

植物病害自動診断に向けた葉領域検出および 病変認識手法の提案

川崎, 雄介 / Kawasaki, Yusuke

(出版者 / Publisher)

法政大学大学院理工学・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 / 法政大学大学院紀要. 理工学・工学研究科編

(巻 / Volume)

58

(開始ページ / Start Page)

1

(終了ページ / End Page)

4

(発行年 / Year)

2017-03-31

(URL)

<https://doi.org/10.15002/00014212>

植物病害自動診断に向けた 葉領域検出および病変認識手法の提案

LEAVES DETECTION AND RECOGNITION METHOD FOR AUTOMATED PLANT DISEASE DIAGNOSIS

川崎雄介

Yusuke KAWASAKI

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

Accurate plant disease diagnosis requires experts' knowledge but is usually expensive and time-consuming. So, an easy and accurate method is highly demanded in Japanese agricultural fields. In this study, we propose some ideas of the integrated system for detecting leaf and diagnosing its disease type. Our system achieved 84.0 % accuracy at the classification part under the 4-fold cross validation strategy.

Key Words : plant disease, integral channel features, convolutional neural networks

1. 研究背景

農作物の品質管理は、農業産出額 950 兆円を誇る我が国にとって、経済活動を支えるための重要な課題の一つである。農作物を市場に安定して供給するためには、農業従事者による圃場の適切な管理が必要であり、その管理領域は圃場環境の確認、気候や湿度などに基づいた水や農薬の適切な使用、農具の衛生管理など多岐にわたる。その管理領域の中でも、作物の商品価値低下の直接的な原因となる、植物病害の早期発見は特に重要である。とりわけ植物ウイルス病害については、同じ圃場にある他の作物への蔓延による 2 次被害を引き起こしてしまう他、感染株への治療が行えないことから、現場において非常に憂慮されているものである。大島によると、そうしたウイルス病害による被害額は年間 1,000 億円を超えるとも推定されている[1]。

こういった背景から、農業生産の現場において、植物病害を早期発見する方法が模索されてきたが、現状その方法は確立されているとは言い難い。最も一般的な方法は、農業従事者や植物病理に関する専門知識を持った人間による目視診断である。これは、診断者が感染の疑いのある植物の株をひとつずつ目視により観察し、植物の葉や茎の様子を勘案して病気の種類を決定する手法である。しかしながらこの方法は、圃場全体を診断者がひとつずつ判断しなければならないため、非常に手間を要する。また、目視診断には、初期段階で葉の異変を察知するための高度な知識が要求される為、専門知識の無い一般の人間が判断することは極めて困難である。

そこで本研究では、農業従事者の負担を減らし、植物病

害の早期発見を促すような植物病害自動診断システムを提案する。本システムは大きくわけて「葉検出部」「葉認識部」の 2 つのパートに分かれており、検出部では農場の写真から葉の領域の抽出を、葉認識部ではその病変の種類を診断するという枠組みとなっている。以下に、本システムのパイプラインを図 1 として示す。

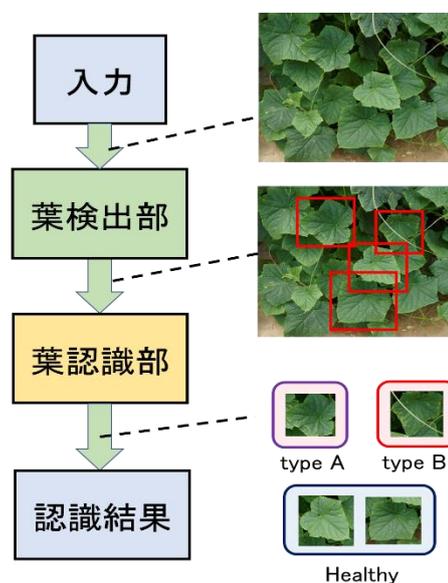


図 1 提案システムのパイプライン

2. 関連研究

(1) 物体検出の先行研究

現在の所、日本の農場のような葉が重畳した状態の画像から葉領域の検出を行った報告は行われていないが、

人間の顔や全身を検出するというタスクにおいては多くの報告がなされている。Viola らの提唱した顔検出システムは、人の顔に共通して存在する明暗差を矩形領域の差分によって表現し、高速な顔検出システムを実現した[2]。Dalal らが提案した HoG 特徴量は、物体の大まかな形を検出でき、更に物体の隠れ等に対して頑健であるため、歩行者検出等に広く応用された[3]。本研究では、こうした顔検出や歩行者検出において用いられてきた知識や評価方法を応用し、葉領域の検出を目指す。

(2) 植物病害自動診断の先行研究

植物病害自動診断における旧来の手法は、濃度共起行列を特徴量として用い、ニューラルネットワークや support vector machine (以下 SVM)を用いて病変の有無を識別するものが多く報告されてきた[4]。

一方で、近年は一般物体認識と呼ばれる、計算機に物体の一般的名称を認識させるタスクにおいて、convolutional neural network (以下 CNN)と呼ばれる枠組みが数多く使用されている[5]。これは、識別に有効な特徴量を学習過程で自動的に獲得する枠組みであり、学習させるデータの種類によって、様々なタスクに対して応用可能性があることが報告されている。本研究では、今後の応用可能性等を考慮し、CNN を用いて識別性能を評価した。

3. 葉検出部

(1) Integral channel features

integral channel features (以下 ICF) は、画像に対し線形・非線形のような変換を施し、変換後の画像チャンネル内部のある矩形領域の総和によって計算される特徴量である[6]。この特徴量は、Viola らの顔検出タスクで用いられていた、グレースケール画像内の顔または非顔画像の矩形領域の差分を特徴量とする Haar-like 特徴量のシンプルな拡張として位置付けられる。ICF は、解決するタスクに応じた自由なチャンネル設計が可能である点が特長であり、顔認識にも活用されている[7]。

画像を I 、変換後のチャンネルを C 、任意のシフト不変性を持つ変換関数を Ω とすると、 C は以下式(1)で定式化することができる。

$$C = \Omega(I) \quad (1)$$

以下に変換例を図2として示す。

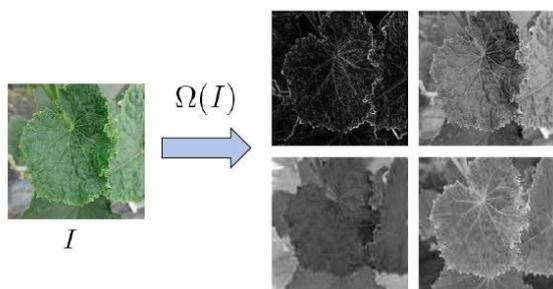


図2 チャンネルの変換例

変換後のチャンネル C からの特徴量 (=矩形領域内の総和)の計算は、積分画像を用いて高速に実施される。積分画像は、ある矩形領域内の輝度値の総和を高速に計算するために作成される概念的な画像であり、数回の加減算で指定した矩形領域の総和が計算できる。

(2) AdaBoost

AdaBoost は、入力する特徴それぞれに重みを付与し、学習過程で適応的にサンプルの重みを変動させるような集団学習法である。AdaBoost を構成する弱識別器には一般的には決定木もしくは決定木が用いられる。AdaBoost は学習過程で、識別空間を最もよく分離するような弱識別器およびその特徴量が選択されるため、greedy な特徴選択機構としても解釈できる。

(3) Attentional cascade

Viola らが提唱した attentional cascade [2] は、AdaBoost 識別器を幾段にも重ねた構成された検出器である。この attentional cascade の特長は、AdaBoost 識別器で用いられる弱識別器の個数を後段ほど増やすことによって、前半部では明らかに物体でない箇所を少数の識別器で高速に除去し、後半部では識別が困難な箇所を多数の弱識別器を用いて判定できる点である。attentional cascade は、ICF 特徴を得る際のチャンネルの選び方によって、農場を撮影した写真内に存在する、重畳のある葉に対しても応用できる可能性がある。そこで本研究ではこの attentional cascade を検出器として据える。以下に、検出部のパイプラインを図3として示す。

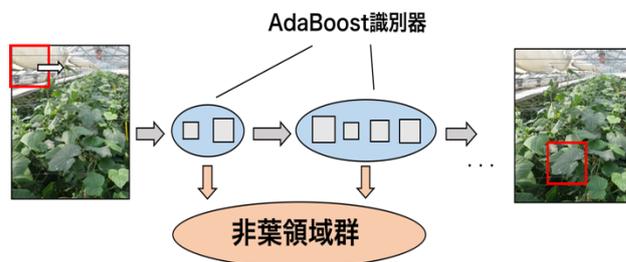


図3 検出機構のパイプライン

4. 葉認識部

(1) CNN の概要

CNN は、「畳み込み層(convolution layer)」および「プーリング層(pooling layer)」と呼ばれる構造が複数段にわたり連結されたニューラルネットワークであり、これらの層で基本的な画像処理技術を複数回繰り返すことで、識別に有効な特徴量を学習過程で自動的に抽出することができる。具体的には、畳み込み層では入力画像と多種多様な重み付きフィルタとの畳み込み積分が行われ、入力画像の局所的な特徴が抽出される。この出力を特徴マップと呼び、一般にまた、プーリング層においては畳み込み層で獲得した出力のマップのうち、ある矩形領域内の局所的な特徴を集約することで、得た特徴量にシフト不変性が与えられる。CNN の学習は、畳み込み層で用いられた

フィルタの重みを変数に持つ目的関数を、確率的勾配降下法を用いて最適化することによって行われる。

(2) CNN の構造

本研究の葉認識部に据えた CNN は、畳み込み及びプーリングを 4 回繰り返すことによって学習および識別を行う[8]。以下に CNN のアーキテクチャを表 1 として示す。なお、表 1 内の filter size は各層での畳み込みまたはプーリングを行う際の局所領域の大きさを、output size は、出力の(縦のサイズ)×(横のサイズ)×(出力マップの枚数)を示している。また、type 列に含まれる"LRN"は局所コントラスト正規化と呼ばれる処理を表しており、中間層において出力される各マップの値を正規化する処理を担っている。

表 1 CNN の構造表

name	type	filter size	output size
Input			224×224×3
Conv1	Conv.	5×5	110×110×48
Conv2	Conv.	4×4	107×107×48
	Pool.	3×3	53×53×48
	LRN	5×5	53×53×48
Conv3	Conv.	5×5	53×53×96
	Pool.	3×3	26×26×96
	LRN	5×5	26×26×96
Conv4	Conv.	5×5	24×24×192
	Pool.	3×3	12×12×192
	LRN	5×5	12×12×192
Out	Fc		8×1×1

5. 評価実験

本研究で用いた葉画像のデータセットは、葉検出部の負例データを除いて、すべて埼玉県農林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ものを用いている。

(1) 葉検出部

a) データセット

葉検出部の定量評価には、1 枚のキュウリ葉に着目して撮影した葉画像を、64×64px. にリサイズしたものを正例として 1,000 枚、McGill Calibrated Colour Image Database[9] に収録されている自然画像の中から 3,000 枚をランダムに選択し、64×64px. に切り取ったものを負例として使用した。

b) 特徴量の抽出と検出器の学習

研究では、論文[6]に従って、LUV 色空間(=3 チャンネル)、15~165 度の角度を持つ直線フィルタ (=6 チャンネル)、勾配強度の合計 10 チャンネルを選択した。AdaBoost 識別器に入れる矩形特徴は、それらのチャンネル画像群の中から、16×16px. の領域をランダムに 50 個選択し、学習に用いた。また、2 層からなる attentional cascade を構成する AdaBoost 識別器には、それぞれ 1 層目は 10 個の、2

層目は 20 個の弱識別器を使用して学習を行った。

c) 対象画像

葉を探索する対象の画像は、ビニールハウスの上部に想定し、畑内部の高い位置から撮影された農場画像を用いた。以下に撮影した画像の例を図 4 として示す。



図 4 畑の全体画像

d) 実験結果

以上の条件のもと、図 4 の画像中を 64×64px. の探索窓を用いて走査した結果、「葉領域」と判定された領域は検出されなかった。

(2) 葉認識部

a) データセット

葉認識部の定量評価には、7 種類のキュウリウイルス病害感染葉および健全葉、合計 8 クラス 16,000 枚 (各クラス 2,000 枚) からなる葉画像データセットを利用した。各クラスに属する病変画像は、光や影の影響が少ない理想条件下で撮影した画像 (good condition) 1,000 枚と、そうした明暗差の影響を大きく受けている画像 1,000 枚 (bad condition) から構成される。以下に、good condition および bad condition に含まれる画像の例を図 5 として示す。なお、これらの画像は、識別器へ入力する前に、224×224px. にトリミングを行い、正規化処理を行った。



図 5. (a) good condition 下のキュウリ葉画像
(b) bad condition 下のキュウリ葉画像

b) CNN の識別能力の検証

CNN が植物病害の診断に有効であることを検証するために、SVM を用いた比較実験を行った。入力した特徴量は、good condition 画像群からサンプルした bag of visual words [10] (以下 BoVW) である。次に識別結果を表 2 と

して示す.

表 2 good condition における識別結果

手法	平均正解率 [%]
BoVW+SVM	34.2
CNN	56.2

c) 明暗差, Augmentation の影響調査

CNN を学習する際, 識別能力を向上させるために, 画像に微小な幾何変化を加え, 画像枚数を水増しする処理が一般に行われる (data augmentation). そこで, good condition および bad condition 各々において, 学習データに微小な位置ずれを加えた画像 (×5), 鏡面画像 (×2), および 10 度刻みで回転させた画像 (×36) を加えて, augmentation を行った. その結果を以下表 3 として示す.

表 3 condition 及び augmentation の有無による識別率の変化

condition	augmentation	平均正解率 [%]
good	×	55.5
	○	84.0
bad	×	50.2
	○	80.6

6. 考察

(1) 葉検出部への考察

今回, 葉検出部においては葉領域の検出を行うことができなかった. 原因として考えられることとして, 特徴量取得に用いた画像チャンネルが, 葉の検出に即していなかった点, および特徴ベクトルの次元が十分でなかった点が考えられる. 前者については, 前述の通り様々なシフト不変性を持つ関数 Ω を設定する事ができる為, 本検出に即したチャンネルの発見可能性が残されている.

後者については, より画像サンプル数及び矩形領域数のサンプルを増加させることによって対応可能である.

(2) 葉認識部への考察

5.2.b の実験により, 特徴量設計を行った上で作成した識別器よりも, CNN が大幅に良い性能を達成していることが明らかとなった. さらに, 5.2.c の実験において, 撮影条件に光や影の影響があった場合においても, 十分に多量のデータを学習させることによって, 識別性能が大幅に向上することが示された. しかしながら, あらゆる環境下において対応可能なシステムを実現するためには, まだ議論の余地が残されている. 今回収集した画像群は葉の背景に対して制約を設けずに撮影した. CNN は, 入力の画素が僅かに変化するだけで, 出力が大幅に変化することが近年の研究で明らかとなっている[11]. 汎用的な病害診断システムを実現するためには, 葉の背景状況に依拠しない学習方法の検討を行う必要がある.

7. 結論

本研究では, 一般的な農園における植物病害自動診断を実現する枠組みを, キュウリ畑を対象として検討した. 検出部においては, 葉領域を高速に探索することが出来る attentional cascade を用いた検出器を提案した. また葉認識部においては, CNN を用いた識別装置を提案し, 悪条件下で撮影された植物病害写真の識別実験において 80%を超える性能を獲得した. 今後の課題として, 現在未解決となっている葉領域検出の実現, またより多種多様な背景, 病変, 植物に対して適用できる診断装置の実現が挙げられる.

謝辞: 本研究を実施するにあたって, データセットの提供他多数のご指導を賜りました宇賀博様, 鍵和田聡様, 共同研究者の藤田恵梨香様, 研究室のメンバー, そして学部時代から 4 年間に渡ってご指導頂いた彌富仁准教授に厚く御礼申し上げます.

参考文献

- 1) K. Oshima.: Plant potyvirus evolution the survey of the genetic structure of populations. Virus, Vol.2, pp.151-160, 2012
- 2) P. Viola et al.: Robust real-time object detection. Int. J. Computer Vision, Vol.57, No.2, pp. 137-154, 2002.
- 3) N. Dalal et al.: Histograms of Oriented Gradients for Human Detection, Proc. IEEE CVPR, pp. 886-893, 2005.
- 4) JGA Barbedo: Digital image processing techniques for detecting, quantifying and classifying plant diseases, Springerplus, Vol.2, No.1, pp.660-671, 2013.
- 5) A.Krizhevsky et al.: Imagenet classification with deep convolutional neural networks, Proc. NIPS, pp. 1097-1105, 2012.
- 6) P.Dollár et al.: Integral Channel Features, Proc. BMVC, pp.1-11, 2009.
- 7) M.Mathias et al.: Face detection without bells and whistles. Proc. ECCV, pp. 720-735, 2014.
- 8) E. Fujita et al.: Basic investigation on a robust and practical plant diagnostic system. Proc. IEEE ICMLA, pp.989-992, 2016.
- 9) A. Olmos et al.: A biologically inspired algorithm for the recovery of shading and reflectance images, Perception, Vol. 33, No.12, pp. 1463 - 1473, 2004.
- 10) G. Csurka et al.: Visual categorization with bags of keypoints, ECCV Workshops, pp. 59-74, 2004.
- 11) C. Szegedy et al.: Intriguing properties of neural networks, CoRR, arXiv: 1312.6199, 2013.