる植物病害自動診断システムを提案する。今回はきゅうりの葉の病害を対象に、システムの1段階目では物体検出手法を用いて葉の病害領域の検出を行い、2段階目では検出した病害部分周辺を入力とするCNNによる病害識別器で診断を行う。後段のCNNはアノテーションコストが低く、より多くの画像で学習ができるため、この2段階システムは双方の弱点を補う効果が期待できる。本実験では提案する2段階手法と既存の物体検出手法の比較及びその結果を報告する。

2 2段階の病害検出モデル

図1にベースラインの物体検出モデル、比較する2種類の2段階システムの構成図を示す。1段階目の検出器には、計算量を抑えつつ高い検出精度を実現する最新の検出モデルYOLOv5x[5](以下YOLO)を用い、2段階目の識別器には、高い実績が報告されているCNNであるEfficientNet-B4[6](以下CNN)を用いた。今回用いる病害画像データは複合感染のないデータである。各画像に1つの病害ラベルと、YOLOの学習用には、病変領域ごとにアノテーションが付随している。YOLO単体では、最も高い信頼度スコアを示した病害のボックスの推定病害ラベルを診断結果とする。病害ボックスが1つも検出されない場合のみ健全と扱った。モデルA,Bでは、YOLOを病害領域の検出用途にのみ使い、検出領域があった場合に、その周囲を含む各領域をCNNに入力し診断結果を得る。複数の領域検出があった場合、CNNの推定結果の多数決を診断結果とした。モデルBは、モデルAと同様だが、YOLOで領域の検出がなかった場

A two-stage plant disease diagnosis effectively combining object detection and recognition techniques

Kohei IWANO[†], Shogo SHIBUYA[‡], Satoshi KAGIWADA[§] and Hitoshi IYATOMI[†]

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

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

[§]Clinical Plant Science, Faculty of Bioscience and Applied Chemistry, Hosei University, Tokyo, Japan

{kohei.iwano.3u@stu., syogo.shibuya.5u@stu., kagiwada@, iyatomi@}hosei.ac.jp,

表 2: 基本的な物体検知モデルをベースとした 2 段階診断モデルの識別結果

モデル	F1-score の平均 (病害のみ) [%]	F1-score の平均 (健全) [%]	macro F1-score(全体) [%]	micro accuracy [%]
Baseline(YOLO)	52.8	64.9	54.0	60.9
モデル A	33.2	69.3	36.8	53.6
モデル B	36.7	73.6	40.4	54.7

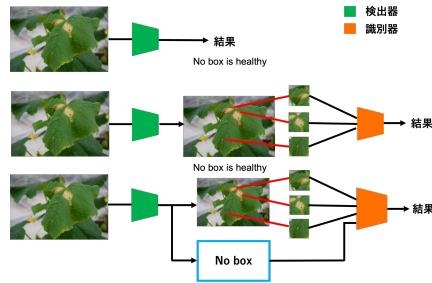


図 1: 病害診断モデル (上段: ベースライン=検出器単体, 中段: 提案モデル A, 下段: 提案モデル B)

表 1: 本実験のデータセット

	YOLO 学習用		CNN 学習用		評価用
	葉表 [枚]	Bounding Box[個]	葉表 [枚]	病害領域周辺 [枚]	
健全	-	-	16,023	-	5,309
うどんこ病	3,494	67,200	7,764	67,200	1,898
炭疽病	3,038	39,902	3,038	39,902	1,125
べと病	2,671	36,808	6,953	36,808	1,260
褐斑病	3,592	110,896	7,565	110,896	1,813
つる枯病	1,051	3,564	1,483	3,564	957
斑点細菌病	1,045	17,181	4,362	17,181	1,147
CCYV	3,602	4,420	5,969	4,420	444
モザイク病	2,190	6,398	26,861	6,398	1,626
MYSV	2,292	2,450	17,239	2,450	1,004
合計	20,662	288,819	97,257	288,819	16,779

合に, 入力画像全体を CNN に渡し判断を得る. 本実験では, 2 段階手法の効果を確認することが主であるため, ベースとなる YOLO および CNN の学習には基本的な data augmentation 以外の工夫は施していない.

3 評価実験

農林水産省の人工知能未来プロジェクトの一環として提供を受けた, きゅうりの葉の共感染を含まない病害 9 種+健全の計 10 種, 計 134,698 枚の画像を利用して解析をした. 利用した画像を表 1 にまとめる. 画像は基本的に中央付近に葉が 1 枚写っている構図であるが, 例外も多く多様である. 評価用の画像は, 学習用とは異なる圃場から採取された画像であり, 評価に用いる病害ラベルは画像ごとに 1 種類である. YOLO の学習用データには, 画像中に認められる各病斑領域に Bounding box のアノテーションが別途付与されている. 学習時の augmentation として, ± 90 度の回転処理, 水平垂直反転処理, ぼかし処理, Grayscale 変換, 矩形領域の Dropout を行い, 最終的に画像サイズは 1472×1472 pixels とした. CNN の学習には, 学習画像の約 9.7 万枚及び, YOLO の学習用 Bounding box を含む領域の画像約 29 万枚を用いて CNN の学習を行った. CNN 学習の augmentation には, 水平垂直反転処理を行い, 画像サイズは 512×512 pixels とした.

識別結果を表 2 に示す. 今回の実験では YOLO および CNN に特別な工夫をしていないため, 識別が難しい 3 種の病気について特定の病害への誤診断が極めて多く, 全体的に診断能が低い. 今回の 2 段階モデル A/B は, 診断能の改善が期待されたが総合的な診断能で YOLO 単体に及ばなかった. また, 複数領域が検出された場合の診断結果を CNN の推定結果の最大値や平均値としても有意な傾向の差は観察されなかった. YOLO は病害によって検出する領域の形と大きさが異なるため, CNN に入力する画像が学習済みの CNN と合っていないことが原因として考えられる. 一方で 2 段階モデルは, 後段の CNN が健全データを明示的に学習できるため, YOLO の弱点である健全データに対する性能で上回った. さらに, モデル B は, モデル A より良好な結果であった. モデル B はボックスが検出されなかった際に CNN で再度判定する処理が加わったため精度向上が得られたものと考えられる.

4 おわりに

今回の試作では, 2 段階診断の手法による総合的な診断精度の向上は確認できなかったが, 健全データに対する向上が確認され, 物体検出モデルの弱点を補える素質が認められた. 今後, 前段の検出結果の効果的な活用により精度向上を目指していく.

謝辞

データ提供して下さった農林水産省の人工知能未来プロジェクトの関係者の皆様には深くお礼申し上げます.

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] 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.
- [3] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, "A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition," *Sensors*, vol. 17, no. 9, p. 2022, 2017.
- [4] Q. Cap, K. Suwa, E. Fujita, H. Uga, S. Kagiwada, and H. Iyatomi, "An end-to-end practical plant disease diagnosis system for wide-angle cucumber images," *International Journal of Engineering & Technology*, vol. 7, no. 4.11, pp. 106–111, 2018.
- [5] L. Ting, Z. Baijun, Z. Yongsheng, and Y. Shun, "Ship detection algorithm based on improved yolo v5," in *2021 6th International Conference on Automation, Control and Robotics Engineering (CACRE)*. IEEE, 2021, pp. 483–487.
- [6] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," in *International Conference on Machine Learning*. PMLR, 2019, pp. 6105–6114.