植物病害自動診断技術の動向と課題

彌 富 仁

法政大学理工学部応用情報工学科*

Trends and Challenges of Automatic Diagnosis Techniques for Plant Diseases Hitoshi Iyatomi

Applied Informatics, Faculty of Science and Engineering, Hosei University*

概要

画像解析に基づく植物病害,虫害に対する自動診断技術の開発は、食糧問題だけでなく農業経済の観点からも重要である。筆者らは、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」のうち、「AIを活用した病害虫診断技術の開発」の課題に参画し、画像を元にした自動診断および周辺技術の開発に取り組んでいる。本稿では、植物病害に対する自動診断技術の研究動向と、似たもの同士の中から違いの識別を行う必要があることに起因する人的、技術的な困難さ、対応策などについて報告する。

1. 研究の背景と動向

1.1 農業被害の損失と、早期診断の必要性

病害虫による農作物の被害は大きく、2014年に出版された文献¹⁾によれば、年額の経済的な損失額は300~500億ドルに達することが予想されている。また直近の論文では、全世界の人類が摂取するカロリーの半分を占める5大主要生産物である麦、コーン、大豆、コメ、イモについては、137のいずれかの病原と虫の被害により、その10~40%の損失が推定されると近年報告されている²⁾。農業分野では、その被害について「植物病害虫」と、病害と虫害を合わせて語られ、前者はウイルスや細菌(バクテリア)、真菌(かび)により感染することで被る害を指す。後者はその名の通り、虫による食害をはじめとする直接的な被害に加え、虫を媒介した病気の感染による害も含んでいる。本稿では、筆者らが中心に取り組んできた病害に対する診断技術について紹介する。

植物病害の自動診断は専門家の目視による方法が第一で、必要に応じて遺伝子検査などが行われる。しかしながらこれらはコストと時間を要し、また必ずしも必要とする農業従事者が利用できる状況にあるとは限らない。特に我が国においては、農業従事者数の著しい減少と高齢化が進んでおり、農業の効率化による単位面積あたりの収量の増加と、コストの低減の両立が

求められる³⁾. こうした背景から,高精度で安価で簡単な自動診断技術の開発が求められてきている. 特に我が国の農業現場からは経済的な側面から,園芸作物(果樹,野菜,花き)のうち,特に果樹,野菜に対する診断技術が強く求められている.

1.2 初期の植物病害診断システム

近年の深層学習技術が普及する前の、古典的な機械学習手法に基づく診断手法として、以下の例が挙げられる $^{4-8)}$. これらは、(1)解析対象となる葉や実などの注目領域(ROI:region of interest)の抽出や、色補正といった前処理、(2)識別のために重要な特徴量の設計と抽出、(3) support vector machine(SVM)や neural networks(NN)、random forest などの識別アルゴリズムによる識別の 3 段階からなる.

最初の3つはNNを用いてコメの病気 4),植物の葉と茎に生じる5種類の病気と健全株の識別 5),様々な作物に対する真菌(かび)を病原とした,うどんこ病の診断 6)を行っている。後半の2つは,SVMを用いて5種類のキャッサバ 7),6種類のサトウキビの病気を対象 8)に解析を行っている。いずれの手法も数値評価において約80 9 9%程度,高いものでは99%と,高い診断精度を報告している。しかしながらこれらの手法は,前述の通り独自のhandcrafted な特徴量に基づく識別であり,またそのため,前処理の精度や,写真の撮影環境などにより精度が大きく異なるという問題点があった。

^{* 〒 184-8584} 東京都小金井市梶野町 3-7-2

1.3 深層学習の広がりと、オープンデータセット 公開による本分野の活性化

一方で,深層学習技術の急速な発展と普及は,この分 野を含む様々な分野に劇的な変化をもたらたした. 特 に computer vision の分野において計 8 層からなる畳 み込みニューラルネットワーク (convolutional neural networks: CNN) である通称 AlexNet が, 従来技術 を圧倒する画像認識能を示し CNN の名を一躍世に知 らしめた. CNN は、その学習過程により識別に必要 な特徴量を自ら獲得できる特性により, 前述の困難さ を大幅に低減でき、結果として近年のここまでの普及 の原動力になっている. 植物病害自動診断においては, 畳み込みと全結合 (full connection layer:FC) 層を合 わせて計 16~19 層の VGG-net⁹⁾, residual feedback と呼ばれる層をまたぐバイパスを導入することで、さ らに深いネットワーク(50~152層)による高い表現 能力を実現しつつ、FC 層削減によりパラメータ数を 抑えた Res-net¹⁰⁾,同様にパラメータ数抑制するため に1×1の畳み込みや、スパースな畳み込みを導入し た Inception v3¹¹⁾などの CNN モデルの、それぞれ ImageNet データセットによる pre-trained モデルが 現在よく用いられている.

深層学習技術をベースに,実際の圃場で撮影された 画像を元に開発された最初のシステムの1つに,著者らが埼玉県の協力を元にしたキュウリの自動診断システム 12)が挙げられる.このシステムは,今では当たり前になった事前の解析対象の領域抽出を行わない初めての自動診断システムであった.利用できる教師ラベルつき学習データの数に限り(800枚)があったことから,畳み込み層とプーリングをそれぞれ3回のみ繰り返し,あえてFC層を排除した浅いCNN構成で,800枚の圃場画像の3クラス(2種のウイルス病と健全)に対して cross-validation で94.9%の平均識別精度を実現した.

大規模な Open Dataset である Plant Village dataset¹³⁾が広く web で公開されて以降,この教師ラベル付きデータセットを使った深層学習ベースのシステムが次々と提案された.このデータセットは,もともとは一般の農業従事者あるいは研究者向けに,主に農作物の画像を種類,病気ごとに集め公開していたものであったが,機械学習技術の進展とともに,集まったデータを機械学習用途のデータセットとして公開するようになった. Mohanty らは,14種の作物, Plant Village データセットに含まれる病気と組み合わせ38ペア計54,306枚という大規模な画像データを CNNで学習することで,平均99%以上の識別能を報告している¹⁴⁾.

同様の研究では、リンゴの特定の病気を対象に90%程度¹⁵⁾、トマトの複数種の病気の識別に対して同様に約94%¹⁶⁾および99%¹⁷⁾と、数値上極めて優れた識別能が報告されている。しかし彼らが利用したこのデータセットから用いた学習および評価データは、解析対象となる葉が事前に切り取られ、無地の背景に置かれた状態の画像であった。このため、詳細は以下の課題の項で述べるが、実践的環境では大幅に識別能が低下することが報告されている。このデータセットには、こうした実験室環境ではない実際の圃場で撮影されたとみられる画像も多数公開されていたが、このデータセットがもともと広くユーザサイドから投稿された病気のラベル付きデータを集めたものであったため、教師ラベルの妥当性が課題として指摘されていた。現在、データセットの公開は中止されている。

1.4 深層学習を元にした接写画像を対象にした実 践的なシステム

こうした実験室環境のデータを解析した手法と異な り、実際の圃場から採取された画像を元に独自に構築 したデータセットを元に構築された手法も近年多く提 案されている. こうした研究のほとんどは、葉や実と いった解析対象が1枚の画像の中心にあることを想定 したシステムである.藤田らは、様々な悪条件下の画 像や初期病徴を含んだキュウリの主要ウイルス7種と 健全の8クラス各1,000枚ずつ,計8,000枚の独自の データセットを構築した18). 識別が難しく, また教師 ラベルの管理が難しい初期病徴画像を最初に扱った研 究といえる. 図1に扱ったそれぞれの感染葉の典型例, 図 2 にそれらの初期病徴の例を示す. 類似する対象間 の識別という fine-grained classification 問題の典型と もいえるが、初期病徴例の診断はその中でも極めて難 しい課題と言える. 過学習を避けるために VGG-net を参考にした軽量 CNN モデルで約82%の平均識別率 を実現した.

以下のサーベイ論文^{19,20)}に、1枚の葉や実を対象とした同様研究成果がまとめられている。文献¹⁹⁾では、2017年までに公開された深層学習技術を用いた本分野の成果について、前述の成果を含めて計8つの論文が、発行年、識別クラス数、利用した画像数、前処理とdata augmentation、CNNの構成、転移学習の有無と、平均精度がまとめられている。もう一方のsurvey²⁰⁾では、2018年度初頭までの同様の成果について、用途(識別、病勢などの定量)、CNNの構成、対象植物、病気の種類などが17の文献についてまとめられている。ただし、精度や画像数の情報はまとめられていない。

また,ここに挙げられていない研究で特筆するべき研















図1 キュウリのウイルス病の典型的症状と健全(右端)の例(左から MYSV, ZYMV, CCYV, CMV, WMY, KGMMV および健全株). 画像:[Fujita¹⁸⁾] より.















図2 キュウリのウイルス病の初期症状と健全の例.病気の並び順は図1と同じ.見た目だけでは専門家でも診断が難しい.画像: $[Fujita^{18}]$ より.

究として、Ferentinos による植物種 25 種について病気 と合わせた合計 58 ペア、計約 88,000 枚の画像を対象 とした大規模研究がある 21)。例示されている画像の一部に Plant Village のような事前に切り取られた画像も結果に見受けられるが、最高の結果を示した VGG-net では平均 99%以上の識別精度を達成している。

これら報告されている成果は、いずれも数値上極め て高い識別能を実現しているが、システムの評価は作 成したデータセットを分割、あるいは cross-validation によって行われている。そのため、データセット内に 存在する潜在的な類似性により引き起こされている強 い過学習により、結果が水増しされている懸念がある。 この問題点については後述する.

1.5 複数オブジェクトを対象にした検出十診断モデル

2014 年以降 computer vision 分野では、物体検出と識別を統合して行える手法に注目が集まり、Faster R-CNN 22 や、Single shot multibox detector (SSD) 23 などといった高速で、かつ精度の高い手法が次々と提案されてきた。こうした流れを受け、植物病自動診断分野でも、上記の研究より撮影範囲がやや広範囲(カメラ〜被写体の距離が約 $1\,\mathrm{m}$ 程度まで)で、複数の解析対象が含まれる画像を対象としたシステムが多くはないが提案されるようになった。

Luらは、独自の麦の 6 種の病気と健全の画像計 9,230 枚を元にデータセットを構築し、VGG-net をベースとした FC 層のない full convolutional neural networks を用いて病変領域の検出と診断を同時に行うシステムを提案した 24). 彼らは、その成果を "mean recognition accuracy" で約 98%と報告している。しかし彼らの結果例では、同じ病気に対して複数の大小の boundary box が重なって提示されていたりすることから、上記

の accuracy は recall と考えられ、誤検出数は考慮されていないように見受けられる.

Fuentes らは、上記の Faster R-CNN や SSD など の手法を用いて,一般物体検出+認識問題で普段行われ る手法を植物病自動診断に適用した.彼らは独自のト マトの葉の接写画像計5,000枚(病気, 虫体のアノテー ション付きのボックス約 43,000 個つき) を対象に, 合 計10種の病気と虫体の検出問題を設定し,様々な識別 器の条件下(検出+識別のフレームワークと、そこに組 み合わされる各種 CNN モデル) で性能を比較した 25). その結果、彼らの実験においては VGG-net を region proposal network として活用した Faster R-CNN が mean average precision で 0.836 と優れた成果を実現 している.後に彼らは、こうした学習を用いた自動診 断技術の問題点として, 誤検出と, 病気ラベルのアンバ ランスによる総合的な識別能の低下を引き起こすこと を問題にし、これらに対処する多段 CNN から構成さ れる識別モデルである reinforcement filter bank network を提案している²⁶⁾. このモデルは, 最初に前段 の Faster R-CNN などのモデル (primary diagnosis unit) で病変候補領域を検出し、確信度の高い候補領 域のみ、後段 (secondary diagnosis unit) に送り、そ の候補領域が検出されるべきか否かを判定する. この 判定には,各識別対象(病気)を識別する様学習され た CNN により獲得された CNN フィルタバンクが用 いられている. 学習段階の場合, この2段目で誤認識 した画像パッチは、対応する CNN ごとに負例として 学習に用いられる. このような枠組みを導入すること で、同じトマトの病害虫認識問題において13%の識別 率向上を果たし、約96%を実現したと報告している. これまで植物病の自動診断においては、多少の前処理 の工夫などは見られたものの識別の部分は CNN の能



図3 空撮画像によるコメの「ばか病」検出の例. 苗全体に病気の特徴が表れるため、感染している苗の検出は、病気の特徴に応じたアルゴリズムの構築である程度対応できることが期待できる. 丸囲み部分が検出すべき苗の部位. 画像: [西日本某所 研究協力者より提供].

力に実質的に頼り切っていた研究が多かった。その中で,独自の学習枠組みを作り上げて実践的な環境の中で高い識別精度を実現したことは注目に値する.

1.6 より実践的なシステムへ:広域画像を扱うシステムとその問題点

病気の特徴が表れる葉、実、茎部を、一枚ずつ写真撮影が必要な従来の自動診断システムでは、広い圃場などでの利便性に課題が残る。前述のような定点観測カメラやドローンなどからの撮影を考慮した、広域写真からの複数領域の一括診断が望ましい。こうした問題設定において、図3の空撮画像の例のように、対象植物全体に病状が顕著に表れる場合(この例の稲の「ばか病」の場合、病気にかかった株は、他の稲より葉や葉鞘が長くなる、葉が倒れ角度が大きくなる、健全株に比べて大きさや色が薄くなる特徴がある)は、従来の画像解析やルールベースの検出技術、あるいは、上記の検出と識別を一括して行う深層学習手法を導入することで、ある程度良好な検出、診断能が期待できる.

しかしながら、図4のキュウリの温室内での画像のように、上記の研究で扱っていたような葉や実に小さい病変があるような病気を対象とした場合、それらの検出がさらに大幅に困難になる。園芸作物を対象とし

た病害診断は、この問題設定になることが多いため検 討が必要であるが、利用できる教師データの入手困難 さもあり、関連する研究は極めて少ない、我々は、500 枚のキュウリ圃場の広角画像を対象に物体検出アルゴ リズムと、後段に CNN 病気の識別器を備えたシステ ムを提案し、病害葉と健全葉の検出において、一定の成 果を挙げたが (平均 precision=68.1%, recall=65.8%) 改善の余地が残された27).後に我々はさらに多くの合 計約 1.000 枚の教師ラベル付きの広域圃場を準備し、 こうした問題にどのように対処すべきか上記の Faster R-CNN 等の「統合的手法」と、検出と識別を別々に 行う「2段階手法」の比較を行った28). こうした場面 では、現時点で利用できる技術を想定する限り、過学 習の影響が顕著に表れるため、検出と識別は2段階に 分けて実施するべきという結論に達した. この課題の 困難さについては後述する.

2. 植物病自動診断における主要な問題点

2.1 人的要因に起因する問題点

(a) 正しい学習データセットの構成―ラベルつき データの収集

植物病の診断器構築のためには正しい病害ラベルの



図4 キュウリ温室内における定点観測カメラを想定した画像.基本的に似た形状を持つ葉が多数重なりあっている状態で、その上にあるわずかな病徴を基にした診断は、適切な教師データの付与、過学習の対応といった面でも容易ではない。また、教師データ作成のコストも大きい。ここで細かい病気ごとのラベルを付けるのは事実上不可能である。赤枠が病気ラベルのついた葉領域、白枠は健全ラベルの付いた葉領域。画像: [Suwa²⁸] より.

ついた画像データの収集が大量に必要である。専門家の目視によるラベル付与は、特に初期病徴の場合に信頼性に懸念が残る。前述の Plant Village データセットは、一般から収集されたデータセットであったため、教師データの信頼性に大きな問題点があった。そうした背景から、筆者らが参画しているプロジェクトでは、病気ごとに隔離された専用の環境を用意して、病気を専門家が接種し、混在しないようにする方法を採っている。これは病気のデータを取得するという意味では精度の高い方法であるが、コストが高く、場合によっては後述のように特定の病気の画像は特定の背景がセットになることによる過学習の要因にもなる。

(b) 生理障害への対応

病気ではないものの、栄養素の欠乏や過剰、あるいは老齢化など健全な状態ではない生理障害は、対策も必要なため識別できることが望ましい。しかしながら、特定の栄養分の欠乏などにより発生する生理障害は再現が難しく、教師ラベルつきデータの作成が極めて困難である。またそのため、著者らが知る限り大規模なデータに基づく自動診断の成果とした報告は見当たらない。開発が必要な技術であるが、現時点ではいずれ

かの病気ではないが、健全でもない、というカテゴリで対応するほかないのが現状である.

2.2 過学習に起因する課題

機械学習の本質的な問題である過学習への対処が, 植物病の自動診断技術実現では極めて重要である.

(a) 病変特徴が画像上小さいことによる困難性(初期病徴含む)

多くの植物病に対する自動診断では、識別したい病気により生じる画像上の特徴が小さいことが本質的にこの問題を難しくしている。図1に例示した典型例では、農業の専門家でなくても、それなりに各クラスがそれなりに異なっていることがわかるが、機械学習分野で広く利用されているImageNetデータセットに代表されるような一般物体認識のそれよりも、クラス間の画像の差が小さいことは一目瞭然である。

さらに、図2に示すような初期病徴を扱う場合、専門家でも見た目だけでは判断が難しい場合が多い。例えば256×256の画像上に数ピクセルしかない、うどんこ病の特徴をきちんと捉えて、他の光の当たり具合や背景などに惑わされずに識別器が頑健に正しく識別することは難しい。筆者らの経験では、ロバストな識

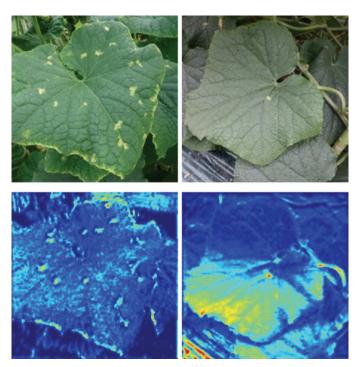


図5 キュウリ「ベと病」に対する診断根拠の GradCAM による可視化の例. 高い識別能を実現する識別システムであっても、右の例では、その診断根拠と見なせる注目領域が左下の地面の部分になってしまっている。 画像: $[Fujita^{18}]$ より.

別精度実現には、一般物体認識で必要な画像数よりも、多くの学習画像が必要になる。実践的な画像データは 圃場などで撮影された写真であり、それらの集合でデータセットが構成される。しかしながら、同じ圃場、あるいは試験環境など類似する背景などに過学習することが、これまであまり指摘されてこなかったが深刻な問題となる。

特に、信頼性の高いデータセットを構築するために、病気を接種する特別な環境を作る場合、「A 病害の背景には xxx が写っている」「B 病害の写真の撮影時は、天気がよかったので全体的に明るい(暗い)」というようなことが起こる。一般的に CNN のような深層識別器は、特にかすかな病気の特徴より、大きな面積を持つ背景や、画像の特性(明るさ、色味)などの特徴を捉える傾向があるため、過学習の原因となる。図 5 に、計 12 クラスのキュウリの病気に対して、平均約 94% と高い識別能を実現したシステム 29 の識別根拠を可視化するために、「べと病」の根拠と見なせる領域を $GradCAM^{30}$ により heatmap 表示を行った例を示す。識別器は、高い識別能を達成しているにもかかわらず、一部の画像においてその識別の根拠とみなせる領域が背景部分に

表れている.こうした現象は、この例のような局所的 な病変が出る菌類の病気でも見られるが、特にうっす らと広域に病徴が表れるウイルス病の場合に、よりそ の傾向が見られた.これは、構築者が望むような識別 器が必ずしも構築できていないことを示す.

一般的にあるデータセットを cross-validation など を含む、学習用データ (training data)、検証用デー タ (validation data), 評価データ (test data) に分 割して評価する場合,画像データセット内に含まれる 「隠れた類似性」が影響し、見た目の診断精度が大幅に 向上する. しかしながら、未知の他の圃場に対する精 度、つまりそのシステムの本質的な精度は極めて低く なる^{27, 28, 31)}. 特に学習画像の大量の確保のため、連射 撮影などを行うと、極めて類似した画像が、学習と評 価に分かれ、同様に見た目の精度のみ向上する. この ことは、Mohanty らの研究¹⁴⁾において、背景がない、 あるいは単一の背景の同一データセット内の画像に対 しては、99%以上の精度が実現したが、他のデータにつ いては31%程度の精度に低下することや、Fuentesら の、実環境と研究室環境の混在したデータで学習した モデルは同様に、99%程度の識別能を実現していたが、

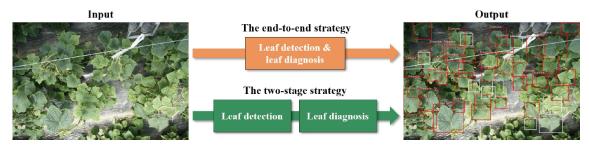


図6 広域画像を対象とした自動診断システムにおける戦略の違い.植物病害自動診断において広域画像を対象とする場合,様々な理由から注目領域の検出と,検出後の診断を分けて行う2段階システムの方が望ましい.画像:[Suwa²⁸]より.

背景などが均一のデータセットのみの学習したモデルでは 33%程度まで低下²⁶)した報告でも確認できる.

こうしたことから,様々な従来研究では極めて良好な数値結果が報告されているが,これらは大きなバイアスがかかっている可能性が極めて高く,本質的な識別性能を検証するためには,このデータセット内の潜在的な類似性を排除するため,同じデータセットを分割するのではなく,別の場所,時間で撮影された圃場の画像を用いて評価する必要がある.

(b) クラスごとのデータセットの数の違いによる 影響

機械学習問題において、クラスごとの教師データの偏りへの対策は一つの重要な問題である。この差を解消すべく、古くは over sampling などの手法が取られたが、近年得られているクラスごとのデータ数の割合に応じて学習係数を決定するような優れた機械学習的なアプローチ³²⁾が提案され成果を挙げている。しかし筆者がそれらを実装して実験した限りでは、植物病自動診断問題において、残念ながら抜本的な解決にはなりえておらず、さらなる対策が求められる。

(c) 特に広域画像を対象とする場合に発生する困難性

広域写真からの複数領域の一括診断が望ましいが、 しかし実現には2つの大きな問題点がある。一つは診 断に関する識別器の能力の問題、もう一つは妥当な教 師データをどのように与えるかの問題である。

一般物体認識技術では、Faster R-CNN や SSD などの検出と識別を一括して実行できるシステムが優れた精度を実現しているが、fine-grained classificationタスクの中でも難しい問題である本課題において、これらの技術を単に適用するだけでは、過学習により頑健性の高いシステムの構築が難しい。筆者らは、およそ25,000枚のキュウリの葉(約17,000枚の健全葉と

約8.000 枚の病害葉) が写っている約1000 枚のキュ ウリ圃場の広域画像を元に自動診断システムを構築し, cross-validation ならびに、全く異なる圃場から撮影 された広域写真に対する識別能を比較した29). その結 果,同じ学習データと評価データが同じ圃場内で撮影 された(ただし、学習画像に含まれない)広域写真の場 合, Faster R-CNN や SSD は極めて高い葉領域の領 域検出 (F1-score=91.5%) および、病害葉の診断精度 (F1-score=84.1%) を示した. しかしながら, 新しい圃 場の広域画像に対してはこのスコアは壊滅的に低下す る (F1-score=4.4~6.2%程度). これは明らかに前述 した過学習が原因である. そうした背景から筆者らは、 Fuentes ら²⁶⁾と同様に「注目領域候補の検出」と、その 「各候補領域の診断」を別々に行う図6下段のような、 2段階システムの利用を提唱している. 候補領域の検 出にはSSD などの手法を用い、診断部は、従来研究に あるような1枚の対象画像が何に感染しているかを判 定する CNN 識別器から構成される. 我々は比較実験 を通じて, 広域画像に対する自動診断問題において, 数 値上必ずしも魅力的な数値ではないが病気の早期防除 に役に立つレベルである病害葉の検出精度を達成でき ることを確認した (precision=79.9%, recall=25.7%, F1-score=38.9%).

信頼できる教師ラベルの付与は、前述の通りコストの高い作業であるが、広域画像に対する場合、さらに困難となる。図4のような1枚の広域画像の中に数十枚以上の様々な大きさの葉や実が重なり合って映り込んでいる中から、病変、あるいは病変を含む葉などの領域のアノテーションのコストは大変大きいだけでなく、解像度の問題から専門家であっても困難なケースが多く現実的ではない。検出と識別の過程は分けることができれば、後段の識別器の学習には従来研究で多く用いられる1画像1対象の教師データが活用でき、

こうした問題も回避できる.

3. 効果的な対策の紹介

3.1 解析対象 (葉,実) などの事前抽出,前処理 病変の画像上の特徴が小さい故に,汎化性の高いシ ステムを構築するためには,機械学習技術で一般的に 行われている各種 data augmentation や dropout な どの正則化などの過学習抑制手法の導入のほか,問題 に特化した前処理が必要となる.

注目領域外の背景などの特徴を学習することによって、みせかけの識別能だけが高くなる現象を抑えるべく、筆者らは葉や実といった注目領域のみを事前に抽出することで、こうした過学習を抑制することを試みた³¹¹). 葉領域の抽出に敵対的生成モデルの考え方を領域分割に適用した pix2pix³³³)を用いることにより,良好な葉の抽出結果を「生成」し、また学習法を工夫することにより明るさなどの補正も同時に実現した(図 7). これにより未知圃場の画像に対する,見かけではない"実際の"識別精度を大幅に向上させることを実現した. このような前処理は,植物病の自動診断においては必須となると考えている.

単純な画像の明るさや色味の他,日照条件によりまだらに明るい部分と暗い部分が表れるケースも実圃場画像では多く見受けられる。こうした画像に対してはCycleGAN³⁴⁾などの敵対的ネットワークを元にした処理を活用することで,ある程度補償できることを確認している。またこうした画像生成ネットワークは,学習データの確率分布を学習するため,うまく工夫することで限られた学習データから新しい病害データを"生成"できる可能性が期待できる。

また、こうした病気特徴の小ささから起こる過学習は、未知のテスト画像の評価時に、外乱が加わった際(つまり明るさや、距離など画像の状態が少し変わった場合)、識別結果の変動となって表れる。頑健な識別器構築のためには、病気の本質をとらえるような識別器の構築が必要である。同じクラスラベルを持つ入力が、似た低次元表現を持つように制約を加える metric learning³⁵⁾や、外乱に対して同じ出力が得られるような制約を加える stability training³⁶⁾の導入は、こうした外乱に対する耐性が期待できる。

3.2 超解像技術を用いた識別精度改善

広域画像を用いた病害識別においては、解像度の低下が識別率低下の大きな問題となる。筆者らは、近年盛んになっている深層学習をベースにして優れた超解像画像を生成する ESRGAN (Enhanced super-resolution generative adversarial networks)³⁷⁾を改良しつつ独



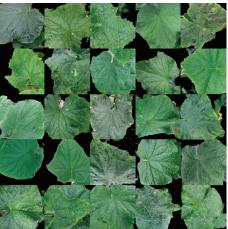




図7 (上段) 入力画像, (中段) 検出(生成) された明るさ, 色補正済み葉領域, (下段) 抽出すべき葉領域(教師画像:参考). 色補正を含め適切な葉領域の抽出が実現できている. こうした処理により, 未知の圃場画像に対する識別精度は12%向上した. 画像: [Saikawa³¹] より.



(a) Original high resolution image (not given).



(b) Reduced resolution into 1/16 and interpolated with bi-cubic interpolation.



(c) Generated super-resolved images by [Cap³⁸⁾].

図8 開発した植物病自動診断用 超解像手法による結果例.元の高解像画像 (a) を $1/4 \times 1/4$ 倍に縮小し bi-cubic 補間したもの (b), 超解像処理後 (c) を行い比較したテスト画像例.見た目では生成された超解像画像は、元画像と遜色なく、これらを用いた自動診断では bi-cubic 法による補間に比べて 26%も精度が向上し 92%以上に達し、元画像のそれとの差は 3%程度まで減少した。画像: $[Cap^{38}]$ より.

自の制約を加えることにより、背景の不適切な色変化を抑えつつ、縦横 4 倍に拡大しても視覚的な劣化が認識できないレベルに高周波成分を再現(生成)できる超解像手法を開発した³⁸⁾. 図 8 に参考画像例を示す.これにより、Bi-cubic 法で拡大処理をした場合に比べてキュウリの病害葉の識別問題において約 27%精度を向上させ、元の解像度による識別率(95.5%)に迫る平均識別率 92.4%を達成した.上記のような注目領域の検出や、病変の失われた特徴の再現を試みるこうした手法は、どの作物、どの部位の識別においても適用できる効果的な処理と期待している.

4. データ取得から解析までの研究を進めていく上で の注意点と戦略

これまで本プロジェクトを進めてきて,各府県の試験場の皆様との議論の中で,得られた植物病の自動診断技術を開発していく上での注意事項について紹介する.

4.1 解析対象部位の決定と、教師ラベルの一貫性 の確保

診断が必要となる植物病害は,作物,病気ごとに,診 断の手がかりとなる症状が主に発生する部位が異なる. そのため作物ごとに、診断対象となる病気の特徴が大 きく表れ, 撮影すべき部位をあらかじめ専門家同士の 話し合いにより決定し、それぞれについて正しい病気 ラベルつきデータを十分に確保することが必要となる. 現時点で提案されている画像診断を行うシステムの多 くは、病害の特徴がより表れやすい葉の表や実を対象 にしている (ただし、虫害の場合、虫は葉の裏に集ま ることが多いので葉裏が重要な解析対象となる). カメ ラと対象までの距離によるが、葉や実は、茎や花など の他の部位と比べて面積が大きいため, 画像解析の技 術的な面からも扱いやすい領域である. 一方で花柄や 花茎, いちごのランナーなど, 画像解析上は茎に類す る部位を診断対象にした研究は現時点では限られてい る. 葉を解析対象とする場合、キュウリやナスのよう に、1枚の葉が独立する単葉と、トマトやいちごのよ うに、複数の葉(子葉)でひとまとまりになる複葉の 植物がある. 精度の高い自動診断システムを構築する 場合、利用者に撮影してもらう部位をどこにするのか、 作物ごとに事前のコンセンサスが必要になると考えら れる.

また、専門家は診断の際に、一か所のみを見ているのではなく、複数個所を見て総合的に判断を行う. 現時点で提案されている自動診断技術は、いずれも葉や実、茎などの特定の部位およびその周辺を見て判断を行っているが、病気によっては、全体の様子を解析す

ることが必要な病気(青枯れ病、半身萎凋病など)も存在する.このため、こうした全体像、あるいは複数個所を考慮した診断技術の開発も必要であろう.ただし株の全体像を教師データとして必要とするような場合、現実的な圃場の制約から類似する画像にならないよう注意が必要であり、多様性のある学習データ数の確保は簡単ではない.

4.2 写真撮影時における注意事項とデータ管理

学習データ数を確保するために、安易に連射による 撮影を行うと極めて類似した画像が大量に生成される。 そのため、それらを元に構築されたシステムの評価時 に、単純にデータセットを比率で割る、あるいは crossvalidation 評価を行うと、前述のように大きな bias に なる。そのため、こうした連射データは学習と評価の データに分離されないよう注意が必要である。やむを 得ず同じターゲットを連続して撮影する場合は、2次 元回転、shift は後処理で可能なため、3次元的に角度 を変えて撮影すべきである。

また、複数の機関の専門家でデータセットを構築する際、病勢(初期、中期、末期など)の判断のレベルが評価者によりばらつく、またどのような状態の写真を撮影するか、個人により極めて大きな差が生まれる。このため、事前により専門家の間で、どの程度までの症例を扱うのか、また写真の撮り方に共通の同意が必要となる。

4.3 ターゲットとする病気の選定と出口戦略

対応すべき優先度の高い植物病害の種類は、地域、時期、扱う作物の品種などによって異なる。信頼できる病害情報ラベル付き画像データの確保は、コスト(人的、時間的、金銭的)の高い作業であるため、作物×発生部位×病害のすべての可能性について識別器を構築するのは非現実的である。また、データ取得のために、隔離された環境下で病気の接種を行っても、必ずしも天候などの影響で希望する病害データを撮影できるとも限らない。こうしたため、どの作物のどの部位に発生する、どの病気を扱うかの選定は重要な課題である。

そのため、実践的なシステムを構築するには、各病気の識別よりも、感染が発覚した場合に、どのような手立てをとるべきなのか、の出口戦略ごとに病気をまとめるというのも現実的な選択となる。例えば、植物病のウイルス病は治す手段がないため、現実的には発見次第圃場から取り除くしかない。ウイルス病各種の識別は、できるに越したことはないが、農業経済的な観点からは優先度が下がる。

5. ま と め

本稿では,画像解析に基づく植物の自動診断に関す る関連研究とその困難性,解決に向けた方策と,注意事 項について紹介した. 本課題は, 分類すべき識別対象 の特徴がどのクラス (病気) にも極めて類似している fine grained と呼ばれる問題の中でも、特に難しい部 類のタスクである. そのため技術的な視点からは, 背 景などが及ぼす識別器の過学習を抑えることが特に重 要であり、また適切なシステムの評価には、識別器を 構築したのとは別の現場で撮影された画像セットを用 いて行うことの必要性を紹介した. また広域画像の診 断においては、教師ラベル付与の困難さの観点からも、 検出と識別は2段階で行うことが望ましいことを紹介 した. 実用的なシステムの構築には、深層学習器の学 習能力に頼るだけではなく解析対象に応じた適切な前 処理などが必要になると考えられる. 機械学習技術の 進歩により多くの研究成果が報告されているが、こう した技術が農業分野においても一日も早く実践的に活 用されるよう尽力していきたい.

謝辞

これまで植物の専門的な立場で研究の初期から多大なるご尽力,ならびに多数のご助言をいただいた埼玉県農業技術研究センターの宇賀博之博士,本学生命科学部の鍵和田聡先生,また,本受託プロジェクトを推進する上で,プロジェクト全体を統括してくださっている農研機構の後藤千絵領域長,実践的なやり取りで日々大変お世話になっている岩崎亘典博士をはじめ,多くの関係者の皆様に改めてお礼を申し上げます.

参考文献

- Sastry, K.S., Zitter, T.A. (2014): Plant virus and viroid diseases in the tropics, Volume 2, Epidemiology and Management, Springer Netherland.
- Savary, S., Willocquet, L., Pethybridge, S.J., Esker, P., McRoberts, N., Nelson, A. (2019): The global burden of pathogens and pests on major food crops, Nature Ecology and Evolution, Vol.3, pp.430–439.
- 3) 農林水産省:農業従事者,新規就農者の動向 http://www.maff.go.jp/j/wpaper/w_maff/h18 _h/trend/1/t1_2_1_02.html
- 4) Yao, Q., Guan, Z., Zhou, Y., Tang, J., Hu, Y., Yang, B. (2009): Application of support vector machine for detecting rice diseases using shape and color texture features, Proc.

- Engineering and Computation, pp.79–83.
- Bashish, D. A., Braik, M., Bani-Ahmad, S. (2010): A framework for detection and classification of plant leaf and stem diseases, Proc. International Conference on Signal and Image Processing, pp.113–118.
- Pujari, J. D., Yakkundimath, R., Byadgi, A. S. (2014): Recognition and classification of produce affected by identically, looking powdery mildew disease, Acta Technologica Agriculturae, Vol.17, No.2, pp.29–34.
- Mwebaze, E., Owomugisha, O. G. (2016): Machine learning for plant disease incidence and severity measurements from leaf images, IEEE Proc. ICMLA, pp.158–163.
- Hallau, L., Neumannbc, M., Klattc, B., Kleinhenzd, B., Kleind, T., Kuhnd, C., Roehrige, M., Bauckhageb, C., Kerstingf, K., Mahleina, A. K., Steinera, U., Oerke, E. C. (2018): Automated identification of sugar beet diseases using smart phones, Plant Pathology, Vol.67, pp.399–410.
- Simonyan, K., Zisserman, A. (2014): Very deep convolutional networks for large-scale image recognition, CoRR, abs/1409.1556.
- He, K., Zhang, X., Ren, S., Sun, J. (2016): Deep residual learning for image recognition, IEEE Proc. CVPR, pp.770-778.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. (2016): Rethinking the inception architecture for computer vision, IEEE Proc. CVPR, pp.2818–2826.
- 12) Kawasaki, Y., Uga, H., Kagiwada, S., Iyatomi, H. (2015): Basic study of automated diagnosis of viral plant diseases using convolutional neural networks, Lecture Notes in Computer Science, Vol.9475, pp.638–645.
- Hughes, D.P., Salathe, M. (2015): An open access repository of images on plant health to enable the development of mobile disease diagnostics, CoRR, abs/1511.08060.
- 14) Mohanty, S.P., Hughes, D.P., Salathe, M. (2016): Using deep learning for image-based plant disease detection, Frontiers in Plant Science, Vol.7, No.1419, pp.1–7.
- 15) Wang, G., Sun, Y., Wang, Y. (2017): Automatic image-based plant disease severity estimation using deep learning, Computational Intelligence and Neuroscience, No.2917536.
- 16) Durmuş, H., Güneş, E.O., Kırcı, M. (2017): Disease detection on the leaves of the tomato plants by using deep learning, IEEE Proc. Agro-Geoinformatics, No.8047016.
- Atabay, H.A. (2017): Deep residual learning for tomato plant leaf disease identification,

- Journal of Theoretical & Applied Information Technology, Vol.95, No.24, pp.6800–6808.
- Fujita, E., Uga, H., Kagiwada, S., Iyatomi, H. (2016): Basic investigation on a robust and practical plant diagnostic system, IEEE Proc. ICMLA, pp.989–992.
- 19) Brahimi, M., Arsenovic, M., Laraba, S., Sladojevic, S., Boukhalfa, K., Moussaoui, A. (2018): Deep learning for plant diseases: detection and saliency map visualisation. In: Zhou, J., Chen, F. (eds.), Human and Machine Learning, Human-Computer Interaction Series, Springer, Cham.
- Singh, A.K., Ganapathysubramanian, B., Sarkar, S., Singh, A. (2018): Deep learning for plant stress phenotyping: Trends and future perspectives, Trends in Plant Science, Vol.23, No.10, pp. 883–898.
- Ferentinos, K.P. (2018): Deep learning models for plant disease detection and diagnosis, Computers and Electronics in Agriculture, Vol.145, pp.311–318.
- 22) Ren, S., He, K., Kaiming, G., Girshick, R., Sun, J. (2015): Faster R-CNN: Towards realtime object detection with region proposal networks, Advances in Neural Information Processing Systems, pp.91–99.
- 23) Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., Berg, A.C. (2016): SSD: Single shot multibox detector, Proc. European Conf. on Computer Vision (ECCV), pp.21–37.
- 24) Lu, J., Hu, J., Zhao, G., Mei, F., Zhang, C. (2017): A field automatic wheat disease diagnosis system, Computers and Electronics in Agriculture, pp.369–379.
- 25) Fuentes, A.F., Yoon, S., Kim, S.C., Park, D.S. (2017): A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition, Sensors, Vol.17, No.9, E2022.
- 26) Fuentes, A.F., Yoon, S., Lee, D., Park D.S. (2018): High-performance deep neural network-based tomato plant disease and pests diagnosis system with refinement filter bank, Frontiers in Plant Science, Vol.9, No.1162, pp.1–15.
- 27) Cap, Q.H., Suwa, K., Fujita, E., Kagiwada, S., Uga, H., Iyatomi, H. (2018): 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.
- 28) Suwa, K., Cap, Q.H., Kotani, R., Uga, H., Kagiwada, S., Iyatomi, H. (2019), A comparable study: Intrinsic difficulties of plant diagnosis from wide-angle images, IEEE Proc. Big Data 2019 workshop (CoRR, abs/1910.11506).
- 29) Fujita, E., Uga, H., Kagiwada, S., Iyatomi, H. (2018): Practical plant diagnosis system for field leaf images and feature visualization, International Journal of Engineering & Technology, Vol.7, No.4.11, pp.49–54.
- 30) Selvaraj, R.R., Cogswell, R., Das, A., Vedantam, R., Parikh, D., Batra, D. (2017): Grad-CAM: visual explanations from deep networks via gradient-based localization, Proc. ICCV, pp.818–826.
- 31) Saikawa, T., Kagiwada, S., Uga, H., Iyatomi, H. (2019): AOP: Anti-overfitting pretreatment method for practical image-based plant diagnosis, IEEE Proc. Big Data 2019 workshop (CoRR, abs/1911.10727).
- 32) Cui, Y., Jia, M., Lin, T-Y., Song, Y., Belongie, S. (2019): Class-balanced loss based on effective number of samples, IEEE Proc. CVPR 2019, pp.9268–9277.
- 33) Isola, P., Zhu, J.Y., Zhou, T., Efros, A.A. (2017): Image-to-image translation with conditional adversarial networks, IEEE Proc. CVPR, pp.1125–1134.
- 34) Zhu, J-Y., Park, T., Isola, P., Efros, A.A. (2017): Unpaired image-to-image translation using cyclic-consistent adversarial networks, IEEE Proc. CVPR, pp.2223–2232.
- Hoffer, E., Ailon, N. (2016): Semi-supervised deep learning by metric embedding, CoRR, abs/1611.01449.
- 36) Zheng, S., Song, Y., Leung, T., Goodfellow, I. (2016): Improving the robustness of deep neural networks via stability training, IEEE Proc. CVPR 2016, pp.4480-4488.
- 37) Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y., Loy, C.C. (2018): ESRGAN: Enhanced super-resolution generative adversarial networks, IEEE Proc. ECCV workshop (CoRR, abs/1809.00219).
- 38) Cap, H.Q., Tani, H., Uga, H., Kagiwada, S., Iyatomi, H. (2019): Super-resolution for practical automated plant disease diagnosis system, Proc. Information Sciences and Systems (CISS2019).