

合成画像を用いたイチゴ葉病害自動診断システム開発の試み

菅野 怜[†]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

植物病害による農作物への被害低減のため、深層学習技術などを用いた植物病害自動診断システムの開発が行われている。こうしたシステムは高い識別精度を達成している一方で、学習画像の背景等の影響により過学習状態になりやすい。例えば、異なる圃場で撮影されるなど、条件が大きく異なる画像に対する識別精度は大幅に低下する。本報告では学習画像数が限られた環境下で画像の多様性確保のため、複数画像を合成し学習に用いる data augmentation 手法を用いて、イチゴ葉に対する病害診断システムを試作した。2つの画像をアルファ合成する Mixup 手法の導入により、イチゴの葉を基にしたイチゴ病害の自動診断において 1.0% の識別能向上を確認した。

1 はじめに

植物病害は、商品価値の低下や収穫量の減少に繋がるため適切な対応が必要であるが、診断には専門的知識を要し人的・金銭的コストを要する。こうした背景から画像解析、特に近年では深層学習技術を利用した植物病害自動診断システムが提案され成果を挙げている。例えば、convolutional neural networks (CNN) を用いたバナナ、キュウリ葉の病害自動診断システム [1, 2] や single shot multibox detector を用いた、広域を撮影した画像からトマト葉を検出し診断するシステム [3] は高い識別精度を報告している。一方で、これらは多くの様々な状況下で撮影された学習画像を必要とする。また識別に使用する画像の状況（撮影場所、背景など）が異なる場合、識別精度が大幅に低下する過学習に対する課題が残されている [4]。本研究では市場経済的な側面から自動診断の需要が高いイチゴに対し、葉画像の解析に基づく病害自動診断システムを試作する。イ

チゴは複葉をもち、撮影時の状況により画像は多様な状態をとるため、システムの汎化性確保は小葉をもつ植物の自動診断に比べて大幅に難しくなる。本報告では、従来から行われている fine-tuning や、画像の回転などの data augmentation といった汎化性向上手法に加えて、一般物体認識分野で近年良好な成果を挙げている、2枚の画像をアルファ合成する mixup [5] と、4枚の切り抜き画像を結合し学習画像を生成する random image cropping and patching (RICAP) [6] を行い、識別精度への貢献度合いを評価する。

2 手法

2.1 データセットと前処理

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、圃場で病害を厳格に管理されたイチゴの4種の病害感染葉（うどんこ病 444枚、萎黄病 61枚、炭疽病（萎凋症）126枚、炭疽病（葉枯症）38枚）および健全葉 399枚の計5種、1,068枚の画像を使用した。各学習画像は、短辺長×短辺長のサイズでランダムな位置で切り取り、316×316 pix. にリサイズ後、水平反転および10度刻みに360°回転させたものの中心224×224 pix. を切り取り、画像を72倍に水増しした。このデータセットを用いて構築した、後述のCNN識別器の性能をBaselineとした。

2.2 複数画像合成による data augmentation

少ない学習画像への過学習を抑制するため、上記前処理済みの複数画像を合成し学習に用いる data augmentation を行った。

2.2.1 Mixup

任意の2枚の画像 x_1, x_2 を選択し、式(1)に基づいてパラメータ α によるベータ分布から合成比 λ を試行ごとに求め、図1のようなアルファ合成画像 x を作成する(式(2))。正解ラベル c は、選択した2枚の画像に対応する one-hot 表現ラベル c_1, c_2 と λ を用いて計算する(式(3))。合成する画像の選び方は、異なるクラス (different classes), 同じクラス (same classes), 制約無し (no regulation) の3種で比較した。

Preliminary investigation on automated strawberry diseases diagnosis using blended images

Satoi KANNO, Satoshi KAGIWADA, Hiroyuki Uga and Hitoshi IYATOMI

Applied Informatics, Science and Engineering, Hosei University

184-8584, Koganei, Tokyo, Japan

satoi.kanno.2r@stu.hosei.ac.jp




図 1: Mixup 合成画像

図 2: RICAP 合成画像

表 1: 平均識別率の比較

data augmentation	accuracy[%]
Baseline [†]	92.5
+ Mixup (different classes)($\alpha = 0.2$)	93.5
+ Mixup (different classes)($\alpha = 0.4$)	93.5
+ Mixup (same classes)($\alpha = 0.2$)	93.4
+ Mixup (same classes)($\alpha = 0.4$)	93.1
+ Mixup (no regulation)($\alpha = 0.2$)	93.5
+ Mixup (no regulation)($\alpha = 0.4$)	93.2
+ RICAP ($\alpha = 0.3$)	78.2

[†] rotation + random crop + horizontal flip

$$\lambda = \text{Beta}(\alpha, \alpha) \quad (1)$$

$$x = \lambda x_1 + (1 - \lambda)x_2 \quad (2)$$

$$c = \lambda c_1 + (1 - \lambda)c_2 \quad (3)$$

2.2.2 RICAP

RICAP は学習画像から任意の 4 枚の画像を選択し、各画像をランダムな位置で切り取ったものを図 2 のように繋ぎ合わせる data augmentation 手法である。各画像の切り取りサイズを決定する高さ h , 幅 w は、それぞれの辺の長さに対し、式 (1) と同様にパラメータ α を用いたベータ分布により得られる割合を掛けることで求める。この際、正解ラベルの値の合成比は、合成後画像において各切り取り画像が占める面積比を用いて計算する。

2.3 識別器の概要

今回用いた識別器は、VGG-16 [7] の ImageNet 学習済みモデルを基に、出力層のみを 5 ノードに変更し、fine-tuning を行って構築した。

3 結果と考察

2.1 で示したデータセットを用いて学習を行い、5 種の識別問題において求めた平均識別率の比較を表 1 に示す。識別器の性能評価には 4-fold cross validation を用い、学習と識別を 5 回繰り返した平均値を求めた。Mixup の導入により精度が向上した。これは、2 枚の画像を合成することで、画像の多様性が増え、過学習

の原因となりやすい画像背景の偏りが緩和されたためであると考えられる。 $\alpha = 0.2$ とした時に、 $\alpha = 0.4$ とした時よりも良好な結果が得られる傾向が確認された。これは、アルファ合成に用いる 2 枚の画像の比率が 1:0 に近い方が良い傾向を示すことを意味し、ほぼ 1 枚の画像に加わる微かな変化が識別能向上に貢献することを示唆している。一方、今回の実験では組み合わせる画像の種類による差は見られなかった。また、RICAP の導入では精度が向上しなかった。これは、各画像を切り取る際、病変の見られない箇所を切り取ってしまう場合があり、正しく学習が進まなかったためであると考えられる。

4 おわりに

Mixup によりイチゴ病害の診断精度が向上することが示唆された。今回の実験では、利用できるラベル付き画像の枚数が極めて限定されていたため、cross validation での評価となった。しかし、いずれの手法も過学習抑制への貢献度合いを検証するため、今後、今回使用した画像と異なる圃場で撮影された新規画像などを用いた評価が必要である。

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す。

参考文献

- [1] J. Amara, B. Bouaziz, A. Algergawy *et al.*, “A deep learning-based approach for banana leaf diseases classification.” *BTW (Workshops)*, pp. 79–88, 2017.
- [2] E. Fujita, Y. Kawasaki, H. Uga, S. Kagiwada, and H. Iyatomi, “Basic investigation on a robust and practical plant diagnostic system,” *Procs. 15th IEEE International Conference on Machine Learning and Applications*, pp. 989–992, 2016.
- [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] 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.
- [5] H. Zhang, M. Cisse, Y. N. Dauphin, and D. Lopez-Paz, “mixup: Beyond empirical risk minimization,” *CoRR arXiv:1710.09412*, 2017.
- [6] K. U. Ryo Takahashi, Takashi Matsubara, “Data augmentation using random image cropping and patching for deep cnns,” *Procs. 10th Asian Conference on Machine Learning 95*, pp. 786–798, 2018.
- [7] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *CoRR arXiv:1409.1556*, 2014.