

## 2段階の画像生成による植物病害自動診断システム 学習用画像の増強

著者	菅野 怜
出版者	法政大学大学院理工学・工学研究科
雑誌名	法政大学大学院紀要. 理工学・工学研究科編
巻	62
ページ	1-4
発行年	2021-03-24
URL	<a href="http://doi.org/10.15002/00023967">http://doi.org/10.15002/00023967</a>

## 2段階の画像生成による 植物病害自動診断システム学習用画像の増強

PPIG: PRODUCTIVE AND PATHOGENIC IMAGE GENERATION  
FOR PLANT DISEASE DIAGNOSIS

菅野 怜  
Satoi KANNO  
指導教員 彌富仁

法政大学大学院理工学研究科応用情報工学専攻修士課程

Image-based autonomous diagnosis for plants is a difficult task since plant symptoms are visually subtle. This subtlety leads to the system overfitting as it sometimes responds to non-essential parts in images such as background or sunlight conditions. Thus, this causes a significant drop in performance when diagnosing diseases in different test fields. Several data augmentation methods utilizing generative adversarial networks (GAN) have been proposed to address this overfitting problem. However, performance improvement is limited due to the limited variety of generated images. This study proposes a productive and pathogenic image generation (PPIG) technique, a framework for generating varied and quality plant images to train the diagnostic systems. In the method, a number of healthy leaf images are generated and the symptomatic characteristics are added to the leaf part of the generated healthy images.

In this study, we conducted experiments to evaluate PPIG using test images taken in different fields from the training images, assuming six disease classes of cucumber leaves. The proposed PPIG can generate natural-looking, healthy and disease images, and data augmentation using these images effectively improved the robustness of the diagnostic system.

**Keywords** : *Data Augmentation, Plant Disease Diagnosis, Generative Adversarial Networks, Image Processing, Deep Learning*

### 1. はじめに

植物病害により農作物の収穫量や品質の低下が引き起こされており、世界中の食物の40%が植物病害により失われているという報告がある [1]. そのため、植物病害を早期発見し、農薬散布や株の除去などの適切な処置を施すことが求められる。しかし、現在の診断方法は、農家や専門家の目視によるものや、必要に応じて遺伝子検査によるものが主流となっており、人的・金銭的・時間的コストが大きい。これを受け、安価で簡易な植物病害自動診断システムの開発が求められ、多くの深層学習ベースの自動診断システムが提案され、高い識別性能を達成してきた [2, 3, 4, 5]. しかし、システム学習時とは異なる実践的な環境で撮影された画像に対しては、診断性能が著しく低下するという問題が報告されている [6, 2].

これを防ぐ手段として、学習画像の多様性を確保することが挙げられる。しかし、十分に多様で大量の画像を実際の圃場で入手することは困難である。これを受け、画像変換モデルである CycleGAN [7] を用い、健全葉画像を擬似的な病害葉画像に変換する研究も成されている [8, 9]. しかし、CycleGAN は 1 対 1 対応の変換を施すモデルであるため、変換によって生成できる画像の枚

数は、健全葉の枚数に制限される。さらに、CycleGAN は画像の全体を変換するため、病害の特徴が現れる葉領域だけでなく、生成される画像の背景にも変化が加わり、適切な画像が生成されない。

そこで、本研究では、2段階の画像生成を行なうことで多様性の損失を解決する productive and pathogenic image generation (PPIG) を提案する。PPIG では、大量の健全葉画像をノイズから生成する (bulk production phase). 次に、画像変換モデルを用いて、病害症状の視覚的特徴を、大量に生成した健全葉画像の葉領域に付加する (pathogenic phase). この手法により生成された多様かつ枚数が制限のない病害葉画像を、識別器学習時の data augmentation に利用し、学習画像と異なる圃場で撮影された画像に対する診断性能への影響を検証する。

### 2. 手法

#### (1) PPIG

本研究で提案する PPIG は、2種類の画像生成モデルを用いて各クラスの多様な画像を生成し、それを data augmentation に活用することで、識別精度を向上させるための手法である。PPIG の概要図を Fig. 1 に示す。1段階めの bulk production phase では、高精細な画像を

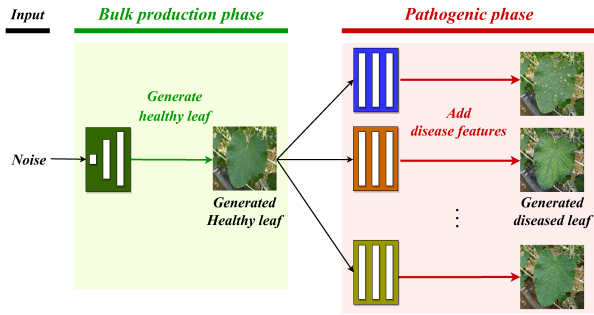


Fig. 1: PPIG の構成

生成できるモデルに健全葉画像を学習させ、さらに多くの健全葉画像を大量に生成する。2段階めの pathogenic phase では、健全  $\leftrightarrow$  病害の変換を学習させたモデルを用い、本物もしくは生成された健全葉画像に病害の特徴を付加する。これにより、多様かつ大量に生成された健全葉画像から、大量の病害画像を入手することが可能となる。

#### a) Bulk production phase

病害に侵された葉は、元の健康な状態の葉から変化が起こる。そのため、この phase では StyleGAN2 [10] を用いて、病徴を持たず、生成画像の最も基本的な形状特徴をもつ、健全葉の高精細な画像を生成する。

#### b) Pathogenic phase

CycleGAN を用いて、健全葉画像に各病害の視覚的特徴を付加する。この際、通常の CycleGAN は画像全体に変換を施すが、背景領域をマスクする AOP [11] を用いて、画像の背景の変化を抑える項を損失関数に加える。

$X$  および  $Y$  をそれぞれ健全葉画像、病害葉画像のドメインとし、葉画像  $x \in X$ ,  $y \in Y$  を AOP に入力し、背景がマスクされた画像  $S_x$ ,  $S_y$  を得る。画像変換モデルは、双方向の generator ( $G: X \rightarrow Y$ ,  $F: Y \rightarrow X$ ) と discriminator ( $D_X$ ,  $D_Y$ ) をもつ。Generator  $G$  の学習時には、discriminator  $D_Y$  は生成画像  $x' = G(x)$  が本物の画像  $y_i \in Y$  であるかどうかを識別する。同時に、 $F$  とそれに対応する discriminator  $D_X$  は、生成画像  $y' = F(y)$  が本物の画像  $x_i \in X$  であるかどうかを識別する。また、 $G: X \rightarrow Y$  の変換時の敵対性損失は以下の通りである。

$$\mathcal{L}_{\text{adv}}(G, D_Y) = \mathbb{E}_{y \sim p_{\text{data}}(y)} [(D_Y(y_s) - 1)^2] + \mathbb{E}_{x \sim p_{\text{data}}(x)} [(D_Y(x'_s))^2] \quad (1)$$

ここで  $x'_s = S_x \odot x'$ ,  $y'_s = S_y \odot y'$  であり、 $x_s = S_x \odot x$ ,  $y_s = S_y \odot y$  は  $x \in X$ ,  $y \in Y$  をマスクした画像である。同様に、 $F: Y \rightarrow X$  の敵対性損失は以下の通りである。

$$\mathcal{L}_{\text{adv}}(F, D_X) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [(D_X(x_s) - 1)^2] + \mathbb{E}_{y \sim p_{\text{data}}(y)} [(D_X(y'_s))^2] \quad (2)$$

また、双方向変換の一貫性を保つためのサイクル一貫性

Table 1: データセットの内訳

Class	Train [枚]	Test [枚]
Healthy	14,379	1,138
CCYV	4,721	1,248
MYSV	10,670	1,468
ZYMV	10,210	3,363
CLS	6,675	491
PM	6,390	1,135
Total	53,045	8,843

損失は以下の通りである。

$$\mathcal{L}_{\text{cyc}}(G, F) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [|F(G(x)) - x|_1] + \mathbb{E}_{y \sim p_{\text{data}}(y)} [|G(F(y)) - y|_1] \quad (3)$$

さらに、本物の画像と生成画像間の背景の類似性損失として  $\mathcal{L}_{\text{bs}}$  を導入する。背景画像は、入力画像とその葉領域をマスクした画像の内積で表される。これを用いて、 $\mathcal{L}_{\text{bs}}$  を以下のように計算する。

$$\mathcal{L}_{\text{bs}}(G, F) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [(1 - S_x) \odot (G(x) - x)|_1] + \mathbb{E}_{y \sim p_{\text{data}}(y)} [(1 - S_y) \odot (F(y) - y)|_1] \quad (4)$$

これらの損失を合わせ、最終的な損失関数は、

$$\mathcal{L}(G, F, D_X, D_Y) = \mathcal{L}_{\text{adv}}(G, D_Y) + \mathcal{L}_{\text{adv}}(F, D_X) + \lambda [\mathcal{L}_{\text{cyc}}(G, F) + \mathcal{L}_{\text{bs}}(G, F)] \quad (5)$$

となる。ここで、 $\lambda$  は損失関数のバランスを決定する係数であり、本研究では  $\lambda = 10$  とした。この損失関数を最小化するように学習することで、健全葉画像がもつ背景情報を病害葉画像に引き継いだまま、画像変換が施される。

## (2) 評価実験

提案手法の有効性を検証するために、キュウリ葉に発生する植物病の自動診断を対象に評価を行った。識別器の学習と評価には、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キュウリ葉の5種の病害感染葉 (cucurbit chlorotic yellow virus (CCYV), melon yellow spot virus (MYSV), zucchini yellow mosaic virus (ZYMV), corynespora leaf spot (CLS), powdery mildew (PM): ) および健全葉の画像を使用した。使用した画像の枚数を Table 1 に示す。各画像は  $512 \times 512$  pix. にリサイズした。識別器として以下の条件で EfficientNet-b1 [12] をそれぞれ学習し、性能を比較した。




Fig. 2: 本物のキュウリ葉画像と PPIG で生成された画像

Table 2: F1-score の比較

Dataset	F1-score [%]							
	Healthy	CCYV	MYSV	ZYMV	CLS	PM	Macro avg.	Micro avg.
Baseline	65.3	76.9	62.1	82.5	52.9	59.2	66.5	71.5
+ CycleGAN	65.1	77.7	64.0	86.2	53.8	66.4	68.9	74.3
+ Pathogenic phase	67.1	<b>79.9</b>	64.4	84.5	<b>59.4</b>	73.4	71.4	75.4
<b>(Proposed) + PPIG (×1.5)</b>	69.5	76.2	66.5	92.1	53.5	76.7	72.4	78.5
<b>(Proposed) + PPIG (×2)</b>	75.1	75.3	<b>73.2</b>	92.5	59.3	<b>79.9</b>	<b>75.9</b>	<b>81.2</b>
<b>(Proposed) + PPIG (×3)</b>	<b>76.0</b>	76.3	72.2	<b>92.7</b>	55.5	79.5	75.4	81.1
<b>(Proposed) + PPIG (×4)</b>	75.9	75.1	71.9	92.3	57.1	79.8	75.3	80.8

- **Baseline** Table 1 に示した学習用画像 53,045 枚を使用した.
- **+CycleGAN** 通常の CycleGAN を用いて本物の健全葉画像から生成した病害葉画像を baseline のデータセットに追加し, 各クラスの枚数を 14,379 枚にした.
- **+Pathogenic phase** Pathogenic phase で AOP を用いた損失項を追加して学習した CycleGAN を用いて, 本物の健全葉画像から生成した病害用画像を baseline のデータセットに追加し, 各クラスの枚数を 14,379 枚にした.
- **+PPIG** 提案手法である PPIG で生成した健全葉画像および病害葉画像を baseline のデータセットに追加し, 各クラスの枚数を 14,379 枚の 1.5 倍 (21,568 枚), 2 倍 (28,758 枚), 3 倍 (43,137 枚), 4 倍 (57,516 枚) にした.

全てのデータセットの学習において, 学習データに対して RandAugment [13] を適用した. この際, 適用する data augmentation の数  $N=6$ , それらの強度  $M=8$  とした. 最適化手法は MomentumSGD [14] を用い, 50 epoch 学習した.

### 3. 結果と考察

#### (1) 生成画像の視覚的評価

Fig. 2 に本物および生成されたキュウリ葉画像を示す. 生成された健全葉画像には, 不自然な背景を有しているものがあったが, それらを変換して生成された病害葉画像は, 背景の変化が抑えられ, 葉領域に病害の特徴が付加された.

#### (2) 生成画像による data augmentation の評価

Table 2 に各条件で学習した識別器の性能を示す. 背景の変換を抑える損失を追加して学習したモデルの生成



(a) CCYV



(b) 生成された CCYV (c) 正しく識別された CCYV (d) 誤識別された CCYV

Fig. 3: (a): 本物の CCYV (b): 生成された CCYV (c), (d): 識別器が正しく / 誤って識別した CCYV

画像を用いた場合、通常の CycleGAN を用いた場合より F1-score が大きかった。これは、健全葉画像の背景を病害葉画像にも引き継ぐことで、病害葉画像の多様性が強化されたためであると考えられる。

さらに、PPIG を用いて各クラスの画像枚数を 28,758 枚にした際、F1-score が最も大きくなった。そのため、PPIG による data augmentation は、識別器の学習に有効であることが示された。一方で、データセットの画像枚数をさらに増加させた際、F1-score は向上しなかった。これは、画像を大量に生成した際にその多様性が頭打ちになり、識別器が類似した生成画像を学習したためであると考えられる。

また、PPIG を用いた場合の CCYV に対する F1-score は、baseline よりも低かった。ここで、Fig.3 に本物の CCYV、生成された CCYV、PPIG( $\times 2$ ) データセットで学習した識別器が正しくもしくは誤って識別した CCYV の画像例を示す。生成された CCYV の画像や正しく識別された画像には、その症状である葉表面の濃淡の変化が強く表れていた。一方で、誤識別された画像に表れた症状は弱かった。このことから、識別器が強い病害特徴をもつ生成画像を多く学習し、評価用画像に含まれる病害特徴の弱い画像を誤識別したと考えられる。

#### 4. おわりに

2 段階の画像生成モデルを用いた PPIG により、高解像度のキュウリ葉病害の画像が生成された。さらに、生成画像を識別器の学習に用いることで、平均の診断性能が向上することが示された。付加する病害特徴の強弱を加減できる手法を用いて、より有用な画像生成を試みる事が望まれる。

#### 謝辞

本研究は農林水産省委託プロジェクト「AI を活用した病害虫診断技術の開発」JP17935051 の助成を受けたものである。

本研究にあたり、データセットの提供ならびに様々な面で支援して下さった生命科学部の専任講師である鍵和田聡先生、埼玉県農業技術研究センターの宇賀博之様、研究用データ整理作業の多くを担当していただいた彌富研究室の澁谷将吾様、全般のご指導のみならず、心身の健康にも常日頃よりお気遣いいただきました彌富仁教授に深く御礼申し上げます。

I also thank Shunta Nagasawa and Quan Huu Cap for fruitful discussions.

#### 参考文献

- [1] FAO, "Protecting plants, protecting life," *Food and Agriculture Organization of the United Nations*, 2020. [Online]. Available: <http://www.fao.org/plant-health-2020/about/en/>
- [2] 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.
- [3] G. Wang, Y. Sun, and J. Wang, "Automatic image-based plant disease severity estimation using deep learning," *Computational Intelligence and Neuroscience*, vol. 2017, 2017.
- [4] H. Durmuş, E. O. Güneş, and M. Kırıcı, "Disease detection on the leaves of the tomato plants by using deep learning," in *International Conference on Agro-Geoinformatics*. IEEE, 2017, pp. 1–5.
- [5] H. A. Atabay, "Deep residual learning for tomato plant leaf disease identification," *Journal of Theoretical & Applied Information Technology*, vol. 95, no. 24, 2018.
- [6] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," *Computers and Electronics in Agriculture*, vol. 145, pp. 311–318, 2018.
- [7] J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros, "Unpaired image-to-image translation using cycle-consistent adversarial networks," *The IEEE International Conference on Computer Vision*, pp. 2223–2232, 2017.
- [8] Y. Tian, G. Yang, Z. Wang, E. Li, and Z. Liang, "Detection of apple lesions in orchards based on deep learning methods of cyclegan and yolov3-dense," *Journal of Sensors*, vol. 2019, 2019.
- [9] H. Nazki, S. Yoon, A. Fuentes, and D. S. Park, "Unsupervised image translation using adversarial networks for improved plant disease recognition," *Computers and Electronics in Agriculture*, vol. 168, pp. 105–117, 2020.
- [10] T. Karras, S. Laine, M. Aittala, J. Hellsten, J. Lehtinen, and T. Aila, "Analyzing and improving the image quality of stylegan," *The IEEE Conference on Computer Vision and Pattern Recognition*, pp. 8110–8119, 2020.
- [11] T. Saikawa, Q. H. Cap, S. Kagiwada, H. Uga, and H. Iyatomi, "Aop: An anti-overfitting pretreatment for practical image-based plant diagnosis," pp. 5177–5182, 2019.
- [12] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," *International Conference on Machine Learning*, pp. 6105–6114, 2019.
- [13] E. D. Cubuk, B. Zoph, J. Shlens, and Q. V. Le, "Randaugment: Practical automated data augmentation with a reduced search space," pp. 702–703, 2020.
- [14] N. Qian, "On the momentum term in gradient descent learning algorithms," *Neural Networks*, vol. 12, no. 1, pp. 145–151, 1999.