

圃場画像による植物病害自動検出に向けた 鉢花領域の分割

藤井 駿¹ 中村 嘉隆² 稲村 浩³ 石田 繁巳³

概要: 農業生産量において植物病害の影響は大きく, 植物病害は発見次第速やかに対処し除去等の処置を行う必要がある. 従来手法では病害検出精度を高める試みはなされているものの, 病害検出のために大量の画像データ収集および監視機器の設置・管理, 病害画像抽出作業等のコストが大きい. そこで, 本研究では圃場全体の画像のみを利用し, 個々の作物にあたる画像を画像処理を用いて分割して切り取る手法を提案し, 切り取った画像に対して病害識別を行うことで病害検出の精度向上を試みる. 評価実験の結果, 作物の画像は CNN による作物部分の分割と比較して約 7 ポイント高い 71.8% の F 値で 1 株の鉢花をトリミングできていることを確認した. 病害検出に関しては, 物体検出アルゴリズム YOLOv5 を圃場全体の画像に対して適用した場合と比較して約 23 ポイント高い 23.8% の F 値で病害であることを識別できることを確認した.

1. はじめに

植物病害によって, 農業生産量の約 1/3 以上が処分されている [1] と言われており, 植物病害は植物間の感染により被害が拡大するため, 発見次第速やかに対処し除去等の処置を行う必要がある. 現状では植物病害の発見は一定以上の知識を有する熟練農家や専門家による目視判断が一般的であるために, 農業就業人口の減少している現在においては管理コストが増大している. 文献 [2] の植物病害に対する調査によると, 植物の生育に携わる企業や農業法人, 農家の 9 割以上が植物病害の問題を抱えていると言われている.

これに対し, 植物病害の予測や検出の自動化を目指した研究が行われている. 文献 [3] や文献 [4] は, センサデータを利用してキュウリやトマトの圃場における病害を予測する研究を行っている. 文献 [5] は, キュウリ葉の病害を検出するために画像処理を用いた識別を行っている. 畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) による深層学習を用いた手法もいくつか提案されており, キュウリやトマトの病害を検出する研究や [6-8], キュウリ, トマト, ナス, イチゴ, ウリの葉を使用し, 植物病害の精度向上した研究も行われている [9]. 野菜以外にもイネに発現する病害を検出する研究を行っている [10].

一方, これらの手法は病害そのものを対象としているため, 病害葉等の特定の箇所のデータが必要となる. このため, 10000 以上の画像データ収集が必要となっており, 監視のための機器の設置・管理コストや, 病害部分の画像抽出等の作業コストが無視できない. 文献 [8] では圃場全体の画像から植物の葉を抽出し, 病害を検出する手法を提案しているが, 同一圃場での 50000 枚程度の画像学習が必要となり, 別の圃場環境で用いた場合には精度が低下する.

これらのように, 病害葉等の特定の箇所に対する病害検出は行われているが, 圃場全体の画像から病害を検出する研究は確立されていない. そこで, 圃場全体の画像から葉などの特定の箇所を抽出するシステムを構築することで既存研究 [6, 7, 9] のシステムを適用できると考える.

本研究では, 格子状に配置して生育するために各植物個体が抽出しやすい鉢花を対象とする. 圃場全体の画像からの鉢花領域分割によって各植物個体を抽出し, 各個体に対して病害識別を行う 2 段階の病害検出手法を提案している. 本稿ではこのうち, 鉢花領域分割について, 圃場画像に現れる格子状の特徴を抽出することで個々の鉢花へ分割する手法を検討する. 病害の識別に関しては, 物体検出アルゴリズムである YOLOv5 を用いる.

本稿の構成は以下のとおりである. 2 章では植物病害の検出に関する関連研究を概観し, 3 章では圃場全体の画像から植物病害を検出する提案手法を説明する. 4 章では提案手法の評価を行って評価結果に関する考察について述べ, 5 章で本稿の結論を述べる.

¹ 公立はこだて未来大学大学院 システム情報科学研究科

² 京都橘大学 工学部

³ 公立はこだて未来大学 システム情報科学部

2. 関連研究

一般的な野菜に発現する病害検出は主に CNN による深層学習を用いた手法と画像処理を用いた手法に分類することができる。

2.1 CNN による深層学習を用いた病害検出

CNN は画像解析に多く用いられており、植物病害検出にも広く利用されている。文献 [6] はキュウリに発現する 8 種類の病害と健康な葉を含めた 9 クラスの分類において識別正解率 83.2% を達成している。文献 [7] は、キュウリ葉の植物病害検出モデルにトマト葉の植物病害データを転移学習させて病害識別を行った結果、7 種類の病害と健康な葉を含めた 8 クラスの分類において識別正解率 83.7% を達成している。文献 [9] は、キュウリ、トマト、ナス、イチゴ、ウリの葉の病害データを学習することによって、植物病害の識別正解率を向上させている。これらで使用する学習データは、1 枚の葉にトリミングされたデータを使用しており、病害と疑われる葉の撮影が必要である。文献 [8] は葉のトリミングに対する問題に対し圃場全体の画像から植物病害を検出し、病害検出率 91.1% を実現している。この手法では、圃場画像から葉の抽出を行い、抽出した葉に対して病害識別を行う 2 段階の検出を行っている。

CNN による病害検出は概ね高精度な評価結果が報告されているが、大量のデータが必要となり、利用可能なデータを収集するコストがかかる。実際に文献 [6] では約 8000 枚、文献 [9] では約 12000 枚、文献 [8] では約 50000 枚の画像データを使用している。文献 [8] に関しては、学習データに用いた圃場とは別の圃場全体を撮影した画像を検出器にかけた場合の病害検出率は 38.9% まで低下している。

2.2 画像処理を用いた病害検出

少ないデータ数で病害検出を可能とするために画像処理を用いた研究がある。文献 [11] は、葉に発現する病害の画像領域のみを抽出する手法を提案し、葉に発現する病害領域のみ抽出している。しかし、病害葉をあらかじめ採取して、再度背景の影響がないように撮影した画像に対し評価を行っているなど撮影条件を制限している。そのため、圃場で適用した場合背景の処理について検討する必要がある。文献 [5] はこの問題に対し、圃場で撮影した葉の画像に対し画像処理を用いて病害を検出を可能としている。画像処理は、入力 RGB 画像にグレースケール処理し、画像中の画素値の数をグラフにした濃度ヒストグラムを算出する。算出したヒストグラムから適当な閾値を決め二値化している。これにより、8 枚の葉の画像データを使用し 3 種類の病害に対し全て正しく識別を行っている。これらの研究も文献 [6, 7, 9] と同様に 1 枚の葉が写っている画像のみを使用しているため、コスト削減にはつながっていない。

文献 [12] はこの問題に対し、画像処理を用いて圃場全体が映った画像から 1 枚の葉を切り取る手法を提案しているが、検出に失敗している。この理由として、特徴取得に使用した画像チャンネルが葉の検出に適していなかったためと述べられている。

文献 [5, 11] のように、検出する病害に顕著な特徴があれば病害領域のみを抽出し病害の種類・感染度を識別することは可能であるが、圃場画像からの葉の抽出に関しては画像処理を用いるのみでは難しいとされている。つまり、画像処理は大量のデータを必要とせず病害検出を行うことが可能である一方、病害検出するために全ての画像に共通する特徴を適切に設定する必要がある。

3. 鉢花領域の分割を用いた病害検出システム

本研究は、圃場全体の画像から病害検出を可能とするため、格子状に配置して生育することから各植物個体が抽出しやすい鉢花を対象とし、植物個体の抽出後に病害識別を行う 2 段階の手法を提案する。提案手法の概要を図 1 に示す。1st step では、圃場全体の画像からの鉢花領域分割によって各植物個体の抽出を行う。2nd step では、各個体に対して病害識別を行う。

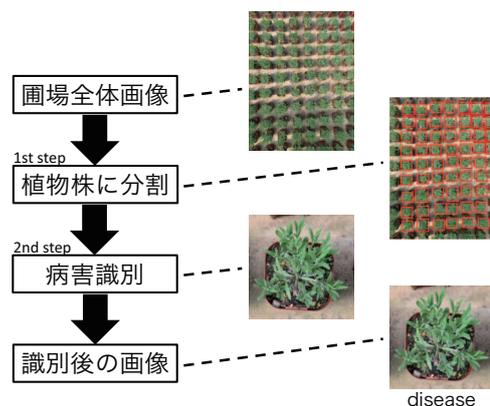


図 1 提案システム概要図

3.1 1st step: 鉢花領域分割手法

画像処理で鉢花領域分割を実現させるために圃場全体に格子状に配置されて生育されているという特徴を利用する。鉢花以外の背景を抽出すると、格子状の線が現れる。格子状の線の交点でトリミングすることで鉢花一株ごとの抽出を実現することが主なアイデアである。各鉢花間に現れる格子状の直線は Hough 変換 [14] を用いて検出する。Hough 変換を用いて鉢花領域を分割し、鉢花個体をトリミングするプロセスを図 2 に示す。まず、Hough 変換を適用するための鉢花個体と背景の領域抽出を行う。抽出した領域に対して Hough 変換を行って直線を検出し、斜線を除去したあと、格子に従って鉢花個体をトリミングする。

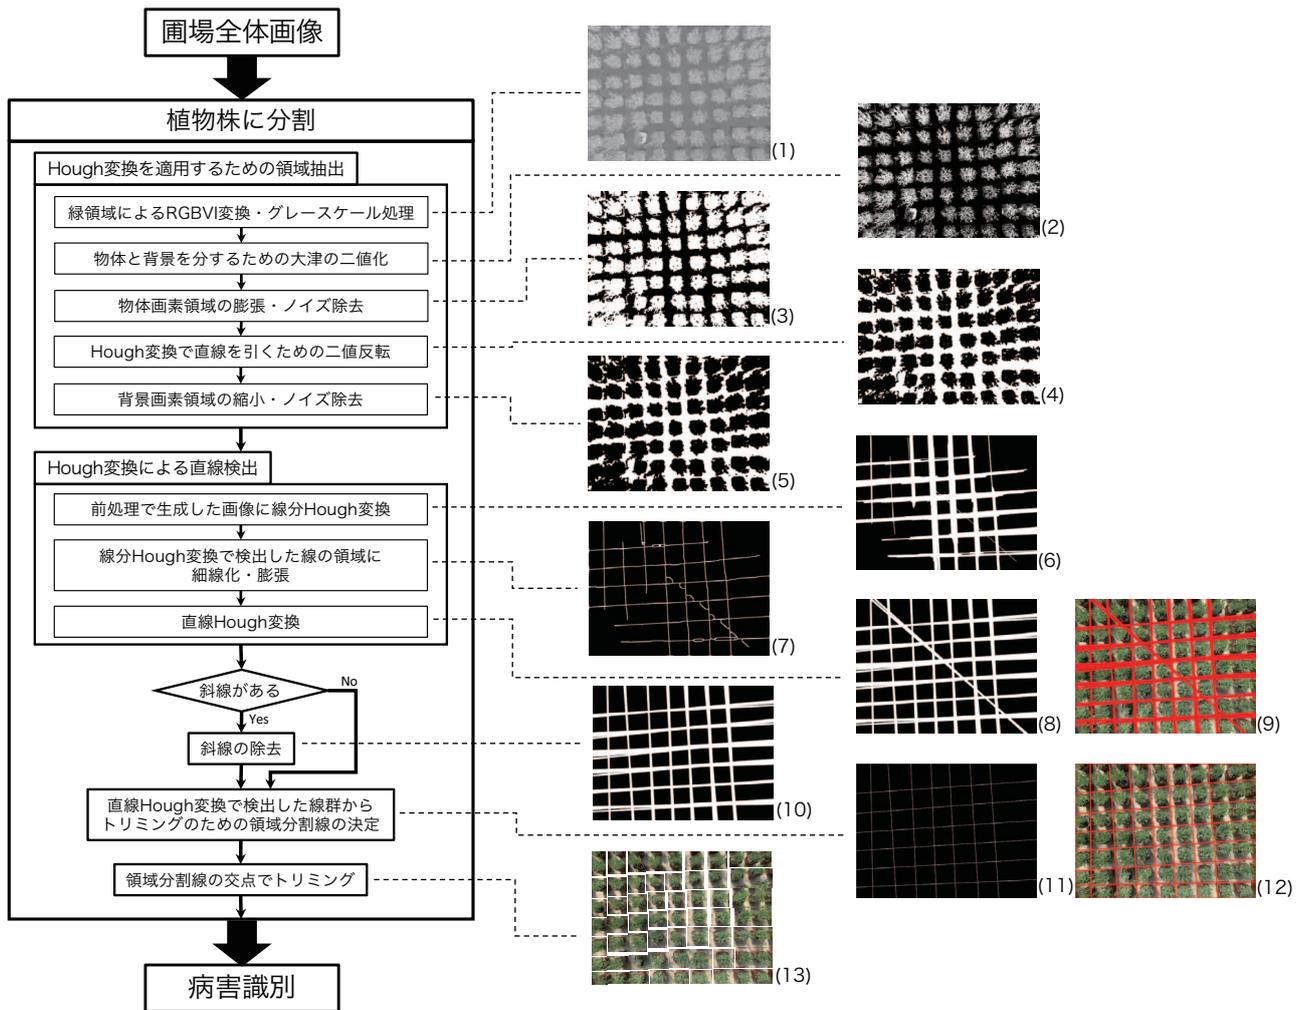


図 2 分割プロセス

Hough 変換を適用するための領域抽出

圃場画像から格子状直線を検出するための前処理を行う。圃場における格子状直線は鉢花個体以外の背景に現れるため、これを分別する。鉢花個体の葉の色である緑に着目し、緑以外の色を背景とみなす。植物個体の緑領域を抽出する手法として、朴ら [15] は稲作の生育状況を把握するために画像の RGB チャンネルを用いており、式 (1) に示す赤緑青植生指数 (RGB based Vegetative Indexes: RGBVI) を用いることで、高精度で緑領域の特徴を抽出している。

$$\frac{G^2 - (R \times B)}{G^2 + (R \times B)} \quad (1)$$

本研究でもこの手法を利用し、圃場全体の画像の RGB チャンネルから緑領域を抽出する。圃場全体の画像はチャンネル数 3 であり、いずれのピクセル値も 0~255 の範囲にある。それぞれピクセルごとに式 (1) を適用するとチャンネル数 1 のピクセル値は -1~1 の範囲になる。式 (1) の適用後の画素値 -1~1 の範囲を 0~255 にし、グレースケール画像に変換する。

変換したこのグレースケール画像は多段階調の画像であるために、そのままでは Hough 変換を適用できない。そこで、変換したグレースケール画像に対して二値化処理を行う。ここでは大津の二値化 [16] を適用する。二値化後の圃場画像は鉢花個体が白、背景が黒で表される。一般に Hough 変換は白領域を直線として検出するため、二値化後の画像を白黒反転する。

反転後の圃場画像には、鉢花個体部分に黒斑、背景部分に白斑が存在し、ノイズとなっている。画像内の白領域に対し膨張処理・収縮処理を行うことでノイズを除去する。これらの処理によって圃場全体の画像内の鉢花個体領域と背景領域の分別が可能となる。

Hough 変換による直線検出

ノイズ除去後の圃場全体画像では、背景領域が線状の白領域として現れているが、多数の線分・直線が混在した状態であり、画像に直接 Hough 変換を行った場合には鉢花とは無関係な多数の直線まで抽出されるため、鉢花個体領域と背景領域を分割するための最適

な直線を抽出することが難しい。そこで、まず背景領域内に始点と終点が存在する線分が出力されるようにパラメータを調整した Hough 変換を行う。これを線分 Hough 変換とする。これによって鉢花個体領域と背景領域を分割する直線の候補となる線分が現れる。鉢花個体領域をトリミングするためにはこの線分を画像全体にまたがる直線にする必要がある。線分が多く重なっている部分が領域間の境界線候補として有力であるため、線分 Hough 変換で出力された線分に細線化を施し、細線化した線分に膨張処理を行うことで、圃場全体画像内の鉢花個体領域と背景領域を分割する直線を出力する。これを直線 Hough 変換と呼ぶ。

斜線の除去

図 2 の直線 Hough 変換適用後の画像 (図 2(8)) が斜線を含む場合、この斜線は鉢花の配置から鉢花個体領域とは無関係なノイズであるため、除去する必要がある。Hough 変換の過程では検出した直線の傾き・切片が求められ、この傾きからクラスタリング手法を用いて各直線を分類することで、斜線を分別する。提案手法ではクラスタリング手法に密度ベースのクラスタリング手法である DBSCAN [17] を用いる。斜線は縦横の方向の直線より少なくなるため、直線の本数が上位 2 つのクラスタに属する直線を領域分割線として利用し、残りのクラスタに属する直線は除去する。全ての直線が 2 つのクラスタに分類された場合は斜線が存在しないと判定する。

例として図 2 で例示した画像に対して直線の傾きをクラスタリングした結果を図 3 に示す。縦軸は直線の傾きを表し、横軸は直線の傾きのみでクラスタリングしているため規定値として 0 としている。この結果から、38 本の直線を持つクラスタ、5 本の直線を持つクラスタ、29 本の直線を持つクラスタに分類されている事がわかり、真ん中のクラスタに属する 5 本の直線を斜線として分別し、除去する。

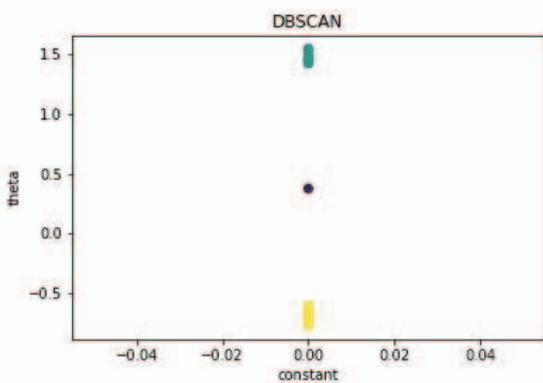


図 3 傾きで DBSCAN した結果

トリミングのための領域分割線の決定

直線 Hough 変換後の画像は複数の直線が重なった状態であるため、そのまま鉢花個体をトリミングするための領域分割線としては利用できない。そこで、全ての直線を太線化し、任意の線に対し領域が重なる線をクラスタリングする。この際、同じクラスタに分類されるはずの直線に対し、直線が細すぎると同じクラスタと分類されず、直線が太すぎるとと本来別のクラスタとするべき直線を同じクラスタと分類してしまうため、20 ピクセル程度の太さに設定する。クラスタリングされた直線の太さを算出し、直線の中央を通る線を領域分割線として採用する。

領域分割線の交点でトリミング

求めた最適な領域分割線の交点でトリミングを行うことで鉢花を 1 株の個体に分割することを可能にする。4 つの交点の通る最大の矩形でトリミングを行う。これによりトリミングした鉢花個体画像は最大限の画像情報を維持できる。

3.2 2nd step: YOLOv5 を用いた病害識別手法

1st step で分割した画像に対し、高速な処理速度をもつ物体検出アルゴリズムである YOLOv5 [13] を用いて病害識別を行う。Yan ら [18] は YOLO の物体検出精度をバージョン間で比較した結果、YOLOv5 は他のバージョンに比べ、mAP (mean Average Precision) や学習速度が向上したと報告している。mAP とは、物体検出モデルに用いられる評価指標であり、数値が高いほど検出精度が高いため、その物体検出モデルの有効性を表す。さらに、農業における物体検出にも用いられており、トマト、スナックエンドウ、イネの検出を行った結果、高い検出精度を達成している [19]。病害識別の学習時には病害の種類ごとにはラベル付けせず、病害箇所のみをアノテーションしたデータを学習し病害識別のモデルを構築する。

4. 評価と考察

病害検出の評価のために、鉢花個体トリミング手法と病害検出手法全体の評価を行う。鉢花個体トリミング手法に関する評価では、提案手法と CNN を用いた分割手法の精度について比較評価を行う。病害検出手法に関する評価では、提案する 2 step の病害検出システムと圃場全体の画像から YOLOv5 のみを用いて病害検出した手法の比較評価を行う。

評価データとして、実際の圃場から図 4 のような装置で代表的な鉢花であるラベンダーの圃場を撮影した画像データ 136 枚を用いた。学習データとしては約 60 株が 1 枚に写っている画像、約 10 株が 1 枚に写っている画像、1 株が 1 枚に写っている画像のようにズームしたものをを用いた。テストデータとしては、78 枚を用いた。

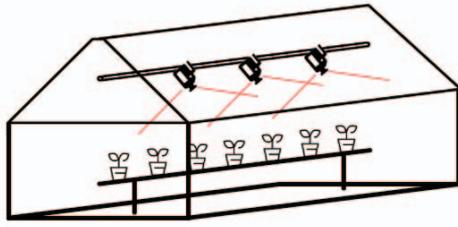


図 4 撮影環境

4.1 鉢花個体領域トリミング手法の評価と考察

鉢花個体領域トリミング手法の評価では、1株全体のみをトリミングできているかどうかを評価基準とする。ここでいう「1株全体のみ」とは「1株全体が写っており、他の株は半分より小さい部分のみが写っている」状態を指す。

この評価基準に対して、適合率 (Precision, 式 (2)), 再現率 Recall, 式 (3)), F 値 (F measure, 式 (4)) を用いて評価する。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

$$\text{F measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

本実験では、TP (True Positive) はテストデータの画像から鉢花がトリミングされた場合、FN (False Negative) はテストデータ画像のトリミングで鉢花がトリミングされなかった場合、FP (False Positive) はテストデータ画像のトリミングで鉢花以外もトリミングされた場合を指す。そのため、適合率はトリミングした画像が鉢花1株である確率、再現率は複数の鉢花株を1株としてトリミングしている確率となる。

評価結果として CNN を用いた分割手法では適合率 94.3%, 再現率 49.5%, F 値 65.0% に対し、提案する鉢花領域トリミング手法は適合率 74.3%, 再現率 69.5%, F 値 71.8% となった。適合率では CNN による深層学習の方が精度が高いが再現率と F 値は提案手法が高い値を達成している。この結果から提案手法は CNN を用いた分割手法より、鉢花株の見落としが減少している。

提案手法の適合率が 77.2% となったのは、密集箇所における分割の精度が低いことが考えられる。分割がうまくいかなかった入力画像と領域抽出後の画像と 2 回目の Hough 変換後の画像を図 5 に示す。画像の中心から縁にかけて撮影時に歪みが生じており、該当部分の背景領域の部分が検出できなくなってしまったことが原因であると考えられる。

また、再現率も適合率と同様画像の領域分割精度が低いため 67.5% にとどまっていると考えられる。したがって、撮影画像の歪み補正や Hough 変換のパラメータ調整を用いることで、鉢花個体領域の分割精度を向上できれば、鉢花領域トリミング手法全体の精度も向上可能である。



図 5 分割がうまくいかなかった場合の入力画像 (左: 入力画像, 中央: 前処理の画像, 右: 2 回目の Hough 変換)

4.2 病害検出の評価と考察

提案手法の病害識別も比較対象の YOLOv5 の病害検出も同じ病害を学習させたモデルを使用する。学習データは 168 枚で、約 1200 箇所の病害をアノテーションしたデータを学習している。病害識別手法の評価では、病害株の病害箇所をバウンディングボックスの形で検出できているかどうか評価基準とする。

この評価基準に対して、適合率 (Precision, 式 (2)), 再現率 (Recall, 式 (3)), F 値 (F measure, 式 (4)) を用いて評価する。

本実験では、TP (True Positive) はテストデータの画像から病害箇所がバウンディングボックスの形で識別された場合、FN (False Negative) はテストデータ画像から病害箇所を識別できなかった場合、FP (False Positive) はテストデータ画像から病害箇所として識別した箇所が病害箇所ではなかった場合を指す。そのため、適合率は識別した病害箇所が正しく病害箇所である確率、再現率は画像中の病害箇所が識別できた確率となる。

提案手法に関しては、鉢花領域トリミング手法で、圃場全体画像から各鉢花個体を抽出したあとの画像に対して病害識別手法を適用しており、圃場全体画像そのものを YOLOv5 に入力して病害識別する手法と識別の精度を比較する。

評価結果として、YOLOv5 を用いた手法では適合率 0.5%, 再現率 0.6%, F 値 0.5% に対し、提案手法は適合率 18.7%, 再現率 32.9%, F 値 23.8% となり、提案手法による病害識別精度の向上が確認できた。このように、圃場全体画像か

ら直接病害検出を行う場合より、提案手法は検出精度を向上できており、さらに検出に必要なデータ数も従来手法より少ない約 1200 に抑えられているものの、実際に農業現場での作業補助に用いるには精度が不足している。これについては、病害識別部分は、使用する画像データを圃場全体画像からトリミングした鉢花個体画像に変更しているのみであり、識別自体は従来と同じ YOLOv5 を使っているにすぎない。そのため、識別手法を更に改善することで、病害検出精度向上の余地があると考えられる。

5. おわりに

本稿では、Hough 変換を用いた画像処理によって植物病害の検出精度を向上する手法を提案した。圃場全体を撮影した画像から Hough 変換を用いて格子状の鉢花個体領域をトリミングした結果、CNN による作物部分の分割手法と比較して、約 7 ポイント高い 71.8% の F 値で 1 株の鉢花をトリミングできていることを確認した。トリミングした鉢花個体に対して病害識別を行った結果、従来の YOLOv5 を圃場全体画像に用いる手法と比較して、約 23 ポイント高い 23.8% の F 値病害であることを識別できることを確認した。

現状では、病害箇所の識別に関して YOLOv5 を用いた従来手法そのままを適用しており、病害識別手法には改善の余地があるため、病害識別精度の向上が今後の課題となる。

参考文献

- [1] E.C. Oerke, H.W. Dehne, F. Schonbeck, et.al.: Crop Production and Crop Protection: Estimated losses in major food and cash crops, *Agricultural Systems*, Vol.51, No.4, pp.493-495 (1996).
- [2] 福田一徳, 濱本宏, 橋本将典ほか: 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] 菅原直人, 小林隆, 長谷修: 葉面濡れセンサーを用いた葉いもちの発生予察, *生物と気象*, Vol.21, pp.74-80 (2021).
- [4] 森朝子: センサーデータと AI を活用した病害感染リスク予測, *植物防疫*, Vol.73, No.6, pp.381-386 (2019).
- [5] 小川秀夫, 酒井大輔: 画像処理によるキュウリの葉の病害診断, *愛知教育大学研究報告*, Vol.58, pp.13-19 (2009).
- [6] E. Fujita, H. Uga, S. Kagiwada, et.al.: A Practical Plant Diagnosis System for Field Leaf Images and Feature Visualization, *International Journal of Engineering & Technology*, Vol.7, No.4, pp.49-54 (2018).
- [7] 藤田恵梨香, 川崎雄介, 宇賀博之, 転移学習を用いた植物病害自動診断システムの試み, *情報処理学会第 79 回全国大会*, Vol.2017, No.1, pp.293-294 (2017).
- [8] K. Suwa, Q. H. Cap, R. Kotani, et al. : A comparable study: Intrinsic difficulties of practical plant diagnosis from wide angle images, *2019 IEEE International Conference on Big Data (Big Data)*, pp. 5195-5201 (2019).
- [9] 田邊肇比古, 鍵和田聡, 宇賀博之ほか: 2 段階転移学習によるナス病害自動診断システム開発の試み, *情報処理学会第 81 回全国大会講演論文集*, Vol.2019, No.1, pp.245-246 (2019).
- [10] Y. Qing, G. Zexin, Z. Yingfeng, et al.: Application of Support Vector Machine for Detecting Rice Diseases Using Shape and Color Texture Features, *Proc Engineering and Computation*, pp.79-83(2009).
- [11] T. Jadhav, N. Chavan, S. Jadhav, V. Dubhele: A Review on Plant Disease Detection using Image Processing: *International Research Journal of Engineering and Technology (IRJET)*, Vol.6, No.2, pp.2526-2530 (2019).
- [12] 川崎雄介: 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, *法政大学大学院理工学・工学研究科紀要*, Vol.58, pp.1-4 (2017).
- [13] G. Jocher, A. Stoken, J. Borovec, et al.: ultralytics/yolov5: v5.0- YOLOv5-P6 1280 models, AWS, Supervise.ly and YouTube integrations (2021).
- [14] D.H. Ballard: Generalizing the Hough transform to detect arbitrary shapes, *Pattern Recognition*, Vol.13, No.2, pp.111-122 (1981).
- [15] 朴鍾杰, 平山英毅, 王劍南, 吉池美緒: UAV による農作物の判別と生育状況把握 (UAV によるスマート農業への基礎研究), *東京情報大学総合情報研究所プロジェクト研究 研究実績報告書* (2019).
- [16] N. Otsu: A threshold selection method from gray-level histograms, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol.9, No.1, pp.62-66 (1979).
- [17] E. Martin, Kriegel, H. Peter et al.: A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise, *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, pp.226-231 (1996).
- [18] B. Yan, P. Fan, X. Lei, et al.: A Real-Time Apple Targets Detection Method for Picking Robot Based on Improved YOLOv5, *Remote Sensing*, Vol.13, No. 9, pp.1-23 (2021).
- [19] T. Nukui: 【YOLOv5】スナックエンドウの収穫に物体検出をつかってみる【独自データ】, *FarmL BLOG (オンライン)*, 入手先 <<https://farml.com/yolov5/>> (参照 2022-05-23)