

実用的な画像に基づいた植物診断に向けた過学習抑制のための前処理

SAIKAWA, Takumi / 犀川, 巧

(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・工学研究科編

(巻 / Volume)

61

(開始ページ / Start Page)

1

(終了ページ / End Page)

7

(発行年 / Year)

2020-03-24

(URL)

<https://doi.org/10.15002/00022886>

実用的な画像に基づいた植物診断に向けた 過学習抑制のための前処理

AOP: An Anti-overfitting Pretreatment for Practical Image-based Plant Diagnosis

犀川巧

Takumi SAIKAWA

指導教員 彌富仁

法政大学大学院理工学研究科応用情報学専攻修士課程

In image-based plant diagnosis, clues related to diagnosis are often unclear, and the other factors such as image backgrounds often have a significant impact on the final decision. As a result, overfitting due to latent similarities in the dataset often occurs, and the diagnostic performance on real unseen data (e.g. images from other farms) is usually dropped significantly. However, this problem has not been sufficiently explored, since many systems have shown excellent diagnostic performance due to the bias caused by the similarities in the dataset. In this study, we investigate this problem with experiments using more than 50,000 images of cucumber leaves, and propose an anti-overfitting pretreatment (AOP) for realizing practical image-based plant diagnosis systems. The AOP detects the area of interest (leaf, fruit etc.) and performs brightness calibration as a preprocessing step. The experimental results demonstrate that our AOP can improve the accuracy of diagnosis for unknown test images from different farms by 12.2% in a practical setting.

Key Words : *automated plant diagnosis, preprocessing, segmentation*

1. 背景

植物病害による被害を抑えることは、世界の食料需要と農業生産性の両立をするために重要である。植物を病害から守ることは農業分野で重要な役割を果たしており、収穫量の向上と食料安全保障の向上につながる。一般に、植物病害の診断は、専門家や経験の豊富な農家の目視による観察、または必要に応じて専門機関での遺伝子検査により行われているため、人的、金銭的、時間的コストを要する。したがって、コスト削減のため自動診断技術による植物病害の診断が強く求められている。病害診断の際、植物の葉は診断に使用される一般的な部位であり、葉画像を用いた植物病害の自動診断は広く研究され、多くの提案が convolutional neural networks (CNN) [1]やそれに関連するモデルに基づくアプローチを使用して有望な結果を達成している。先駆的な研究として、川崎ら[2]は実際の農場で撮影されたキュウリ葉の画像を使用して3クラス(2種の病害と健全)分類をするための3層のCNNによる識別器を提案した。彼らのモデルでは、さまざまな撮影状況や複雑な背景のもとで94.9%の平均精度を達成した。藤田ら[3]によって、より実用化に向けた検討を行うために、病害の初期症状や撮影条件の悪い画像を含めた識別器が開発され、キュウリ葉8クラス(病害7ク

ラスと健全)の診断において平均識別精度は82.3%を達成した。Wangら[4]は植物病害のオープンデータセットである PlantVillage [5]データセットを使用してリンゴの黒腐病の診断を行い、90.4%の平均精度を得た。また、トマト[6, 7]および他のいくつかの植物種[8]の診断研究においても、良好な分類性能が実証される。

さらに、複数の識別対象を含み、広範囲を撮影した画像を使用したより実用的な診断システムも提案されている。Fuentesら[9]は当時最先端の物体検出および認識手法である Faster R-CNN [10]および SSD [11]を使用し、トマト葉の画像計5,000枚に対して調査を行い、平均精度83.6%を達成した。Luら[12]は Fully Convolutional Network [13]を使用してモデルを設計し、小麦の病害データセットに対して98.0%の平均認識精度を達成した。彼らは、提案されたシステムをモバイルアプリケーションにも活用できると主張している。先述した一連の研究は、深層学習のブレイクスルーによって病害診断に対し良い結果を示しているが、学習に用いた環境と異なる環境で撮影された未知のデータでの診断を行う場合に、学習に用いた環境と比べ診断のパフォーマンスが大幅に低下する問題が確認されている。この問題は現在のシステムに対して非常に深刻な課題となっているが、この点に言及している

研究は少数にとどまっている。Mohanty ら [14] は PlantVillage データセットに対して背景が均一な植物葉の画像を使用し、99.3%の分類精度を達成した。しかし、異なる環境で撮影された画像で診断を行った場合、識別精度は約 31%に低下したことも指摘している。[9]では、実験場と実環境の両方から得られたデータセット 58 クラス（植物種と病害を含む）の識別を行った際に 99.5%の正解率を達成した。しかし、モデルが実験場の条件下で撮影された画像のみで学習されているため、実環境の条件下で撮影された画像でテストを行った場合、正解率は約 33%に低下することが示された。Cap ら [15]はより広域な環境を撮影した画像を使用したより実用的な植物診断システムを開発した。彼らの診断モデルは、30,000 枚を超えるキュウリ葉の画像で学習された VGG[16]ベースのネットワークで構成され、同じ環境の農場データセットで 97.4%の平均精度を達成した。しかし、他環境の農場のデータセットでテストを行うと、この結果は 65.8%に低下した。植物病害診断タスクでは、症状の現れ方が常に明確ではないため、画像内の背景や撮影条件の変動などの識別対象以外の情報による識別精度への影響は、一般的な物体認識タスクよりもはるかに大きくなっている。藤田ら [17]は Grad-CAM [18]を使用して、キュウリ葉の病害診断システムの診断証拠の可視化を行った。彼女らのモデルは平均正解精度 93.6%を達成したが、識別器の過学習により、注目すべき葉領域ではなく背景領域にシステムが反応することがあると主張している。

これらの研究は、入力画像に対し何らかの標準化プロセスが必要であることを示している。特に、学習ラベルの品質を確保するために整備された環境で植物を栽培する場合、背景の多様性は制限される傾向がある。例えば、特定の種の病害に感染した一連の画像郡に、固有の背景が見られる点や撮影のされ方に類似点が見られる点などがあげられる。このため、植物病害診断で特に顕著である上記の過学習の問題を軽減するには、region of interest (RoI)のみを抽出する効率的な前処理の導入が必要であると考えられる。一般的に複雑な背景に対する RoI の堅牢な抽出は困難であるが、近年ディープラーニングに基づくいくつかの堅牢な方法が提案されており、優れた機能を持つことが示されている。たとえば、U-Net [19]および pix2pix [20]と呼ばれる手法は、ターゲットドメインの知識を必要とせず、学習画像とそのラベルとなるセグメンテーションエリアのペアを学習させるだけで高いセグメンテーション精度を得ている。前処理の一部としての RoI のセグメンテーションは、画像認識またはコンピュータビジョンのタスクで不可欠なステップであった。しかし、深層学習の活用によって、このステップの必要性は減り、一部の医療タスクを除いて一般的に省略されている。一方で上記の理由により、実際の画像ベースの植物病害診断タスクにおいては、高度な領域抽出プロセスが必要となった。本研究では、深刻な過学習の問題に対処

Table 2.1 本実験で使用したデータセット

Disease	Disease classification dataset			
	Training	Validation	Test (Different farm)	
Viral disease	MYSV	7,448	827	2,596
	ZYMV	9,189	1,021	3,364
	CMV	4,109	456	563
	WMV	2,511	279	306
Fungal disease	Brown Spot	2,014	224	654
	Downy Mildew	1,311	146	380
	Powdery Mildew	2,204	245	114
Healthy	6,908	768	1,138	
Total	35,694	3,966	9,115	

するため、画像ベースの植物病害診断システムの前処理として、関心のある領域（葉、果物など）を抽出するための anti-overfitting pretreatment (AOP) を提案する。本研究は植物病害診断タスクにおける関心領域のセグメンテーションを実施し、実際の農場画像を使用して妥当性を確認する最初の研究である。

2. 方法

(1) データセット

本研究では、2種類のキュウリ葉のデータセットを使用した。

1つ目はキュウリ葉の画像計 8,000 枚の葉領域抽出用データセットと、それらに対応する葉領域の抽出済みの ground truth で構成されている。このデータセットは、本研究で提案する AOP の学習に使用し、葉領域抽出用データセットに適した状態の画像のみを収集した（明るすぎる画像や、暗すぎる画像、およびその他の悪条件の画像の削除を行った）。このデータセットはさまざまなアスペクト比の画像で構成されているため、画像の短辺を辺の長さを一辺とする正方形の大きさと中央領域の切り抜きを行い、316×316 ピクセルにサイズの変更を行った。

2つ目は、Table 2.1 に示されているように、単一のキュウリ葉が撮影された 48,775 枚の画像で構成される分類用のデータセットである。これらの画像は、農業技術研究センターの専門家によってラベル付けされた。このデータセットの各画像は、4種類のウイルス性病害（MYSV、ZYMV、CMV、および WMV）と3つの真菌性病害（Brown Spot、Downy Mildew、Powdery Mildew）と健全葉計 8 クラスで構成されている。この分類用データセットは、モデル学習用の $disease_{training}$ 35,694 枚、モデル評価用の $disease_{validation}$ 3,966 枚、およびモデル検証用の $disease_{test}$ 9,115 枚からなり、最終的な病害診断システムの検証には $disease_{test}$ を使用し検証を行った。これらの分類用データセットは識別器に入力する際に、224×224 ピクセルにリサイズを行う。 $disease_{training}/disease_{validation}$ は同一の環境から取得したデータであるのに対し、 $disease_{test}$ は異なる環

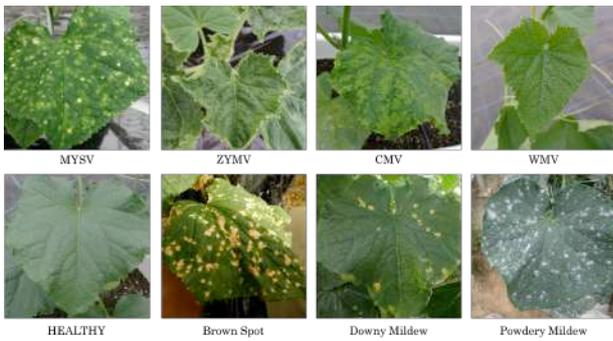


Fig. 2.1 使用したデータセットの例

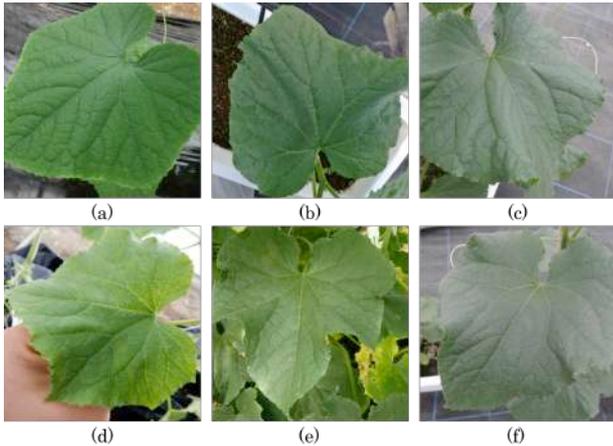


Fig. 2.2 病害の初期症状の例(a: MYSV, b: CMV, c: WMV, d: Brown Spot, e: Powdery Mildew f: Healthy Leaf)

境から取得されたデータセットである。Fig. 2.1 に、使用したデータセットの各病害例を示す。

また、このデータセットには、MYSV, CMV, WMV, Brown Spot, Powdery Mildew などの初期症状の画像が多く含まれている。これらの初期症状の画像は、それぞれ健全な画像と区別できない。Fig. 2.2 に、病害初期の例を示す。

(2) Anti-overfitting pretreatment (AOP)

提案手法である anti-overfitting pretreatment (AOP) の主な機能は、RoI (葉の形状) の領域抽出と画像の明るさ補正である。本手法は、過学習の問題を引き起こす背景領域の影響を減少させることを期待する。

AOP モデルは pix2pix のアーキテクチャに基づいており、Generator と Discriminator で構成されている。Fig. 2.3 に、AOP の概略図を示す。

Generator は U-Net アーキテクチャを使用している。Generator は 8 つの畳み込み層と 8 つの逆畳み込み層で構成され、Discriminator は 5 つの畳み込み層で構成される。一般的に逆畳み込み層はチェッカーボードアーティファクト[21]と呼ばれるノイズを生成することが知られているため、これを回避するため本実験では畳み込み層の後に unpooling を使用する。

pix2pix は、優れたセグメンテーションおよび画像変換

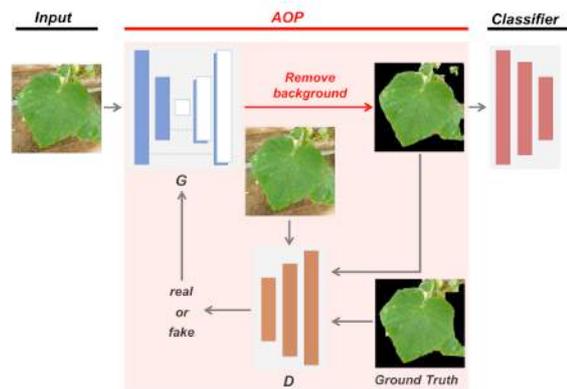


Fig. 2.3 AOP の概略図

機能を持つことが示されている。一般に pix2pix は画像変換に使用されるため、照明条件が悪い画像などの輝度を改善するために使用できると考えられる。本実験で使用する画像は実際の農場で撮影された条件悪い画像も含まれている。よって、AOP は画像のセグメンテーションを実行し、画像の状態も改善すること期待する。

輝度補正の機能追加は、AOP の学習時に data augmentation としてガンマ補正を行い、入力画像に輝度の変化を追加することで行っている。ガンマ補正のガンマ値は[0.8, 1.0, 1.5, 2.0, 2.2]の中からランダムに選択した。この明るさの調整により、モデルが入力画像を良い撮影条件の画像に変換し葉領域が抽出された画像を生成できると考えられる。

AOP モデルの精度向上のため学習には data augmentation として 90°刻みの画像の回転, ミラーリング, 256×256 ピクセルのサイズへのランダムクロッピングを行っている。

pix2pix では平均絶対誤差 (MAE) が content loss に使用されているが、より構造的特徴をモデルが捉えられるように Structural Similarity (SSIM) [20]に変更を行った場合の検証も行った。

(3) 病害識別器

本研究の最終目的は、実環境に近い未知のデータセットで診断システムをテストし、過学習に対する AOP の有効性を証明することである。したがって、さまざまな病害識別器を設計し、未知である $disease_{test}$ でテストを行う。これらのネットワークは ImageNet データセット[22]で事前に学習された VGG-16 をもとに構築され、 $disease_{training}$ を用いて再学習している。

モデルの過学習を避けるため、出力層の前の全結合ではベースとしている VGG16 よりも少数のノード (1024 および 32) を使用している。また、精度向上のため 10°刻みの回転, ミラーリング処理, ガンマ値を[0.5, 1.0, 1.5]からランダムに選択するガンマ補正を data augmentation として行った。

(4) モデルの学習

a) AOP モデルの学習

AOP モデルの学習では、前述の data augmentation がオンラインで実行される。セグメンテーションデータセットの 80% をトレーニング用にランダムに選択し、残りの 20% を AOP モデルのテストに使用する。本実験では異なる実験条件で学習された 3 つの AOP モデルを比較する。AOP_{MAE} を pix2pix と同じ条件で学習し直接画像を生成するモデルとし、AOP_{MAEprob} を、pix2pix と同じ条件でセグメンテーションマスクを出力する（出力は確率型であり、閾値を 0.5 とし 2 値化を行った）ように学習し入力と出力を合成し画像を生成するモデルとし、AOP_{SSIM} を pix2pix の content loss として SSIM を使用して学習し、直接画像生成を行うモデルとする。

最適化には Generator と Discriminator に $\alpha = 0.0002$, $\beta = 0.5$ の Adam[24] を適用し、バッチサイズは 16, エポック数を 100 とし学習を行った。

b) 識別モデルの学習

本実験では実際の農場で撮影された葉画像を用いて、キュウリの病害診断に対する AOP の効果を調査、比較を行うため、上述の 3 つの AOP モデルを適用したデータセットと AOP を導入していないデータセットでそれぞれ学習を行った識別器を 4 つ作成した。それぞれのモデルの検証には $disease_{test}$ に対してそれぞれ対応した処理を行ったデータを使用した。

識別器の学習にはオンラインで上述の data augmentation を行った。

最適化には学習率 0.001 の momentum SGD[25] を適用し、バッチサイズは 16, エポック数を 100 とし学習を行った。

3. 実験と結果

(1) AOP ネットワークの葉領域抽出精度

作成した 3 種の AOP モデルの評価は Precision, Recall, F1-score を計算し行った。Table 3.1 は、テストデータセット（葉領域抽出用データセットの 20%）における抽出精度の比較結果を表す。Fig 3.1 に、葉領域抽出の結果の例を示す。抽出結果から、葉領域が適切に抽出されたことが示された。AOP モデルは高いセグメンテーション精度を実現し、特に提案手法である AOP_{SSIM} では F1-score 98.1% を達成した。これらの結果は、本セグメンテーションモデルが背景除去に十分効果があり、後続の診断システムの病害診断の性能の改善が期待されることを確認した。

(2) 病害分類器の識別精度

AOP モデルを導入した場合と導入しない場合で、病害の分類精度を評価し、比較を行った。Table 3.2 に識別精度の結果を示す。

Table 3.2 から、全ての識別モデルにおいても

Table 3.1 AOP によるセグメンテーション精度

	Precision [%]	Recall [%]	F1-score [%]
AOP _{MAEprob}	100.0	95.8	95.8
AOP _{MAE}	98.4	97.1	97.8
(Proposed)AOP _{SSIM}	98.6	97.5	98.1

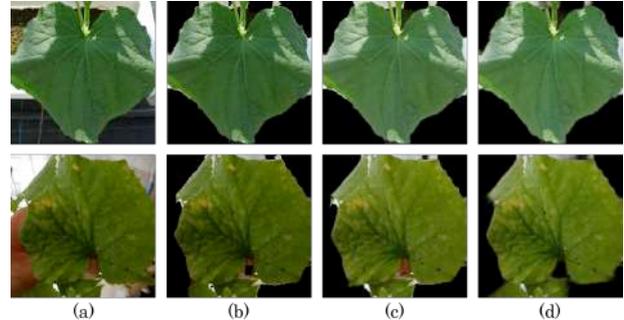


Fig 3.1 AOP による葉領域抽出の結果 (a: original, b: AOP_{MAEprob}, c: AOP_{MAE}, d: AOP_{SSIM})

Table 3.2 AOP を導入した場合としない場合の精度比較

	Average Accuracy [%] (8 Classes)		
	Disease _{training}	Disease _{validation}	Disease _{setset}
w/o AOP	98.2	97.5	40.3
AOP _{MAEprob}	98.2	97.2	48.8
AOP _{MAE}	98.0	97.1	49.7
AOP _{SSIM}	98.0	97.4	52.5

$disease_{training}$ と $disease_{validation}$ の識別精度にはわずかな差しか見られなかったが、 $disease_{validation}$ と未知のデータセットである $disease_{test}$ とは識別精度に大きな差がみられる。特に AOP の導入をしていない識別モデルは識別精度が最も低い結果となった。このモデルの精度は、 $disease_{validation}$ の識別精度 97.5% に対し、 $disease_{test}$ の識別精度 40.3% と大幅に低下する。一方で、AOP_{SSIM} を使用した識別モデルは、未知のデータセットである $disease_{test}$ の識別精度を 12.2% 改善し、52.5% の識別精度で達成している。Fig 3.2 に、病害識別結果の混同行列を示す。

Fig 3.2 の結果から、AOP の導入のありとなしのどちらの場合でも Powdery Mildew への誤識別が見られるが、AOP_{SSIM} による診断精度の改善が確認できる。さらに、診断根拠の可視化を行ったところ AOP_{SSIM} を使用することにより、識別器が背景領域ではなく葉領域に焦点を当てることができることが確認された。Fig 3.3 に、Grad-CAM [16] 手法を使用した AOP なしと AOP_{SSIM} を導入した識別器の診断証拠のヒートマップを示す。ヒートマップが赤いほど、識別器の識別根拠を表す。Fig 3.3 から AOP 導入の結果は、識別器が葉領域に注目し、AOP を導入していない識別器は背景領域を注目していることが確認された。

(a) Without AOP

MYSV	854	40	112	42	61	32	2	1453
ZTMV	688	2105	53	139	21	2	1	355
CMV	45	6	128	7	39	0	2	336
WMV	3	3	20	4	40	0	0	236
HEALTHY	6	1	66	2	217	0	0	846
Brown Spot	21	0	18	0	18	154	36	407
Downy mildew	43	0	0	0	50	7	109	171
Powdery mildew	0	0	0	0	5	0	1	108

(b) With AOP_{SSIM}

MYSV	1046	107	226	28	79	40	6	1064
ZTMV	516	2404	132	129	59	2	3	119
CMV	80	6	261	9	77	0	1	129
WMV	7	3	36	6	118	0	0	136
HEALTHY	15	2	133	2	687	0	1	298
Brown Spot	147	10	35	0	14	153	15	280
Downy mildew	70	1	10	0	66	11	131	91
Powdery mildew	1	1	0	0	11	0	1	100

Fig 3.2 病害識別結果の混同行列

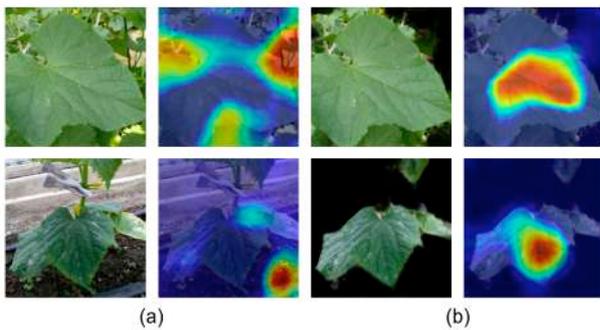


Fig 3.3 (a):AOPなしと(b):AOP_{SSIM}を導入した識別器の診断証拠のヒートマップ

4. 考察

(1) 葉領域抽出

Table 3.1 から AOP による葉領域抽出は高い精度で行うことができることが示された。しかし、出力された画像を確認したところ画像の一部が白飛びしている画像や黒つぶれしている画像に対しては正しく抽出処理されなかった。これは学習画像に白飛びしている画像や黒つぶれ

している画像がなく、葉であると認識されていなかったためと考えられる。そのため、より多様な葉画像の抽出を行うには、白飛びしている画像や黒つぶれしている画像も含めて学習を行う必要があると考えられる。

(2) 識別性能

Fig. 3.3 から、AOP の導入により本モデルは葉領域内に注目するように学習されたことが示された。Table 3.3 に示すように、テストデータにおける AOP 導入なしの病害分類器の精度は 40.3%であったが、AOP_{SSIM}のある分類器は 52.5%の精度を達成し、識別精度は全体で 12.2%向上した。これにより、異なる環境で撮影された未知の検証データセットに対して識別精度が大幅に向上することが示された。この結果は、構造的特徴をよりよく捉える SSIM が、葉領域を適切に抽出し、識別の障害となりうる背景領域が除去された状態での診断に効果的であると考えられる。また、Table 3.3 の結果から、輝度補正が機能している AOP_{MAE} が輝度補正されていない AOP_{MAEprob} と比較して診断精度が 0.9%向上したことから生成された際の輝度補正が精度向上に寄与していると考えられる。しかし、輝度補正による改善のパフォーマンスは予想されていたものよりも小さかった。これは、分類器の学習時の data augmentation に使用されたガンマ補正が機能しており、診断精度に寄与しているためであると考えられる。しかし、Table 3.3 から本実験では、どの場合において検証データセットの診断精度が学習/評価データセットの診断精度よりも低いことを示している。この精度低下の主な原因は、Fig 3.2 に示されたように他の病害や健全の Powdery Mildew への誤検出が多数みられることから、識別器の Powdery Mildew への誤診であると考えられる。特に WMV は、ほとんどが健全または Powdery Mildew として誤識別されている。Table 3.1 より学習データセットには Powdery Mildew が 2,204 枚含まれており、そのデータの約 25%が初期症状の葉画像であった。また、Fig. 2.2 から WMV、MYSV、CMV、Brown Spot、Powdery Mildew の初期症状が非常に酷似している。そのため本実験のモデルでは葉の上に微小な物体が存在するだけで Powdery Mildew と誤識別してしまうと考えられる。上記のことからより実用的なシステムを構築するには初期症状による問題に対処する必要があり、今後の課題である。

5. 結論

本研究では、画像ベースの植物病害診断研究におけるデータセット内の潜在的な類似性によって引き起こされる過学習の問題について確認した。深刻な過学習の問題を軽減する堅牢な画像ベースの植物病害診断を実現するために、RoI の適切なセグメンテーションを行う AOP を提案する。AOP の導入により、未知のキュウリ葉データに対する最終的な診断精度は、8 クラスの病害分類タスクにおいて平均精度が 12.2%向上した。上記のことから背

景を除去することの有用性が示されたが、実用的なシステムを構築するにはより高い精度が求められる。より識別精度を高めるために、他の重要な要因の調査を継続する。

謝辞：本研究にあたり、全般にわたるご指導をくださった彌富仁教授、データセットの提供をくださった各都道府県の皆様とその取りまとめを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、および彌富研究室の皆様、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に深く御礼申し上げます。

参考文献

- 1) A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, pp.1097–1105, 2012.
- 2) Y. Kawasaki, H. Uga, S. Kagiwada, and H. Iyatomi, "Basic study of automated diagnosis of viral plant diseases using convolutional neural networks," *International Symposium on Visual Computing*, pp. 638–645, 2015.
- 3) E. Fujita, Y. Kawasaki, H. Uga, S. Kagiwada, and H. Iyatomi, "Basic investigation on a robust and practical plant diagnostic system," *15th IEEE International Conference on Machine Learning and Applications (ICMLA)*, pp. 989–992, 2016.
- 4) G. Wang, Y. Sun, and J. Wang, "Automatic image-based plant disease severity estimation using deep learning," *Computational intelligence and neuroscience*, vol. 2017, 2017.
- 5) D. Hughes, M. Salathe et al., "An open access repository of images on plant health to enable the development of mobile disease diagnostics," *CoRR preprint arXiv:1511.08060*, 2015.
- 6) H. Durmus, E. O. Gunes, and M. Kırıcı, "Disease detection on the leaves of the tomato plants by using deep learning," *6th International Conference on Agro-Geoinformatics*, pp. 1–5, 2017.
- 7) H. A. Atabay, "Deep residual learning for tomato plant leaf disease identification." *Journal of Theoretical & Applied Information Technology*, vol. 95, no. 24, 2017.
- 8) S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, "Deep neural networks based recognition of plant diseases by leaf image classification," *Computational intelligence and neuroscience*, vol. 2016, 2016.
- 9) A. Fuentes, S. Yoon, S. Kim, and D. Park, "A robust deep-learning based detector for real-time tomato plant diseases and pests recognition," *Sensors*, vol. 17, no. 9, p. 2022, 2017.
- 10) S. Ren, K. He, R. Girshick, and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks," *Advances in neural information processing systems (NIPS 2015)*, pp. 91–99, 2015.
- 11) W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, and A. C. Berg, "Ssd: Single shot multibox detector," *European conference on computer vision (ECCV 2016)*, pp. 21–37, 2016.
- 12) J. Lu, J. Hu, G. Zhao, F. Mei, and C. Zhang, "An in-field automatic wheat disease diagnosis system," *Computers and electronics in agriculture*, vol. 142, pp. 369–379, 2017.
- 13) J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431–3440, 2015.
- 14) S. P. Mohanty, D. P. Hughes, and M. Salathe, "Using deep learning for image-based plant disease detection," *Frontiers in plant science*, vol. 7, p. 1419, 2016.
- 15) Q. H. 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.
- 16) K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *CoRR preprint arXiv:1409.1556*, 2014.
- 17) E. Fujita, H. Uga, S. Kagiwada, and H. Iyatomi, "A practical plant diagnosis system for field leaf images and feature visualization," *International Journal of Engineering & Technology*, vol. 7, no. 4.11, pp. 49–54, 2018.
- 18) R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-cam: Visual explanations from deep networks via gradient-based localization," *Proc. of the IEEE International Conference on Computer Vision*, pp. 618–626, 2017.
- 19) O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *International Conference on Medical image computing and computer-assisted intervention*, pp. 234–241, 2015.
- 20) P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros, "Image-to-image translation with conditional adversarial networks," *Proc. of the IEEE conference on computer vision and pattern recognition*, pp. 1125–1134, 2017.
- 21) A. Odena, V. Dumoulin, and C. Olah, "Deconvolution and checkerboard artifacts," *Distill*, vol. 1, no. 10, p. e3, 2016.
- 22) Z. Wang, A. C. Bovik, H. R. Sheikh, E. P. Simoncelli et al., "Image quality assessment: from error visibility to structural similarity," *IEEE transactions on image processing*, vol. 13, no. 4, pp. 600–612, 2004.

- 23) J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," 2009 IEEE conference on computer vision and pattern recognition, pp. 248–255, 2009.
- 24) D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," CoRR, abs/1412.6980, 2014.
- 25) N. Qian, "On the momentum term in gradient descent learning algorithms," Neural networks, vol. 12, no. 1, pp. 145–151, 1999.