

植物病害自動診断システムの為の広範囲にわたる葉領域抽出の試み

諏訪 勝元[†] 藤田 恵梨香[†] 川崎 雄介[†] 宇賀 博之[‡] 鍵和田 聡[†] 彌富 仁[‡]法政大学[†] 埼玉農業技術研究センター[‡]

概要

近年、深層学習を用いた植物病害自動診断システムが提案されている。しかしこのような診断機構は、葉などの局所画像を入力として解析するため、広範囲の圃場における利用に課題が残されていた。そこで本研究では、定点カメラで撮影された圃場の画像を想定し、広い範囲の葉が写った画像から、既存の診断システムへの入力画像領域を抽出する手法を検討し、結果を報告する。

1 背景

全国で植物病害による被害が多く確認されており、我が国のウイルス性植物病害のみにおいても、年間被害総試算額は1,000億円を超えるとされている。植物病害の被害を最小限に抑えるためには、治療が可能であれば農薬の散布、不可能であれば対象の除去といった早急な対応が求められる。しかしながら、現在の植物病害の初期診断は農家・専門家の目視や、遺伝子検査により行われているため、人的・金銭的成本を要しているのが現状である。このような問題を解決する為に様々な植物病害の自動診断システムが提案されてきた[1, 2]。我々は、画像から直接識別に関する特徴量を学習できるConvolutional Neural Network(以下CNN)を用いた植物病害自動診断システムを提案し、きゅうりを対象に健全葉と典型的な7種のウイルス病に感染した葉の診断に対して平均正解率83.2%を達成した[2]。しかし、診断は葉が一枚写った画像を基に行うため、実際の圃場で広範囲の診断を行うには時間や手間を要する。

そこで、本研究では複数の葉が写った画像から先行研究のシステムで使用可能な葉領域(識別可能葉)を抽出する手法を提案する。本研究では、任意の大きさの物体を画像中から検出する手法の一つである selective




図1 システムの全体像

search(以下SS)[3]と、機械学習手法の一つである support vector machine (以下SVM)を組み合わせることで、識別可能葉を検出する手法を提案し、妥当性を検証する。

2 方法

提案するシステムは図1に示す通り、複数の葉が写った入力画像から葉の候補領域群を検出する「葉候補領域抽出部」と、前段で得られた候補領域群が、それぞれ診断に使用できるか否かを分類する「葉領域識別部」から構成される。各項目の詳細については後述する。

2.1 データセット作成および前処理

本研究では埼玉県農業技術研究センターにて一般的なデジタルカメラで撮影されたきゅうりの葉の画像を使用した。画像は、複数の葉が写った画像と、一枚の葉が中央に写った画像の2種類を使用した。葉候補領域抽出部の評価用データセット(以下データセット1)は複数の葉が写った画像群から構成される。また、葉領域識別部の学習用データセットは図2左のような先行研究の診断に使用できる画像(以下正例)とそれ以外の画像(以下負例)各8,000枚の計16,000枚から構成される(データセット2)。なお、データセット2の正例は、先行研究にも使用されていたウイルス感染葉7種と健全葉の計8種類の葉一枚が撮影された画像を224×224pixelsに縮小して作成した。同様に負例は、データセット1には使用していない複数の葉が映った画像100枚からランダムに10パッチずつを取得後、各パッチ位置においてスケールの異なる画像を4枚取得し、左右反転画像を加え、224×224pixelsにリサイズして作成した。

A Study of Leaves Region Detection from Field Images for Automated Plant Diagnosis System

[†] Katsumasa Suwa, Erika Fujita, Yusuke Kawasaki, Satoshi Kagiwada, Hitoshi Iyatomi (Hosei University)

[‡] Hiroyuki Uga (Saitama Agricultural Technology Research Center)



図2 診断可能葉識別部 SVM が学習する画像例

2.2 葉候補領域抽出部

葉の候補領域を抽出するために SS を適用し、得られた候補領域を葉の診断候補領域として抽出する。SS はピクセル単位で画像内の類似する領域をグループ化させる処理を繰り返すことで、画像中にある「何らかの物体」の候補領域を抽出する手法である。

2.3 葉領域識別部

葉領域識別部では、検出された候補領域が葉か非葉かを SVM を用いて識別する。SVM の学習に使用した特徴量は、データセット 2 を、ImageNet データセットで学習済みの 19 層の CNN モデル (VGG-19)[4] に入力し、一つ目の全結合層で得られる 4,096 次元の特徴ベクトルである。VGG-19 は 2014 年度の一般物体画像認識コンテスト (ILSVRC2014) で優勝したモデルであり、様々なタスクに使用可能な特徴量を学習しているという報告から使用した。

2.4 評価方法


システム全体の評価のために、複数の葉が写った画像に対して、intersection-over-union(以下 IoU) と呼ばれる評価指標を計算することで、各葉候補領域の教師データを生成した。IoU は、画像中の物体の領域画像を X_a として、候補領域画像を X_b とした際、 $IoU = X_a \cap X_b / X_a \cup X_b$ であり、本研究では $IoU \geq 0.7$ の領域を検出すべき葉領域として、最終的な葉領域の検出性能の評価を行った。

3 結果

複数の葉が写った画像に、手動で付与した抽出すべき葉領域と SS により得られた候補領域の結果例を図 3 に示す。葉領域識別部の SVM 単体での分類性能を評価するため、データセット 1 を用いて学習した SVM の識別精度を表 1 に示す。全体のシステムの評価結果の一例を表 2 に示す。

表1 SVM による評価結果

感度 (診断可能葉)[%]	特異度 (診断不可能葉)[%]	正解率 [%]
99.9	99.9	99.9



白枠：検出すべき葉領域(gold standard)
黒枠：葉候補領域

図3 診断候補領域抽出例

表2 システム全体の評価結果

precision(精度) [%]	recall(再現度)[%]
33.3	57.1

4 考察と結論

本研究は、圃場における広範囲の定点観測画像などから、自動診断を行うことを想定しているため、再現度はそれほど高い値を必要としない。SS を用いた葉候補領域検出は、検出すべき葉領域をおおまかに検出できることが確認できた。葉候補領域の SVM は、検出すべき葉領域とそれ以外をほぼ正確に識別することを実現したが、実際に複数の葉が撮影された広範囲の画像から抽出された領域の評価においては、満足いく結果が得られなかった。SVM が学習した画像群と、実際の評価に用いた葉候補領域の画像群は、人間の見た目には類似性が高いものの、CNN モデルである VGG-19 が作り出す特徴ベクトルの間では大きな差があったためと考えられる。CNN は人間による見た目がほぼ同じでも全く異なる出力を得ることが知られており、今後より良好な特徴表現を検討する。

参考文献

- [1] S.Phadikar, et al., "Rice Disease Identification using Pattern Recognition Techniques," IEEE proc. on ICCIT, pp.420-423, 2008.
- [2] E.Fujita, et al., "Basic investigation on a robust and practical plant diagnostic system," IEEE proc. on ICMLA, pp.989-992, 2016.
- [3] J.Uijlings, et al., "Selective search for object recognition, in IJCV," pp.154-171, 2013.
- [4] K. Simonyan, et al., "Very Deep Convolutional Networks for Large-Scale Image Recognition," in CoRR, abs/1409.1556, 2014.