# 法政大学学術機関リポジトリ

# HOSEI UNIVERSITY REPOSITORY

PDF issue: 2025-07-02

# 植物病害自動診断における効果的な全体・茎 頂部画像のデータ拡張手法の提案

# イダロ, ティムジェイソン / IDALO, Tim Jason

(出版者 / Publisher)
法政大学大学院理工学研究科
(雑誌名 / Journal or Publication Title)
法政大学大学院紀要.理工学研究科編
(巻 / Volume)
65
(開始ページ / Start Page)
1
(終了ページ / End Page)
5
(発行年 / Year)
2024-03-24
(URL)
https://doi.org/10.15002/00030724

# 植物病害自動診断における 効果的な全体・茎頂部画像のデータ拡張手法の提案

### PROPOSAL OF AN EFFECTIVE DATA AUGMENTATION METHOD FOR WHOLE PLANT AND STEM TOP IMAGES IN AUTOMATED DIAGNOSIS OF PLANT DISEASE

# イダロ ティムジェイソン Tim Jason IDALO 指導教員 彌冨仁

## 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

In recent years, automatic plant disease diagnosis systems based on deep learning techniques have been proposed. These studies have mainly used images of plant leaf surfaces as input, and there has been no progress in the development of diagnosis systems for other parts of the plant. In addition, while high discrimination accuracy can be obtained for images taken in the same field (shooting environment) as that of the training data, there is still a problem that the discrimination accuracy for images taken in different fields (unknown data) is significantly reduced. Therefore, in this study, we focused on the diagnosis of whole plants and stem tops, and constructed an automatic diagnosis system using a high-performance convolutional neural network model. In addition, a new data expansion method utilizing latent diffusion model is introduced. We trained images of diseases for which data is limited, generated thousands of similar images based on them, and incorporated them into the dataset. In addition, to increase the diversity of the data, we generated healthy images taken in different fields with the disease symptoms of each disease. These images were added to the dataset and the performance of the classification model was verified. The improved generalization performance of the classification model confirms the usefulness of the proposed model.

Keywords : plant disease diagnosis, convolutional neural networks, image classification, stable diffusion

### はじめに

グローバリゼーションが進み、多くの人や物資が国境 を超えるようになり, 植物の害虫や病気は世界中に広 がっている.国連食糧農業機関 (FAO) が人間の栄養に とって重要な作物としてリストアップしている 168 種類 の作物には、何百もの菌類病が影響を及ぼしている.薬 剤の大量施用, 病気に強い品種を栽培しているにもかか わらず, 世界では毎年 10% から 23% の収穫前段階の作 物を菌類病で失っている [1]. 日本国内でも被害は多く確 認されており,植物病害によって農作物の生産可能量の 約3割が失われているとの報告がある[2].同時に、地球 規模の気候変動により病害の分布域が拡大し, さらなる 被害が懸念される.植物病害による収穫量の減少は,植 物に大きく依存する私たちの食糧安全保障に関わる問題 である.被害を最小限に抑えるために,植物病害の症状 の早期発見と的確な診断に基づいた対処を行うことが重 要である.現在の一般的な診断方法は、経験豊富な農家・ 専門家による目視であり、必要に応じて専門機関による 遺伝子検査も行われる.しかし、これらの方法では人的・ 金銭的・時間的なコストを要する. こうした背景から, 深

層学習技術を活用した高速で安価かつ頑健性を兼ね備え た植物病害自動診断システムの開発がされてきた [3].

画像による植物病害自動診断システムにおいて, CNN: Convolutional Neural Network (畳み込みニュー ラルネットワーク)[4] と呼ばれる深層学習技術が主に使 われている. この手法を用いて, Mohanty らは学習デー タと同様に Plant Village データセット [5] からなるテ ストデータに対して、99.3% という高い識別精度を達成 した.しかし、学習データと異なる環境で撮影された画 像を使用したテストデータで診断した場合,識別精度が 約 31% まで低下したことを確認した [6]. Fuentes らも, 学習データと同じ実験場で撮影された画像のデータセッ トに対して 99.5% の正解率を達成したが, 実際の栽培環 境で撮影されたテストデータに対しては正解率が約33% まで下がった [7]. このように, 学習データに存在しない 未知のデータにおいては、識別精度の大幅な低下が報告 された. つまり、分類モデルが過学習することが発見さ れた. これは、撮影機器や背景など、診断対象の領域以外 の要素に起因すると考えられた. これらの研究で使用さ れた画像は、各葉が一枚ずつ、統一された環境(似たよう な距離,角度,照明,背景)で撮影されていたためである. 圃場の違いによって識別能力が大きく乖離するという

課題に対処するために、様々な研究が行われた. Saikawa らは学習データに背景除去や輝度調整などの処理, Anti Over-fitting Pretreatment (AOP) を施した. F1-score は AOP が適用されていないモデルと比べて 12.2% も向 上し、52.5% に達した [8]. Shibuya らも高解像度の画像 の学習は, AOP と同様に過学習を抑制する効果があるこ とを発見した [9]. これらの研究では、識別能力の向上が 確認されたが、性能の差異は依然として顕著であり、未 だに克服されていないと言える.

これまで紹介した研究は、植物の葉表を対象とした研 究がほとんどである.しかし、実際には葉だけでなく、植 物全体と茎頂部を観察しなければ、正しい診断ができな い病害が存在する. ナスの半身萎凋病と青枯病がその代 表的な例である. それらの病害は, 専門家でも診断が難 しいため,全体や茎頂部を対象とした自動診断手法の提 案は極めて少ない. そこで本研究では、全体や茎頂部を 対象として、これら2つの病気の自動診断に焦点を当て ました.ここで、実際の現場を想定してテストデータに は学習データとは異なる圃場で撮影された画像を使用し た. データ拡張として、潜在拡散モデルを活用し、デー タが限られている病気の画像を数千枚生成した.また、 各圃場の健全な画像に病徴を出現させた画像も生成し、 データセットに追加して学習させた.本研究では,潜在 拡散モデルで生成された画像をデータセットに追加する ことで多様性を拡充し、それによるモデルの頑健性の向 上を検証しました.

#### 2. 実験

#### (1) Baseline データセット

本研究では、ナスの全体画像と茎頂部画像からなる データセットを Baseline とした.このデータセットは、 Healthy, Verticillium Wilt, Bacterial Wilt (健全, 青枯 病, 半身萎凋病)の3クラスで合計 15,453 枚から構成さ れている.それぞれのクラスの画像の枚数を Table 1 に 示す.各部位と各クラスの画像例を Fig. 1 と Fig. 2 に 示す. Verticillium Wilt と Bacterial Wilt は、ナスの病 害として被害が発生しやすく、診断の必要が高いため、こ の2つの病害を診断の対象とした.ここで、テストデー タは学習データと異なる圃場で撮影された画像である. これらのデータセットで用いられた画像は、農水省委託 プロジェクト研究「人工知能未来農業創造プロジェクト」 に参加している都道府県から提供されたものである.

Table 1 Baseline データセットの構成

No.	Class	Train[枚]	Test[枚]
00	Healthy (HE)	$7,\!664$	929
17	Verticillium Wilt (VW)	$1,\!172$	434
18	Bacterial Wilt (BW)	$4,\!143$	1,111
	Total	12,979	$2,\!474$

圃場には,病害と同様にそれぞれ番号が割り振られて いる.例として,「10\_群馬」,「16\_富山」のように管理 されている.本研究では,病害と圃場の番号を組み合わ

Table 2 Baseline データセットの構成

Class	Fields			
01a55	Train	Test		
Healthy	群馬, 富山, 山梨, 三重	高知, 京都		
Verticillium Wilt	群馬, 鹿児島	三重		
Bacterial Wilt	富山, 山梨, 三重, 鹿児島	群馬		

#### せた独自のトークンをいくつか設定した.







(a) 健全(b) 青枯病(c) 半身萎凋病Fig. 1 ナスの全体画像の例



(a) 健全
 (b) 青枯病
 (c) 半身萎凋病
 Fig. 2 ナスの茎頂部画像の例

### (2) 画像生成

本研究では、Dreambooth を使用して Stable Diffusion 2.1 を Fine-tuning し、病気の画像生成モデルとした. この過程で、異なる学習設定やプロンプトを組み合わせ、計5つの画像生成手法で画像生成を行った.

# (3) 共通設定

共通で使用する設定を以下に示す.

- 学習時
  - resolution = 512
  - learning rate = 1e-6
  - input images = 30
- 生成時
  - resolution = 512
  - num inference steps = 80
  - guidance scale = 15

また,学習時も生成時も,プロンプト始まりを"photo of"とした.これは,生成画像が現実世界の画像であると いう縛りを設けるためのプロンプトである.

#### a) FreeU のパラメータについて

FreeUは、生成される画像の品質に合わせて、その都 度 backbone features や skip features の割合を調整し、 画像の品質を上げるために適している.しかし、大量の 画像を生成する場合、手間がかかってしまう.本実験で は、生成画像の高品質化ではなく、品質低下を予防する 目的で FreeU を導入した.また,パラメータの大幅な調整は行わず,輪郭の情報を持つ backbone features の比率のみを 1.05 に変更した.これにより,複数葉の結合や根の肥大化などの不適切な情報を排除できると期待される.

#### (4) 提案する画像生成手法

次に、5 つの画像生成手法それぞれの具体的な内容を 以下に示す.補足として,以下で言及する「概念」とは, 特定の病害とそれが発生した圃場を一組として捉え,こ の組み合わせを「概念」と呼んでいる.また,一つの概念 は病害と圃場の二つの情報を持つことから,「識別子」は この二つの管理番号の組み合わせとした.例えば,「10-群馬の17\_半身萎凋病」という概念には,";17-10;"と設 定した.これは、生成に使用するプロンプトに不要な情 報が含まれないようにするための工夫となっている.

#### a) Standard-augmentation

Standard-augmentation では、各概念を個別の学習 データとして扱った. 各概念の識別子をプロンプトに組 み込み、それぞれの概念ごとに 1500 枚の画像を生成し た. この手法で生成された画像を Baseline に追加し、そ のデータセットを"Standard"とした.

#### b) Mix-augmentation

Mix-augmentation では、圃場で区別せずに各病害と 合わせて、一つの概念とした.一つの大きな概念に複数の 概念が集まっているため、それらが組み合わさった画像 が生成できると期待した.識別子には、圃場の管理番号の 代わりに"Mix"を用いた.各概念の識別子";XX\_Mix;" をプロンプトに組み込み、各病害の圃場ごとに 1500 枚 の画像を生成した.例えば、一つの病害に 3 圃場含まれ る場合、4500 枚生成する.この手法で生成された画像を Baseline に追加し、そのデータセットを"Mix"とした.

# c) Prior Preservation Loss を用いた 2 段階 Fine-tune

ここでは、最初に「健全」を含む概念のみを学習デー タとした. この時、学習データの概念に過学習するよ うに Fine-tune した.次に、「病害」を含む概念を学習 データとし、Prior Preservation Loss 考慮して 2 度目の Fine-tune を行った.これにより、各圃場の健全画像に 各病害の病徴が付与されることを期待した.この手法で 生成された画像を Baseline に追加し、そのデータセット を"PPL"とした.

#### d) Standard-augmentation 識別子なしの生成

ここでは、学習時は Standard-augmentation と同様の 設定であるが、識別子を用いずにクラスプロンプトのみ で画像を生成した.これにより、事前学習済みの多数の 概念を組み合わせることができるを期待した.この手法 で生成された画像を Baseline に追加し、そのデータセッ トを"Standard-augmentation w/o token"とした.

#### e) Mix-augmentation 識別子なしの生成

ここでは、学習時は Mix-augmentation と同様の設定 であるが、識別子を用いずにクラスプロンプトのみで画 像を生成した.これにより、事前学習済みの多数の概念 を組み合わせることができるを期待した.この手法で生 成された画像を Baseline に追加し、そのデータセット を"Mix-augmentation w/o token"とした.

#### (5) 前処理

前処理として、始めにデータセットの各画像を中央で クロップし、316×316 pixels にリサイズした.これらの 前処理の流れを Fig. 3 に示す.さらに、学習画像には以 下に示す Online Data Augmentation を施した. Online Data Augmentation とはあるデータサンプルに対して、 様々な処理を加えることで正解ラベルの情報を保持し たまま、擬似的なデータを作成する手法である. 擬似的 に増えたデータセットを学習に用いることで分類モデ ルの汎化性能を向上させることができる. Online Data Augmentation を施したときの例を Fig. 4 に示す.



Fig. 3 前処理



Fig. 4 Online Data Augmentation

#### 3. 評価方法

本実験では、ImageNet で事前学習済みされた EfficientNetV2-S (21k)を用いて、それぞれのデータ セットでFine-tuningを行った.それぞれの画像生成手 法で生成した画像を適用した場合と、未適用の場合との 比較を行った.これにより、各手法で生成された画像が もたらす汎化性能への影響を検証した.各手法の評価 は、各クラスごとのF1 スコアで行った.各手法の評価 は各クラスごとのF1-score で評価した.

#### 4. 結果・考察

Baseline データセットと作成した5つのデータセット を識別した結果を Table 3 に示す.5つの画像生成手法 で生成された画像を学習データとして用いたモデルの識 別精度を比較した.

Table. 3 より, 作成した全てのデータセットに対する Macro avg. と Accuracy は, **Baseline** のよりも高かっ

Dataget	F1-score [%]				
Dataset	HE	VW	BW	Macro avg.	Accuracy
Baseline	75.5	27.3	60.3	54.4	62.8
Standard	72.4	35.4	64.2	57.3	64.2
Mix	72.2	37.6	60.6	56.8	62.9
PPL	72.0	35.1	60.9	56.0	63.0
Standard w/o token	73.5	41.7	66.3	60.5	66.4
Mix w/o token	72.0	42.5	63.7	59.4	65.0

Table 3 ナスの病害識別結果 (F1-score)

た.特に, **Standard w/o token** では, Macro avg. が 6% 程度と Accuracy が 4% 程度向上した. **Standard** w/o token は, どのデータセットよりも優れた識別結 果を示した. **Mix w/o token** では, 同様の性能向上 が見られ, VW に対する F1-score は **Standard w/o** token よりも高かった. さらに, 作成した全てのデータ セットでは, 2 つの病害に対する F1-score が **Baseline** のと比較して向上した.しかし, HE に対してはどのデー タセットでも F1-score が低下した.

## 5. 考察

Baseline を除いた 5 つのデータセットでは, Macro avg. と Accuracy の向上が確認できた. これは, Baseline データセットと比べて他の5つのデータセットは学 習用画像の数が多いためだと考えられる. CNN モデル は、学習画像が増えるとある程度汎化性能が上がるため、 本実験でも数 % の上昇が確認できた. Standard w/o token では, Macro avg. と Accuracy の最高 F1-score を記録した. これは, 識別子のないプロンプトによって 画像が生成されたことで学習データの概念と text-toimage モデルが事前学習していた概念が合わさり, 新た な概念を獲得したと考えられる. これにより, 生成され る画像の多様性が向上したと言える.したがって、デー タ拡張として行った画像生成手法が分類モデルの汎化性 能を向上させるのに寄与したと考えられる. Mix w/o token についても, Standard w/o token 同様の効 果が得られたと推測できる. しかし, Mix w/o token の text-to-image モデルは, Standard w/o token の モデルより汎化性能が低いため、textbfStandard w/o token よりも多様な画像を生成することができなかっ た. したがって, Standard w/o token データセット で学習した分類モデルの方が汎化性能優れていたため, F1-score を超えることができなかった. その他のデー タセットの text-to-image モデルも, Standard w/otoken の text-to-image モデルと比較して劣っているた め, Standard w/o token の F1-score を上回ること ができなかったと考えられる.5つのデータセットにお いて, HE に対する F1-score が上がらなかった. PPL と Mix w/o token データセットでは、HE に対する F1-score 最も低かった. これは、概念の組み合わせに よる影響が考えられる. 上記でも言及したが, PPL の text-to-image モデルは学習不足が疑われる. 学習不足

に陥ると,植物に葉の病徴を学習しきれず健全に似た植物の画像が生成されることがある.この際,生成された 画像はすべて病害のラベルがつけられる.したがって, 分類モデルは生成された健全に似た画像を病害として学 習する.このように,学習不足が HE の誤分類に繋がっ ていると推測される.

### 6. おわりに

本研究では、Dreambooth で Stable Diffusion 2.1 を Fine-tune し、わずかな学習データから病害画像の生成 した.まず、病害の概念で Stable Diffusion を少し過学 習させることで、病害の概念と大規模なデータセットで 事前学習したバリエーション豊かな植物の概念を融合さ せることに成功した.また、複雑なプロンプト必要とし ないため、低コストでデータセットの多様性を上げるこ とが可能になった.この手法で生成された画像が分類モ デルの汎化性能の向上に貢献したことを確認した.

今後の展望として,複数の概念をミックスさせて学習 させた場合の生成画像の品質向上が求めらる.そのため に, Dreambooth のパラメータ調整や学習データの見直 しが必要となってくると予想される.

#### 謝辞

本研究にあたり, 全般にわたるご指導をしてくださっ た彌冨仁教授, 生命科学部の鍵和田聡先生, データの提 供とその取りまとめをしていただいた国立研究開発法人 農業・食品産業技術総合研究機構の皆様, および知的情 報処理研究室の皆様に深く御礼申し上げます.

#### 参考文献

- E. Stukenbrock and S. Gurr, "Address the growing urgency of fungal disease in crops," *Nature*, vol. 617, no. 7959, pp. 31–34, 2023.
- [2] 福田一徳, 濱本宏, 橋本将典, 中山万奈美, 根津修, 鍵和田聡, 大島研郎, and 難波成任, "我が国におけ る農業関連企業および農家等の植物病に対する対処 の実態調査," 日本植物病理学会報, vol. 81, no. 2, pp. 127–135, 2015.
- [3] M. H. Saleem, J. Potgieter, and K. M. Arif, "Plant disease detection and classification by deep learning," *Plants*, vol. 8, no. 11, p. 468, 2019.

- [4] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [5] D. Hughes, M. Salathé, et al., "An open access repository of images on plant health to enable the development of mobile disease diagnostics," arXiv preprint arXiv:1511.08060, 2015.
- [6] 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.
- [7] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, "A robust deep-learning-based detector for realtime tomato plant diseases and pests recognition," *Sensors*, vol. 17, no. 9, p. 2022, 2017.
- [8] T. Saikawa, Q. H. Cap, S. Kagiwada, H. Uga, and H. Iyatomi, "Aop: an anti-overfitting pretreatment for practical image-based plant diagnosis," in 2019 IEEE International Conference on Big Data (Big Data), pp. 5177–5182, IEEE, 2019.
- [9] S. Shibuya, Q. H. Cap, S. Nagasawa, S. Kagiwada, H. Uga, and H. Iyatomi, "Validation of prerequisites for correct performance evaluation of imagebased plant disease diagnosis using reliable 221k images collected from actual fields," in *AI for Agri*culture and Food Systems, 2022.