

等間隔な配置を利用した画像からの作物検出*

太田薫平^{**},^{***} ルイ笠原純ユネス[†] 浅間 一[†] 山下 淳[†],[†]

Crop Detection Using Images and the Uniform Spacing in Crop Positions

Kumpei OTA, Jun Younes LOUHI KASAHARA, Hajime ASAMA and Atsushi YAMASHITA

Crop detection is important for automatic weeding. A previous study achieved crop detection by detecting plant blobs in crop rows and by classifying them as crop or weed using k-means. However, this method was not robust to the amount and shape variation of the weed. In this paper, we propose a crop detection method that uses the uniform spacing in crop positions to address the problem encountered by the previous method. The classification results of the previous method are updated such that plants with uniform spacings are classified as crop. Experiments with artificial and real weeds validate the effectiveness of the proposed method.

Key words: crop detection, crop row, genetic algorithm

1. 序 論

雑草は農業生産に悪影響を及ぼすため、防除する必要がある。雑草の防除手段として、ほ場全体に除草剤を散布する方法が広く用いられている。しかし、近年は環境影響等の懸念から、農薬の使用量低減に向けた取り組みが日本を含む世界各地で活発化している¹⁾³⁾。

除草剤の使用量を低減する代表的な方策として、雑草を引き抜く、埋没させる、又は物理的に破壊する方法である機械除草がある。従来から用いられてきた機械除草の主な方法は、カルチベータ、ロータリーカルチベータ等の機械による除草、ホー等の人力の除草道具による除草、手取り除草である。しかし、カルチベータ、ロータリーカルチベータ等の機械による除草では、作物列に沿って走行しながら連続的に処理を行うため、作物と雑草の混在する作物列内の除草はできない。一方、手取り除草と人力の除草道具による除草では作物列内の除草が可能であるが、作業能率が小さい。これに対し、一定の作業能率を確保しつつ作物列内の除草を実現するため、作物又は雑草を検出し選択的に処理することで作物列内の機械除草を行う除草ロボットの開発が多く行われている⁴⁾⁷⁾。このような除草ロボットにおいて、作物検出、雑草検出は必須の技術である。

これまでに、教師有り学習を用いて画像から作物、雑草を検出する研究が多く行われてきた⁸⁾⁹⁾。Ahmedらは画像中の植物を作物と雑草に分類するためにサポートベクターマシンを用い、その有効性を示した¹⁰⁾。また、Paricoらは、空撮画像からの雑草検出に畳み込みニューラルネットワークを用い、その有効性を示した¹¹⁾。しかし、これらの方法を農業現場で使用する場合には、ほ場に存在する雑草の種類や生育度合いを事前に把握し、正解ラベル付きの訓練データを用意して検出器を訓練する必要があ



Fig. 1 An example of cabbage field. Crops are planted in straight line with uniform spacing

る。しかし、次の2点の理由により、ラベル付けされた作物と雑草の画像を十分量確保することは困難な場合が多いと考えられる。第一に、想定外の雑草がほ場に侵入する可能性もあり、また、雑草の種類や生育度合いは時間の経過に伴って変化するため、それらを事前に実施することは困難である。第二に、作物画像の公開データセットも存在するが、それらで対応可能な作物は限定的である。作物の種類には地域差もあり、特定の地域でしか栽培されないものもあることから、全ての作物に対して公開データセットが整備されるまでには相当の年月を要すると考えられる。したがって、ラベル付けされた作物と雑草の画像を用いなくても使用可能な作物検出、雑草検出の方法が必要である。

そのような作物検出、雑草検出の方法として、作物の直線的な配置を利用する方法がある¹²⁾¹⁴⁾。作物栽培においては、主に除草等の管理作業、収穫作業を容易にする目的で作物を直線的に植え付ける場合が多い(図1)。傾斜地において降雨による土壌侵食を防止するために等高線方向に畝立てをする場合等に非直線的な作物列を作成する場合もあるが、機械による作業性の観点からは直線的な作物列を作成することが基本である。その特徴を利用し、直線的に配置された植物を作物、逆に直線から離れた位置に存在する植物を雑草として判定することが、これらの手法の基本的な考え方である。Wendelら、Louargantらは、画像から作物列を表す直線(作物列直線)を検出し、その直線を利用して自動でピクセル単位のラベル付けを行い、輝度値を特徴量として分類器を訓練する方法を提案した¹²⁾¹³⁾。Bahらは画像中の植物領域を小領域に分割し、作物列直線と小領域の位置関係によって作物と雑草に分類する方法を提案した¹⁴⁾。

* 原稿受付 令和4年5月27日

掲載決定 令和4年10月31日

** 正会員 農業・食品産業技術総合研究機構 農業機械研究部門(埼玉県さいたま市北区日進町1-40-2)

*** 正会員 東京大学大学院 工学系研究科 精密工学専攻(千葉県柏市柏の葉5-1-5)

† 正会員 東京大学大学院 工学系研究科 精密工学専攻(東京都文京区本郷7-3-1)

†† 正会員 東京大学大学院 新領域創成科学研究科 人間環境学専攻(千葉県柏市柏の葉5-1-5)

作物の直線的な配置を利用したこれらの手法には、次に述べる2点の長所がある。第1に、作物が直線的に配置されている限り、作物と雑草の種類にかかわらず適用できる。第2に、作物と雑草の生育ステージにかかわらず適用できる。しかし、これらの研究では作物列直線上の植物を全て雑草とみなすため、作物列直線上に存在する雑草も作物として分類してしまう問題がある。したがって、作物列直線上の植物を作物と雑草に正しく分類する手法が必要である。

上述の問題を解決するため、Otaらは形状特徴を用いたk-means法によって作物列直線上の植物を2分割し、含まれるサンプル数の多いクラスを雑草、他方を作物として特定する方法を提案した¹⁵⁾。この方法によって、作物列直線上に存在する作物と雑草を区別することが可能となった。しかしk-means法は一般にクラスに含まれるデータの数や密度がクラス間で異なる場合に性能が低下しやすい。したがって、Otaらの手法¹⁵⁾は雑草の数や形状特徴のばらつきによっては性能が低下する懸念があると考えられる。

そこで本研究では、雑草の数と形状特徴のばらつきに対して頑健な作物検出手法の提案を目的とする。目的を達成するため、本研究では、作物は直線的に配置されているだけでなく、直線上での間隔がほぼ均一であること（等間隔性）に注目し、その性質を利用して作物検出を行う手法を提案する。具体的には、Otaらの手法¹⁵⁾による処理結果に対し、等間隔性を考慮した更新処理を適用することで、性能の改善を行う。

2. 提案手法

2.1 コンセプトと概要

本研究で対象とする作物検出は、除草ロボットへの搭載を想定したものである。想定する除草ロボットは作物列に沿って走行し除草作業を行う。画像から作物を検出し、作物との接触を回避しながら作物列内の除草を行う。カメラにはRGB-Dカメラを用いる。

作物栽培においては養分、水分、日光を各作物個体に均一に分配する目的で作物を一定の間隔で植え付ける場合が多い。本研究ではこの特徴に注目し、検出した植物のうち一定の間隔で存在するものを作物、そうでないものを雑草に分類するよう分類結果を更新する手法を提案する。具体的には、提案手法ではOtaらの手法¹⁵⁾による分類結果を基に、作物に分類されたプロブの作物列方向の間隔のばらつきが小さくなるよう結果を更新する。

本研究で提案する作物検出手法のコンセプトを図2に示す。図2の左側の検出結果は、ベースとなるOtaらの手法¹⁵⁾による結果を表す。第1章で述べたように、Otaらの手法¹⁵⁾では雑草の数や形状特徴のばらつきによっては誤分類が生じる懸念がある。誤分類が生じた場合、作物に分類された植物の間隔（図2左側の $d_1 \sim d_5$ ）は不均一になる。これに対し、図2の右側に示すように、間隔が均一になるように結果の更新を行うことで、誤分類を減らすことができると考えられる。

提案手法の概略を図3に示す。提案手法では、植物を表すプロブを画像から検出し、そのプロブを作物・雑草のいずれかに二値分類することで作物検出を行う。提案手法は大きく植物検出、作物列検出、k-means法による分類、等間隔性を利用した結果の更新の4段階からなる。このうち、植物検出、作物列検出、k-means法による分類の3段階はOtaらの手法¹⁵⁾と同様であり、本研究の新規性は等間隔性を利用した結果の更新の部分にある。次節以降で、各処理の詳細を述べる。

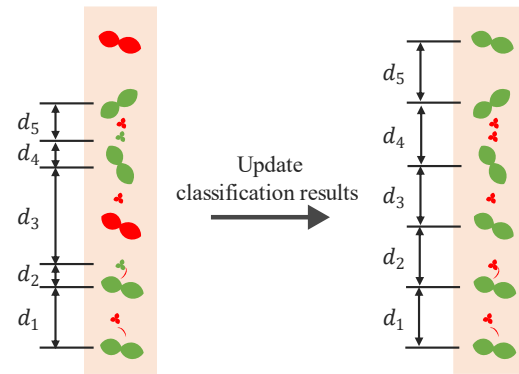


Fig. 2 The concept of the proposed method (Green represents crop. Red represents weed)




Fig. 3 The overview of the proposed method




Fig. 4 Plant area extraction

なお、除草ロボットによる具体的な作業方法としては、次の2段階を想定している。第1段階は、画像を用いた作物位置取得のための自動走行、第2段階は、第1段階で取得した作物位置を用いた除草作業である。第1段階では、GNSS、IMU、ホイールエンコーダー、ビジュアルオドメトリなどを活用し、画像から取得した作物位置を記録する。第2段階では、第1段階で取得した作物位置を利用し、作物の存在しない領域の土壌表層全体を処理し、除草を行う。具体的な除草装置としては、Robovator¹⁶⁾と同様のものを想定している。この除草装置は、2枚1対の平板状の除草爪を土壌に潜らせながら進行することで雑草を切断するまたは引き抜くものである。除草ロボットは作物列に沿って

走行し、作物の存在する地点でのみ 2 枚 1 対の除草爪が離れて作物を通すことのできるスペースを設けることで、作物以外の領域を処理する。この方法では作物以外の領域を全て処理するため、雑草の位置や数を認識する必要はない。上記第 1 段階と第 2 段階の繰り返しは作物列 1 列ごとに実施する。具体的には、ある作物列に対し、往路で作物位置取得、復路で除草作業を行う。この方法では作物検出はオフライン処理で問題ないが、処理時間が長くなると第 1 段階と第 2 段階の間の待機時間が長くなるため、処理時間は短くすることが望ましい。

2.2 植物検出

本処理では、RGB 画像中に存在する植物のプロブを検出する。処理は二値化、連結成分ラベリングの 2 段階からなる。二値化は、Ahmed ら¹⁰⁾の植物領域抽出処理と同様に RGB 画像の G チャンネルを用いて行う。閾値は大津の方法¹⁷⁾を用いて決定する。閾値を一定の値にせず大津の方法¹⁷⁾を用いて決定する理由は、太陽光の変動による輝度の分布の変化に対応するためである。連結成分ラベリングは、Scan plus Array-based Union-Find アルゴリズム¹⁸⁾によって行う。

植物検出の結果の例を図 4 に示す。図 4(a)の RGB 画像と図 4(b)の二値画像を対比すると、RGB 画像中の植物領域とその他の領域が正しく分離されていることが分かる。

2.3 作物列検出

本処理では、太田らの提案した畝形状を利用する作物列検出手法¹⁹⁾を用いる。作物列検出においては、直線的に存在する作物列を作物列として検出する方法¹²⁾⁻¹⁴⁾が広く用いられているが、この方法では雑草量が多い場合に精度が低下する問題がある。それに対し、太田らの方法¹⁹⁾は、地表面を抽出した深度画像に波形面をフィッティングすることで畝を検出し、その中央線を作物列として検出するものである。地表面の形状は雑草量の影響を受けないため、太田らの方法¹⁹⁾は雑草が多く存在する場合でも高い精度で作物列を検出可能である。

具体的な手順は次の通りである。まず、植物検出の処理で作成した二値画像を深度画像に重ね合わせる。この処理の目的は、深度画像のうち地表面に対応する領域だけを抽出することである。続いて、深度画像に対して波形面のフィッティングを行う。畝は通常一定の間隔で存在するため、周期的な波形面を用いることで高精度に作物列を検出可能である。波形面は以下の式(1)、(2)で表される 1 次元の波形を y 軸方向に走査することで形成する。

$$z = hc \cos \frac{2\pi(x - x_c)}{T} + b, \quad (1)$$

$$x_c = \frac{\rho - y \sin \theta}{\cos \theta}. \quad (2)$$

x 軸は画像の右方向を正、y 軸は画像の下方向を正、z 軸は画像の奥行方向を正とする。本手法では、鉛直方向下向きに取付けたカメラで撮影した画像を用いるため、z の値は水平面に対する起伏を表わす。x_c は作物列直線の x 座標である。h、T、b、ρ、θ はフィッティングで最適化するパラメータであり、それぞれ波の振幅、周期、基準面の高さ、作物列直線と画像原点の画像上での距離、作物列直線の画像上での傾きを表す (図 5)。このフィッティングで得られる作物列直線のパラメータ ρ、θ は 1 組であるが、ρ に周期 T の整数倍を加えることで画像中に存在する他の作物列直線を検出可能である。本研究では、画像の中心に最も近い直線だけを作業対象の作物列として検出する。

作物列検出結果の例を図 6 に示す。図 6(a)の RGB 画像と図 6(b)の深度画像を対比すると、作物列に沿って周期的に地形が隆




Fig. 5 Parameters of wave surface




Fig. 6 Crop row detection

起していることが分かる。また、検出された作物列直線 (赤線) は畝の中央に存在していることが分かる。

2.4 k-means 法による分類

本処理では、Ota らの方法¹⁵⁾を用いて作物列上に存在する植物のプロブを作物と雑草のいずれかに分類する。従来の研究では、作物列上に存在する植物を全て作物に分類する方法が用いられてきた¹²⁾⁻¹⁴⁾。しかし、その方法では雑草が多く存在する場合に誤分類が多く生じてしまう。Ota らの方法¹⁵⁾ではその問題を解決するため、作物列上に存在する植物のプロブを k-means 法で 2 つのクラスに分け、含まれるデータ数の多いクラスを雑草クラス、他方を作物クラスに割り当てる。なお、この方法では雑草数が少ない場合には誤ったクラスの割り当てを行ってしまうと考えられるが、本研究の提案手法では後続の 2.5 節で述べる処理によってその問題を解決する。

具体的な手順は次の通りである。まず、2.2 節の処理で得た植物のプロブと、2.3 節の処理で得た作物列直線を組み合わせ、作物列と重なるプロブだけを抽出する。続いて、抽出したプロブごとに形状特徴を取得し、標準化を行う。形状特徴には、プロブの面積、周囲長、アスペクト、円形度、Solidity、Elongation²⁰⁾、Cube of Perimeter to Area by Length²⁰⁾を用いる。そして、クラス数 k を k=2 とする k-means 法によってクラスタリングを行う。最後に、含まれるデータ数の多いクラスを雑草クラス、他方を作物クラスに割り当てる。

2.5 等間隔性を利用した結果の更新

本処理では、分類性能を向上させるため、作物の等間隔性を利用して k-means 法による分類結果の更新を行う。具体的には、遺伝的アルゴリズムを用いて作物列上のプロブへのクラスラベルの割り当てを最適化する。遺伝的アルゴリズムの方法は binary-coded GA である。各プロブへのクラスラベルの割り当て (雑草は 0、作物は 1) によって 2 値の符号化をする。染色体長はプロブ数であり、作物列上のプロブ数に応じて画像ごとに設定する。交叉は 2 点交叉によって行い、交叉率は 0.5 とする。突然変異

は、ある遺伝子の値を反転させることで行い、突然変異率は0.01とする。最も適応度の優れた個体の適応度が改善されない世代交代が10回連続で生じた場合を収束と定義し、収束が生じた場合、あるいは100世代に到達した場合には計算を終了する。個体数は100とする。以下の式(3)で表す目的関数を最小化するようにクラスラベルの割り当てを最適化する。

$$\sum_{i=1}^n \sum_{j=0}^{k-1} w_{ij} \|x_i - \mu_j\|_2 + \sum_{l=1}^{m-1} \left\| \frac{d_l - \bar{d}}{\bar{d}} \right\|_2, \quad (3)$$

$$w_{ij} = \begin{cases} 1 & (x_i \in C_j) \\ 0 & (x_i \notin C_j) \end{cases} \quad (4)$$

ここで、雑草、作物のクラスラベルはそれぞれ $j = 0, 1$ で表す。 n はプロブの総数、 m は作物クラスに割り当てられたプロブの数、 w_{ij} はクラスラベルの割り当てを表す係数、 x_i は i 番目のプロブの特徴ベクトル、 μ_j は j 番目のクラスのセントロイド、 d_l は作物クラスに割り当てられたプロブのうち l 番目と $l+1$ 番目のプロブの作物列方向の重心間距離、 \bar{d} は d_l の平均値、 C_j はクラス j に分類されたプロブの特徴ベクトル x_i の集合である。

式(3)の第1項は特徴量空間における各クラスのばらつきを程度を表す。第1項の目的は、前節で述べた k-means 法の結果を保存することである。第2項は作物プロブの画像上における作物列方向の間隔のばらつきを程度を表す。第2項の目的は、画像上で等間隔に存在する植物を作物に、そうでない植物を雑草に分類することである。式(3)ではこの2項の和をとることによって、k-means 法の結果をある程度保存しつつ、等間隔に存在する植物だけを作物へ分類し直す。

なお、第2項では \bar{d} による正規化を行っている。この正規化を行わない場合には、 d_l を小さくするようにクラスラベルを割り当てるほど第2項の値が小さくなる傾向が生じる可能性がある。具体的には、作物列上に多くの雑草が存在する場合に、雑草に作物ラベルを付与することによって第2項を小さくする方向へ探索が進む可能性がある。第2項では \bar{d} による正規化を行うことで、 \bar{d} の値の大小による影響を消去し、その問題に対処している。

また、本処理では作物クラスに割り当てられたプロブの数 m が2以下とならないよう制約を設ける。これは、 m が2以下の場合には第2項が0となるため、この制約を設けない場合には作物への割り当てを少なくする方向へ探索が進む可能性があるためである。ほ場における作物の間隔の設計値は事前に知ることができる。したがって、3株以上の作物が撮影範囲に含まれるようにカメラ位置を定めることは可能である。

ここで一例として、2.4節の k-means 法による分類結果において1つのプロブの分類結果を作物から雑草に変更した場合の目的関数の変化について説明する。k-means 法では、各データ点とセントロイドの距離が最小になるようにクラスタリングが行われる。したがって、式(3)の第1項は2.4節の k-means 法によって最小化されている。そのため、ある1つのプロブのクラスを変更すると、第1項の値は増加する。しかし、その変更によって作物クラスに属する植物の画像上での間隔のばらつきが小さくなると、その分だけ第2項の値は減少する。このとき、第2項の減少分が第1項の増加分がよりも大きければ、変更後の個体は変更前よりも優れた個体となる。

初期集団には、2.4節の分類結果を一定の確率でビット反転した個体、及び2.4節の分類結果を全て反転した後、一定の確率でビット反転した個体を半数ずつ用いる。2.4節の分類結果を初期集団に用いる理由は、完全にランダムな割り当てよりも2.4節の



Fig. 7 Image acquisition system




Fig. 8 Shape parameters of artificial weed

Table 1 Shape parameters of artificial weed

Parameter	Uniform shape		Small variation		Large variation	
	Min	Max	Min	Max	Min	Max
N_{leaves}	6	6	5	7	2	10
ϕ	60	60	40	80	0	360
l	5	5	3	7	1	9
s	1	1	1	2	1	3

分類結果のほうが目的とする結果に近いと考えられるためである。また、初期集団の半数に2.4節の分類結果を全て反転した個体を用いる理由は、2.4節の処理では雑草数が少ない場合に誤ったクラス割り当てを行う可能性があるためである。

3. 実験

3.1 実験の概要

第1章において、先行研究には雑草の数と形状のばらつきに対する頑健性の問題があることを述べた。本研究では、その問題に対する提案手法の有効性を検証するため、2つの実験を行った。

第1の実験では雑草の数、形状のばらつきに関する多様な条件下での提案手法の頑健性を検証した。この実験ではキャベツほ場で撮影した画像に対して人工的な雑草（人工雑草）を描画し、雑草の数、形状特徴のばらつきが異なる13種の条件を設けた。そして、各条件で作成した画像に対して、作物の直線的な配置だけを利用する方法、Otaらの手法¹⁵⁾、提案手法を適用し、結果を比較した。

第2の実験では、人工雑草ではなく実際の雑草が多く存在する画像に対する提案手法の性能を評価した。第1の実験と同様、作物の直線的な配置だけを利用する方法、Otaらの手法¹⁵⁾、提案手法を適用し、結果を比較した。

3.2 雑草の数と形状のばらつきに対する頑健性の検証

3.2.1 実験方法

本実験の目的は、雑草の数、形状のばらつきに対する提案手法の頑健性の検証である。本実験では、キャベツほ場で撮影した画像に人工雑草を描画することで雑草の数、形状特徴のばらつきが異なる13種の条件を設け、提案手法の性能を評価した。

画像の撮影に使用した装置を図 7 に示す。この装置は作物列をまたいで走行する除草ロボットを想定し製作したものである。アルミ製の収穫台車に RGB-D カメラ (Intel Realsense D415) を取り付けた構成になっている。

撮影は農研機構農業機械研究部門内のキャベツほ場において行った。キャベツは間隔が 30cm になるよう移植した。撮影範囲に重複のないよう 26 枚の画像を撮影した。

RGB 画像に対し、雑草の数に関する 4 条件、形状のばらつきに関する 3 条件の組み合わせによる計 12 条件で人工雑草を描画した。これに加えて、人工雑草を描画しない条件も設けた。人工雑草の数は 200, 400, 600, 800 個の 4 条件とした。形状のばらつきは、全て同一形状 (Uniform shape), ばらつき小 (Small variation), ばらつき大 (Large variation) の 3 条件とした。人工雑草の形状は葉数 N_{leaves} , 葉長 l , 葉の間隔 ϕ_i , スケール s の 4 種のパラメータによって定めた (図 8)。パラメータの値は上限値と下限値の間からランダムに抽出した。抽出の確率分布は一様分布とした。形状のばらつきに関する 3 条件における各パラメータの上限値と下限値を表 1 に示す。人工雑草は他の植物と重ならないように描画した。人工雑草を描画した画像の例を図 9, 図 10 に示す。

各条件で作成した画像に対し、作物の直線的な配置だけを利用する方法, Ota らの手法¹⁵⁾, 提案手法を適用し、結果を比較した。作物の直線的な配置だけを利用する方法では、作物列上の全てのプロブを作物に分類した。作物検出の性能評価は Precision, Recall, F1 score によって行った。Precision, Recall, F1 score の算出式は以下の通りである。

$$\text{Precision} = \frac{TP}{TP+FP}, \quad (5)$$

$$\text{Recall} = \frac{TP}{TP+FN}, \quad (6)$$

$$\text{F1} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (7)$$

式(5)~(7)において TP は True Positive, FP は False Positive, TN は True Negative, FN は False Negative であり, TP は作物を作物として検出した結果, TN は雑草を雑草として検出した結果である。式(5)~(7)において TP は True Positive, FP は False Positive, TN は True Negative, FN は False Negative である。

3.2.2 結果と考察

各条件における作物検出の評価指標の値を図 11 に示す。図 11 の(a), (b), (c)はそれぞれ Precision, Recall, F1 score の結果であ

る。また、左、中、右列は形状特徴のばらつきに関する 3 条件であり、順に Uniform shape, Small variation, Large variation の結果である。

総合的な評価を示す F1 score (図 11(c)) は, Uniform shape の雑草数 800 の条件を除く全ての条件で提案手法が最も高い値となった。このことから、提案手法は直線的な配置だけを利用する方法, Ota らの手法¹⁵⁾よりも雑草の数, 形状のばらつきに対して頑健であることが示された。

Precision (図 11(a)) は, Uniform shape の雑草数 600, 800, 及び Small variation の雑草数 800 を除く全ての条件で提案手法が最も高い値となった。このことから、提案手法によって検出された作物が実際に作物である割合は、他の 2 手法に比べて高い傾向にあることが示された。

Recall (図 11(b)) は、全ての条件で作物の直線的な配置だけを利用する方法が最も高く、その値は全て 1.0 であった。これは、作物列直線上の植物を全て作物に分類したことにより作物の見落としが生じなかったためである。しかし、この方法では作物列直線上の雑草も全て作物として検出してしまう。それらの雑草は除草ロボットで除去できないため、実用上大きな問題である。提案手法と Ota らの手法¹⁵⁾の比較では、全ての条件で提案手法が Ota らの手法¹⁵⁾を上回る値となった。このことから、提案手法では等間隔性を利用した結果の更新を行うことによって Ota

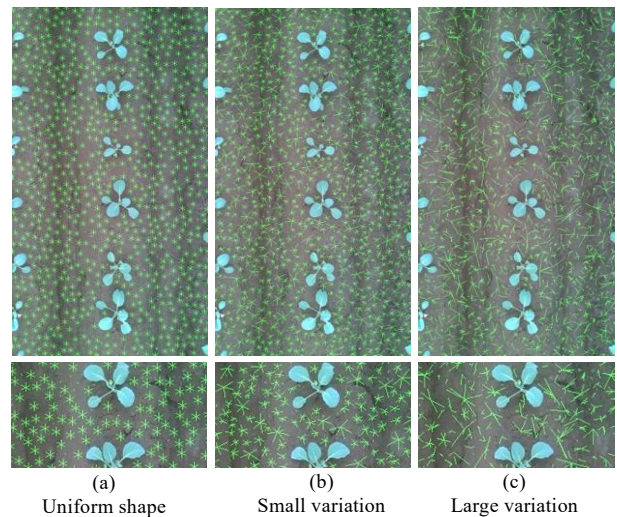


Fig. 9 Artificial weeds with different shape variation (Enlarged images are shown in bottom row)




Fig. 10 Artificial weeds with different amount

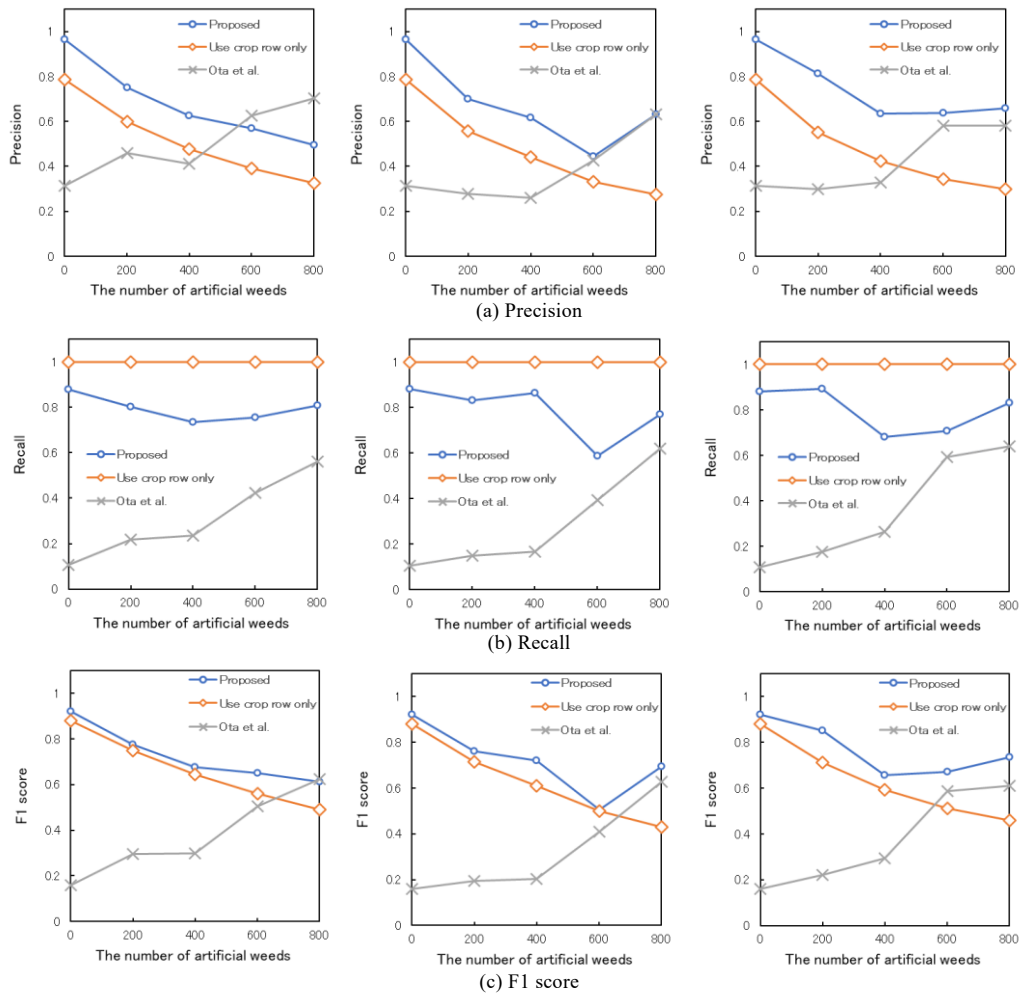


Fig. 11 Results of crop detection
(Left: Uniform shape, Center: Small variation, Right: Large variation)





Fig. 12 Detection results
(Green represents crop. White represents weed)

らの手法¹⁵⁾よりも作物の見落としを少なくできたことが示された。

本実験における結果の例を図12に示す。図12では、Otaらの手法¹⁵⁾では誤って雑草クラスに分類されていた作物が、提案手法では作物クラスに正しく分類されたことが分かる。この結果から、提案手法で用いた等間隔性を考慮した分類結果の更新が

性能向上に有効であると考えられる。

なお、各画像の分類結果を詳細に観察すると、結果の改善が生じなかった画像も一部確認された。例えば、図13の画像では、黄色の矢印で示した箇所においてOtaらの手法¹⁵⁾では正しく分類されていた複数の雑草が、提案手法では誤って作物に分類された。この原因は、遺伝的アルゴリズムによる探索の過程で一部



(a) Ota et al. (2022)¹⁵⁾ (b) Proposed method
Fig. 13 Detection results
 (Green represents crop. White represents weed)

の雑草に作物ラベルが付与された結果、式(3)における \bar{d} の値が作物の真の間隔よりも小さくなり、その \bar{d} に間隔が収束するようさらに多くの雑草が作物に誤分類されたためと考えられる。

本実験では、キャベツほ場で撮影した画像に対して雑草の数、形状特徴のばらつき異なる13通りの条件で雑草を描画し、提案手法の有効性を検証した。その結果、一部の画像を除いて分類結果は改善され、総合的な評価を表すF1 scoreはほぼ全ての条件で提案手法が最も高い結果となった。このことから、提案手法では雑草の数、形状のばらつきに対する頑健性が向上したことが示された。

3.3 実際の雑草での性能検証

3.3.1 実験方法

本実験の目的は、実際の雑草が存在する画像に対する提案手法の性能評価である。本実験で用いる画像は、3.2節の実験で用いた撮影装置(図7)と同様の装置を用いて群馬県農業技術センター高冷地野菜研究センターと埼玉県にある農研機構農業機械研究部門において撮影した。2つの画像データセットには多様な天気、時間帯において撮影した画像が含まれている(表2)。撮影を実施したほ場の外観を図14に示す。このほ場では定植以降除草作業を実施しておらず、ほ場には多くの雑草が存在した。

画像に対し、Otaらの手法¹⁵⁾、提案手法を適用し、結果を比較した。なお、乱数種による遺伝的アルゴリズムの結果のばらつきを検討するため、10通りの異なる乱数種で実験を行った。なお、提案手法とOtaらの手法¹⁵⁾におけるk-means法の乱数種は一定とした。評価指標は3.2節と同様とした。

3.3.2 結果と考察

実験の結果得られたF1 scoreと、乱数種による結果のばらつきを表3に示す。総合的な評価を示すF1 scoreは、群馬データセットでは提案手法がOtaらの手法¹⁵⁾を上回った。一方、埼玉データセットでは、2つの撮影条件で提案手法がOtaらの手法¹⁵⁾を上回ったものの、残る3つの撮影条件で逆にOtaらの手法¹⁵⁾が提案手法を上回った。乱数種による遺伝的アルゴリズムの結果のばらつきは小さかった。

本実験における入力画像と出力画像の例を図15に示す。図15a, d)では、Otaらの手法¹⁵⁾では作物に誤分類された雑草が、提案手法では適切に雑草に分類されたことがわかる(白矢印)。また、図15b)では、Otaらの手法¹⁵⁾によって得られた適切な分類結果が、提案手法でも変わらなかったことがわかる。これらの結果から、提案手法では作物の等間隔な配置を利用することで、



Fig. 14 Appearance of cabbage

Table 2 Dataset


Dataset name	Date	Time	Days after planting	Weather	Number of images
	2022/7/21	10 a.m.	14	Sunny	76
	2022/8/27	7 a.m.	3	Cloudy	60
	2022/8/30	6 a.m.	6	Cloudy	60
Saitama dataset	2022/9/2	6 a.m.	9	Cloudy	60
	2022/9/2	2 p.m.	9	Cloudy	60
	2022/9/3	5 p.m.	10	Sunny	60

Table 3 F1 score


Dataset name	Date	Proposed		Ota et al. ¹⁵⁾	
		Mean	S.D.	Mean	S.D.
Gunma dataset	2022/7/13	0.905	0.0093	0.848	0
	2022/7/21	0.713	0.0111	0.665	0
	2022/8/27	0.519	0.0070	0.467	0
	2022/8/30	0.466	0.0150	0.416	0
Saitama dataset	2022/9/2	0.467	0.0187	0.551	0
	2022/9/2	0.437	0.0160	0.524	0
	2022/9/3	0.449	0.0176	0.508	0

Otaらの手法¹⁵⁾の分類結果を改善する効果があることが示された。


なお、埼玉データセットの一部撮影条件において提案手法がOtaらの手法¹⁵⁾を下回った原因は、図15c)のように作物の画像上での間隔のばらつきが比較的大きかったことが考えられる。またその原因は、埼玉データセットで使用した苗が軟弱徒長の傾向にあり、大きく傾いた作物が多く発生したためと考えられる。このような状態は栽培の観点からも回避すべきものである。




a) Gunma, 2022/7/13 11a.m.



b) Gunma, 2022/7/21 10a.m.



c) Saitama, 2022/9/2 6a.m.



d) Saitama, 2022/9/3 5p.m.

Fig. 15 Crop Detection Results (Green represents crop, magenta represents weed)

ため、発生頻度は高くないが、一部には存在する可能性もある。このような状態に対しては、提案手法は十分な効果を発揮しない場合があると考えられた。

それ以外の課題として、作物と雑草が画像上で重なっているときに、それらが1つのプロブとして検出されてしまう場合があった。その一例は、図15d)に見られる。この事象が生じると、重なった雑草を作物と誤検出、あるいは逆に作物を雑草と誤検出し、結果として作物の位置を正確に検出できなくなる。この問題については、RGB画像からエッジを検出して入力画像に重ね合わせる方法や、楕円形に近いという葉の形状に関する事前知識を利用することで解決可能と考えられる。

続いて、日照条件の影響について考察する。本実験で使用したデータセットには、撮影時間や天気の影響によって多様な日照条件で撮影した画像が含まれている。図15に例示するように、それらの画像に対する二値化による植物領域抽出は問題なく行われた。提案手法のその後の処理では輝度値を使用しない。分類で使用する形状特徴、プロブの間隔は日照条件の影響を受けない。したがって、本手法は日照条件による影響を受けにくいと考えられる。

各世代において最も適応度の優れた個体の適応度の典型的な例を図16に示す。図16では、いずれの乱数種においても世代交代の反復に伴って適応度が減少し、最終的には変化がなくなって計算終了したことがわかる。表3に示したように、最終的なF1スコアのばらつきが小さかったことから、設定した個体数や世代数、交叉確率、突然変異率には問題がなく、適切に解の更新が行われたと考えられる。

収束に至るまでの世代数のパレート図を図17に示す。この図の棒グラフは、0~100世代までを5世代ごとの区間に分割し、各区間において計算終了した画像数をカウントしたものである。

また、折れ線グラフはその積算値が全体に占める割合を示したものである。図17から、本実験では約90%の画像が20世代までに収束し、全ての画像が70世代までに収束したことが示された。この結果から、遺伝的アルゴリズムにおいて最大の世代数を100としたことは妥当であったといえる。

提案手法の処理時間は、全入力画像の平均で14sであった。各ステップの平均処理時間は、二値化は0.001s、作物列検出は1.57s、k-means法は0.03s、遺伝的アルゴリズムは12.22sであった。

本実験では、実際の雑草が存在する画像に提案手法を適用し、提案手法の有効性を検証した。その結果、一部の撮影条件においては提案手法による結果の改善が確認されなかったものの、Otaらの手法¹⁵⁾の分類結果を改善する効果があることが示された。

3.4 遺伝的アルゴリズムの設定の検討

3.4.1 実験方法

本実験では、提案手法で用いた遺伝的アルゴリズムの設定の妥当性検討を目的とした。具体的には、初期集団をk-means法の結果に基づいて生成することが、初期集団を完全にランダムな割り当てで生成するよりも計算時間や最終的な解の観点から優れていることを検証した。

遺伝的アルゴリズムの初期集団をk-means法の結果に基づいて初期集団を生成する場合、完全にランダムな割り当てで初期集団を生成する場合の2通りの条件で表2のデータセットを処理し、計算終了世代の分布と最終的なF1スコアを比較した。

3.4.2 結果と考察

図18にGAの初期集団を完全にランダムな割り当てで設定した場合に計算終了した世代数のパレート図を示す。図

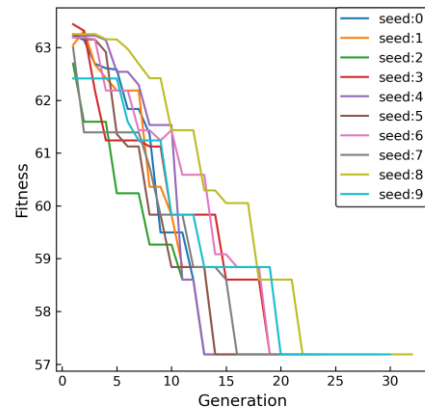


Fig. 16 Fitness of the best individual




Fig. 17 Pareto chart of final generation in proposed method




Fig. 18 Pareto chart of final generation in randomized initial population

Table 4 F1 score

	Proposed	Random
Gunma	0.809	0.577
Saitama	0.460	0.346

18から、約90%の画像が40世代までに収束し、全ての画像が90世代までに収束したことが示された。この結果を3.3節の実験で得た提案手法の結果(図17)と比較すると、提案手法では完全にランダムな割り当てで初期集団を生成した場合と比較して早い段階で収束に到達したことがわかる。したがって、k-means法を前段階に用いることによって、より早い段階で収束に到達し計算時間を短縮できる効果があることが示された。

また、k-means法の結果に基づいて初期集団を設定した場合(提案手法)と、k-means法を用いずGAの初期集団

Table 5 F1 score of different shape features

location	area	perimeter	aspect	roundness	elongation	PTAL	solidity	F1 score
Gunma	1	0	0	0	0	0	0	0.720
	0	1	1	1	1	1	1	0.743
	1	0	1	1	1	1	1	0.767
	1	1	0	1	1	1	1	0.796
	1	1	1	1	0	1	1	0.793
	1	1	1	1	1	0	1	0.797
	1	1	1	1	1	1	0	0.803
	1	1	1	1	1	1	1	0.770
Saitama	1	1	1	1	1	1	1	0.799
	1	0	0	0	0	0	0	0.397
	0	1	1	1	1	1	1	0.442
	1	0	1	1	1	1	1	0.433
	1	1	0	1	1	1	1	0.482
	1	1	1	1	0	1	1	0.471
	1	1	1	1	1	0	1	0.482
	1	1	1	1	1	1	0	0.445
1	1	1	1	1	1	1	0.459	
1	1	1	1	1	1	1	0.457	

を完全にランダムな割り当てで設定した場合の F1 スコアの結果を表 4 に示す。群馬データセットの F1 スコアは、提案手法では 0,809, 完全にランダムな割り当てで初期集団を設定した場合には 0.577 となり、提案手法が上回る結果となった。埼玉データセットの F1 スコアは、提案手法では 0.460, 完全にランダムな初期集団を設定した場合には 0.346 となり、こちらも提案手法が上回る結果となった。これらの結果から、提案手法では、完全にランダムな割り当てで初期集団を設定した場合よりも F1 スコアが大きくなることが示された。

k-means 法をベースに用いた方が、最終的な解のスコアが良くなる理由は、誤分類が含まれるとしても、ある程度の正しきで作物と雑草に事前分類することによって、式(3)に含まれる間隔の平均値 \bar{d} として、真の作物の間隔に近いものが得られるためだと考えられる。k-means 法によるクラスタリングを事前に用いず、完全にランダムな割り当てで初期集団を生成した場合には、GA の開始時点で作物の間隔の平均値 \bar{d} として、真の作物の間隔と大きく異なる値が得られる可能性が高くなる。 \bar{d} の値は、クラスラベルの割り当て方を更新することで更新されるが、初期の \bar{d} として真の作物の間隔と大きく異なる値を用いた場合には、その \bar{d} の周辺に間隔のばらつきを小さくするように探索が進んでしまい、結果として適切な分類が行われない場合があると考えられる。

以上の結果から、初期集団を k-means 法の結果に基づいて生成することは、計算量の低減と最終的な分類性能の 2 つの観点から有効であることが示された。

3.5 形状特徴の検討

3.5.1 実験方法

提案手法で使用する形状特徴の妥当性検証を目的に実験を行った。本実験では、面積のみを使用、6 種の形状特徴を使用、6 種類のうち 1 種類だけを使わない (6 通り) の 8 通りの条件で実験を実施し、F1 スコアを比較した。

3.5.2 結果と考察

結果を表 5 に示す。群馬データセット、埼玉データセットの両方で、面積だけを使用した場合に F1 スコアが最も小さくなった。この結果から、特徴量には面積だけでは不十分であることが示された。

一方、逆に 6 種類のうち面積だけを使用しない場合の F1 スコアは、群馬データセットでは下から 2 番目、埼玉データセットでは下から 3 番目であった。この結果から、形状特徴として面積だけでは不十分ではあるものの、面積は重要な適切な分類のために大きな効果を発揮していることが示された。

それ以外の条件に関しては、群馬データセットでは F1 スコアが高かったものから順に PTAL を使用しない場合、全ての特徴量を使用する場合、elongation を使用しない場合となった。一方埼玉データセットでは、aspect を使用しない場合、elongation を使用しない場合、roundness を使用しない場合となった。つまり、elongation を使用しない場合には両方のデータセットで性能が高くなる傾向があったが、それ以外の特徴量に関しては統一的な傾向が表れなかった。このことから、作物と雑草の分類に効果的な特徴量の種類は、雑草の種類や作物・雑草の生育度合いによって変わると考えられる。雑草の種類や生育ステージの事前予測は困難であることから、実用を考慮すると、提案手法のようにある程度多様な形状特徴を使用することは重要であると考えられる。

4. 結 論

本研究では、雑草の数と形状特徴のばらつきに対して頑健な作物検出手法を提案した。提案手法では、従来手法の結果を基に、作物の等間隔性を考慮した更新処理を行った。更新処理は、作物・雑草各クラス内の形状特徴のばらつきを小さくすると同時に、作物クラスの画像上での間隔が均一に近づくよう最適化することで行った。最適化には、画像から検出した各植物プロブへのクラスラベルの割り当て方を個体とする遺伝的アルゴリズムを用いた。

提案手法の有効性を検証するため、人工雑草と実際の雑草の種類別の画像データを用いて実験を行った。人工雑草を用いた実験では、キャベツほ場で撮影した画像に対して雑草の数、形状特徴のばらつき異なる 13 通りの条件で雑草を描画し、提案手法を適用した。その結果、ほぼ全ての条件で従来手法を上回る性能が得られた。この結果から、提案手法は雑草の数、形状特徴のばらつきに対して従来手法よりも優れた頑健性を有することが示された。

実際の雑草を用いた実験では、多様な天気、時間帯において撮影した、実際の雑草が含まれる 2 つの画像データセットに提案手法を適用した。その結果、一部の画像では性能の改善が生じない場合もあったものの、提案手法は従来手法の性能を改善する効果があることが示された。この結果から、実際の雑草が存在する画像に対しても、作物の等間隔性を利用することによって分類性能を向上できることが示された。

今後、本手法の実用化に向けては、作物、雑草、土壌等に関するより多様な条件下での性能検証を実施する必要がある。

謝 辞

本研究は、農林水産省「国際競争力強化技術開発プロジェクト（課題名：AI を活用したスマート除草システムの開発）」の支援を受けた。

参 考 文 献

- 1) European Commission: Communication from the Commission to the European Parliament, the European Council, the Council, the European Economic and Social Committee and the Committee of the Regions the European Green Deal (2019).
- 2) 浮穴学宗: みどりの食料システム戦略とレギュラトリーサイエンスの推進. *All about Swine*, **59** (2021) 15.
- 3) United States Department of Agriculture: Agriculture Innovation Agenda: Year One Status Report (2020).
- 4) B. L. Steward, J. Gai, and L. Tang: The Use of Agricultural Robots in Weed Management and Control. Burleigh Dodds Science Publishing, Cambridge, UK, (2019) 4.
- 5) N. D. Tillett, T. Hague, A. C. Grundy, and A. P. Dedousis: Mechanical Within-row Weed Control for Transplanted Crops Using Computer Vision. *Biosystems Engineering*, **99**, 2 (2008) 171.
- 6) H. W. Griepentrog, M. Nørremark, and J. Nielsen: Autonomous Intra-row Rotor Weeding Based on GPS. *Proceedings of the CIGR World Congress*, (2006).
- 7) J. Gai, L. Tang, and B. L. Steward: Automated Crop Plant Detection Based on the Fusion of Color and Depth Images for Robotic Weed Control. *Journal of Field Robotics*, **37** (2020) 35.
- 8) A. Wang, W. Zhang, and X. Wei: A Review on Weed Detection Using Ground-based Machine Vision and Image Processing Techniques. *Computers and Electronics in Agriculture*, **158** (2019) 226.
- 9) A. S. M. M. Hasan, F. Sohel, D. Diepeveen, H. Laga, and M. G. K. Jones: A Survey of Deep Learning Techniques for Weed Detection from Images. *Computers and Electronics in Agriculture*, **184** (2021) 106067.
- 10) F. Ahmed, H. A. Al-Mamun, A. S. M. H. Bari, E. Hossainm, and P. Kwan: Classification of Crops and Weeds from Digital Images: A Support Vector Machine Approach. *Crop Protection*, **40** (2012) 98.
- 11) A. I. B. Parico and T. Ahamed: An Aerial Weed Detection System for Green Onion Crops Using the You Only Look Once (YOLOv3) Deep Learning Algorithm. *Engineering in Agriculture, Environment and Food*, **13**, 2 (2020) 42.
- 12) A. Wendel and J. Underwood: Self-supervised Weed Detection in Vegetable Crops Using Ground Based Hyperspectral Imaging. *Proceedings of the 2016 IEEE International Conference on Robotics and Automation* (2016) 5128.
- 13) M. Louargant, G. Jones, R. Faroux, J. Paoli, T. Maillot, C. Gée, and S. Villette: Unsupervised Classification Algorithm for Early Weed Detection in Row-crops by Combining Spatial and Spectral Information, *Remote Sensing*, **10**, 5 (2018) 1.
- 14) M. D. Bah, A. Hafiane. and R. Canals: Weeds Detection in UAV Imagery Using SLIC and the Hough Transform. *Proceedings of the 2017 Seventh International Conference on Image Processing Theory, Tools and Applications* (2017) 1.
- 15) K. Ota, J. Y. L. Kasahara, A. Yamashita and H. Asama: Weed and Crop Detection by Combining Crop Row Detection and K-means Clustering in Weed Infested Agricultural Fields, *Proceedings of the 2022 IEEE/SICE International Symposium on System Integration* (2022) 985.
- 16) B. Melander, B. Lattanzi, and E. Pannacci: Intelligent versus Non-intelligent Mechanical Intra-row Weed Control in Transplanted Onion and Cabbage. *Crop Protection*, **72** (2015) 1.
- 17) N. Otsu: Threshold Selection Method from Gray-Level Histograms, *IEEE Transaction on Systems, Man, and Cybernetics*, **9**, 1 (1979) 62.
- 18) W. Kesheng, E. Otoo, and K. Suzuki: Optimizing Two-Pass Connected-Component Labeling Algorithms, *Pattern Analysis and Applications* **12**, 2 (2009) 117.
- 19) 太田 薫平, ルイ笠原 純ユネス, 山下 淳, 浅間 一: 雑草の多い条件下における作物・雑草検出のための RGB-D カメラを用いた作物列検出, *ビジョン技術の実利用ワークショップ講演論文集 (ViEW2021)* (2021) 75.
- 20) S. I. Cho, D. S. Lee, and J. Y. Jeong: Weed-plant Discrimination by Machine Vision and Artificial Neural Network. *Biosystems Engineering*, **83**, 3 (2002) 275.