

中央領域に注目する Center Attention による 頑健性の高い植物病害診断装置の構築

澁谷 将吾[†]鍵和田 聡[‡]宇賀 博之[§]彌富 仁[†][†]法政大学 理工学部 応用情報工学科[‡]法政大学 生命科学部 応用植物科学科[§]埼玉県農業技術研究センター

概要

農作物への被害が多く確認されている植物病害の発生に対して、深層学習を用いた自動診断システムが複数提案されている。これらの研究では高い識別精度が達成されている一方、葉などの解析対象ではなく背景を過学習してしまい、異なる圃場で撮影された画像に対して精度が大幅に低下するという問題がある。本報告では診断したい葉が画像の中央にある傾向に着目して、深層学習の注目を中央によせる center attention を提案する。背景情報に左右されにくい深層識別器を構築し、実際の圃場で撮影された多数の画像を対象に、予測精度の向上および予測根拠提示の改善を検証した。

1 はじめに

植物病害に対する現状の診断方法は専門的な知識や経験をもつ農家や専門家の目視による判断、遺伝子検査などで行われているため大きな人的、金銭的成本が必要となる。植物病害自動診断へのアプローチとして convolutional neural networks (CNNs) を用いた研究が提案されており、数値上では極めて高精度な診断能が報告されている [1]。一方機械学習分野においては、識別器が重要な領域により注目させる、attention 機構が提案され、識別能向上のみならず、識別器の説明性の向上など優れた成果をあげている [2]。近年提案された attention branch network (ABN) [3] は、CNNs の後段部分を通常の識別部と attention 部を担う部分に分けることで、効率かつ精度の高い attention を実現している。しかしながらこの手法は元となる識別器が正しい

A robust image-based plant disease diagnosis with the center attention

Shogo SHIBUYA[†], Satoshi KAGIWADA[‡], Hiroyuki UGA[§] and Hitoshi IYATOMI[†][†]Applied Informatics, Science and Engineering, Hosei University, Tokyo, Japan[‡]Clinical Plant Science, Faculty of Bioscience and Applied Chemistry, Hosei University, Tokyo, Japan[§]Saitama Agricultural Technology Research Center, Saitama, Japan

{syogo.shibuya.5u@stu., kagiwada@, iyatomi@}hosei.ac.jp, uga.hiroyuki@pref.saitama.lg.jp

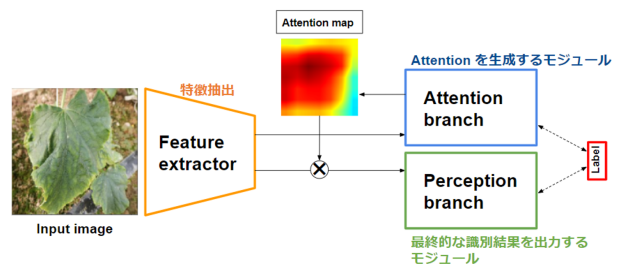



図 1: attention branch network



(a) ABN より得られる attention map (M)
 (b) ガウス分布を基に作成した attention map (C)
 (c) center attention を適用した attention map (M · C)

図 2: center attention で用いる attention map

識別根拠を得ている事が前提であるため、このままでは効果が限られる。本報告では、CNNs が本来の解析対象である葉により注目するように学習させるため、ABN をベースに、診断が求められるほとんどの葉領域は中央に写っている傾向があることを利用し、ネットワークが中央領域に注目するよう工夫した center attention を提案する。評価実験を通じて、提案手法における識別器の汎化性能および判断根拠の改善を検証した。

2 Center attention

本報告では、ImageNet (一般物体画像 1000 クラス合計 120 万枚) で事前学習済みの VGG16 [4] を基に識別器の構築をし、global average pooling によって得られる可視化マップを attention map として応用する

ABN (図1) を追加することで attention を考慮したネットワークを作成した. ABNより得られた attention map は必ずしも正しい位置に attention を当てるわけではないため attention をできるだけ中央によせる制約として従来の ABN の損失関数 \mathcal{L}_{abn} に対して新たな損失関数 \mathcal{L}_{cen} を導入する.

$$\mathcal{L} = \mathcal{L}_{abn} + \alpha\mathcal{L}_{cen} \quad (1)$$

α は定数で, 本報告では 1 とした. 損失関数 \mathcal{L}_{cen} は以下のように定義する.

$$\mathcal{L}_{cen} = \text{MSE}(M, M \cdot C) \quad (2)$$

ここで M は ABN より得られる可視化マップ, C はガウス分布を基に作成した attention map である. C と $M \cdot C$ の可視化を図2に示す.

3 評価実験

本研究では, 提案手法である center attention を用いて, キュウリ葉を基にしたキュウリの病害識別器の構築を行い提案手法の有用性の検証のため従来の学習方法と比較実験を行った. 農水省委託プロジェクト「人工知能未来農業創造プロジェクト」参加地域から提供された, 病害7種 (Brown Spot (BS) 1449枚, CMV 1303枚, Downey Mildew (DM) 1457枚, MYSV 1471枚, Powdery Mildew (PM) 688枚, WMV 1344枚, ZYMV 1528枚) および健全 1216枚のキュウリ葉画像を学習に用いた. また, 評価には学習で用いた葉画像とは異なる圃場で撮影された画像 (BS 339枚, CMV 309枚, DM 571枚, MYSV 421枚, PM 293枚, WMV 322枚, ZYMV 436枚, 健全 323枚) を用いた. 前処理としてデータセットの各画像は 224×224 pixels にリサイズした. さらに学習画像には 90度刻みに 360度回転と反転処理を加えることでデータセットの水増しを行った.

比較として VGG16, ABN, center attention を適用した ABN の3つのネットワークを用いた. 識別結果を表1に示す. さらに ABN と center attention を適用した ABN より得られる attention map の比較を図3に示す. 表1より先行研究と同様に, 他の圃場で撮影された葉画像に対して精度が低下した. ABN を追加することで同一圃場かつ別の圃場で撮影されたキュウリ葉画像に対して正解率が向上していることが確認できた. center attention を追加することで従来の ABN より若干の汎化性能の向上と, 図3より, 通常の ABN より得られる attention map と比べて, 比較的葉に注目が当たっていることが分かる. 注目領域を絞ることで深層学習の学習と推論がより明確になったためだと考えられる.

表 1: キュウリ葉画像に対する識別結果

モデル	Accuracy [%]	
	同一圃場	別の圃場
VGG16	95.1	41.0
VGG16+ABN	96.9	46.4
(Ours) VGG16+ABN+CA	96.3	47.8




図 3: attention map の比較

4 おわりに

同一圃場による葉画像による評価ではなく, 異なる圃場による葉画像をより重視するべきであることが分かった. attention 機構を用いた深層学習技術が植物病害診断に対しても有用であることが示唆された. また葉画像の傾向を考慮する center attention を用いて attention map の改善が確認された. 今後の展望として葉だけではなく病変部位も同時に考慮した attention map の生成を行い, ネットワークが不必要な部分からの特徴を抽出しないような制約を検討する.

謝辞

本研究は JSPS 科研費 基盤研究 (C) 17K08033, (2017-2020) の助成を受けたものである.

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] F. Wang, M. Jiang, C. Qian, S. Yang, C. Li, H. Zhang, X. Wang, and X. Tang, "Residual attention network for image classification," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 3156–3164.
- [3] H. Fukui, T. Hirakawa, T. Yamashita, and H. Fujiyoshi, "Attention branch network: Learning of attention mechanism for visual explanation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2019, pp. 10 705–10 714.
- [4] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *CoRR abs/1409.1556*, 2014.