

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

○太田 薫平[‡], ルイ笠原 純ユネス[†], 山下 淳[†], 浅間 一[†]

[†]: 東京大学大学院 工学系研究科 精密工学専攻

[‡]: 農業・食品産業技術総合研究機構 農業機械研究部門

otakumpei@robot.t.u-tokyo.ac.jp

概要: 雑草の多い条件下でも作物・雑草検出を行うため, 深度データを使用した作物列検出手法を提案する. 具体的には, 地表面の深度データに畝形状を模した曲面をフィッティングすることで畝位置を検出し, その中央線を作物列として検出する. キャベツ畑で撮影した RGB-D 画像に人工的な雑草を描画し, 提案手法を適用することで有効性を示した.

<キーワード> RGB-D 画像, フィッティング, 農業

1. 序論

農業では病虫害や雑草の防除を目的として農薬が一般的に使用されている. しかし, 近年は環境影響等の懸念から農薬使用量の低減が世界各地で推進されている[1, 2]. 農薬の使用量を低減する方法として農薬の局所散布, 機械除草がある. しかし, 局所散布, 機械除草を人力で行うには莫大な労働力を要するため, 自動化が必要である. そのために, 作物・雑草検出は不可欠な技術である.

作物・雑草検出に取り組んだ研究として, Wendelら[3], Louargantら[4], Bahら[5]の研究がある. これらの研究はいずれも, 作物は直線的に整列しており, 一方雑草は不規則に存在することを事前知識として利用した. 具体的には, 植物領域を抽出した2値画像(植物2値画像)にハフ変換を適用し, 作物列検出を行った. そして, 作物列上のピクセル又はプロブを作物, 作物列と離れたピクセル又はプロブを雑草と自動ラベリングし, 教師あり学習モデルを訓練することで作物・雑草検出を行った.

作物配置の規則性を利用したこれらの手法は, 作物と雑草の種類や生育段階にかかわらず使用できる点が特長である. しかし, 雑草が多く存在するとき, 植物2値画像にハフ変換を適用しても正確な作物列検出ができない. また, 正確な作物列検出ができない場合, 訓練データに誤ったラベル付けをしてしまい, 訓練データの質が低下する問題がある. この問題を解決するためには, 雑草が多く存在する条件下でも使用可能な作物列検出手法が必要である.



(a)



(b)



(c)

図1 対象とする畑の一例
(a) 外観, (b) 作物列のRGB画像,
(c) 作物列の深度画像

そこで本研究では, 雑草が多く存在する条件下で使用可能な作物列検出手法の開発を目的とする. そのために, 本研究では地表面の深度データに畝形状を模した曲面をフィッティングする手法を提案する. 曲面フィッティングにより畝位置を検出し, その中央線を作物列として検出する.

2. 提案手法

本研究では, 作物列検出における雑草量の影響を低減するため, 地表面の深度データを利用して作物列検出する手法を提案する. 具体的には, 1畝1条植えの場合には作物列は畝の中央に存在することに注目し, 深度データを用いて畝を検出することで作物列を検出する手法である. 雑草が多く存在しても, 隙間から露出する土壌表面の深度データを利用することで作物列検出が可能と考えた. 対象として想定する畑の一例を図1に示す.

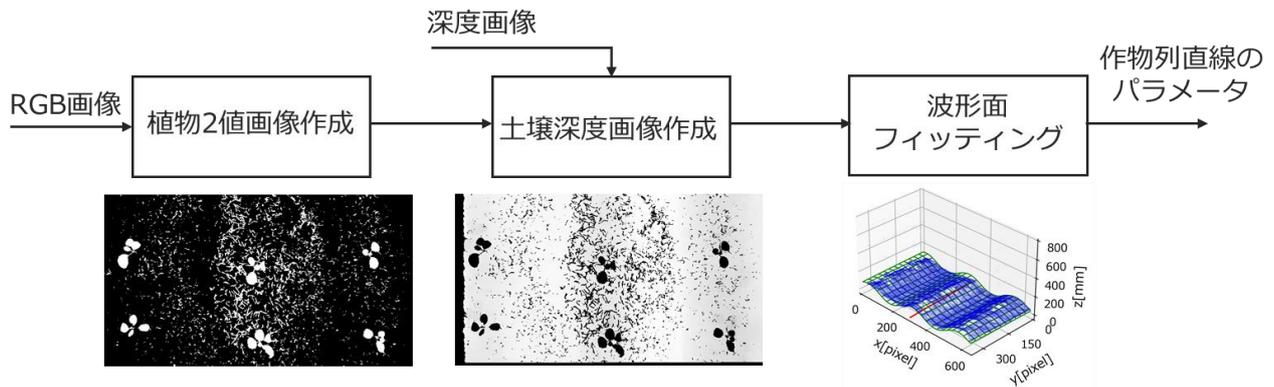


図2 提案手法の概略

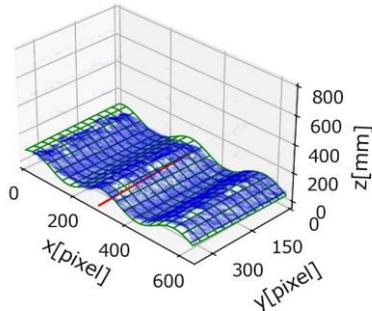


図3 波形面フィッティングによる作物列検出

(x, y は画像上の座標, z は高さ,
青のプロットは実際の深度画像のデータ,
緑の格子面はフィッティングした波形面,
赤線はフィッティングで取得した直線)

提案手法の概略を図2に示す。提案手法は、植物2値画像作成、土壌深度画像作成、波形面フィッティングの3段階からなる。植物2値画像作成では、RGB画像のRチャンネルに対して大津の方法[6]を適用することで植物と背景の土壌を分離する閾値を定め、画像の2値化を行う。続いて、土壌領域の深度データだけを利用するため、植物2値画像を深度画像に重ねて土壌領域だけを抽出した深度画像(土壌深度画像)を作成する。そして、土壌深度画像に対して波形面フィッティングを行う(図3)。

フィッティングに用いる波形面は以下の式(1), (2)で得られる1次元の波形を画像の y 軸方向に走査することで形成する。

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

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

x, y は画像上の座標, z は深度を表す。 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4)。このフィッティングで得られる作物列直線のパラメ

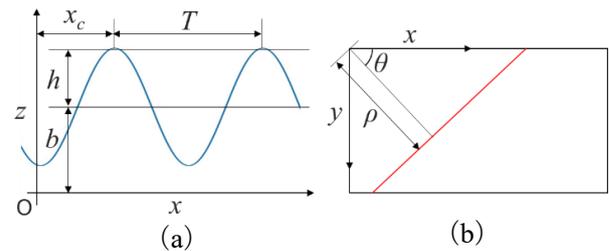


図4 波形面の各パラメータ

(a) 式(1)のパラメータ, (b) 式(2)のパラメータ

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。

3. 実験

提案手法が雑草量の影響を受けにくいことを検証するため、キャベツ畑で撮影した画像に提案手法を適用した。画像は2021年7月16日に群馬県高冷地野菜研究センターのキャベツ畑で撮影した。キャベツは6月7日に播種され、7月7日に畑に移植された。除草作業は行っておらず、畑には多くの雑草が存在した(図5)。撮影は、収穫台車にRGB-Dカメラ(Intel RealSense D415)を下向きに取り付け、手押しで走らせて実施した(図6)。画像は縦幅360 pixel, 横幅640 pixelで取得した。

異なる雑草量の条件を模擬的に再現するため、植物2値画像に人工的な雑草(人工雑草)を描画した。人工雑草は半径3ピクセルの円とし、ランダムな位置に描画した。人工雑草描画後の画像全体に占める植物領域の面積割合(被覆率)を5条件(50, 60, 70, 80, 90%)設定した。

作物列検出の精度を検証するため、提案手法で取得した作物列直線と、人間が深度画像を目視して描画した作物列直線の ρ, θ を比較した。なお、畝が画像の周縁部に存在し、途中で途切れている場合には目視による作物列の特定が困難であった



図 5 キャベツ畑の外観



図 6 データ取得機器

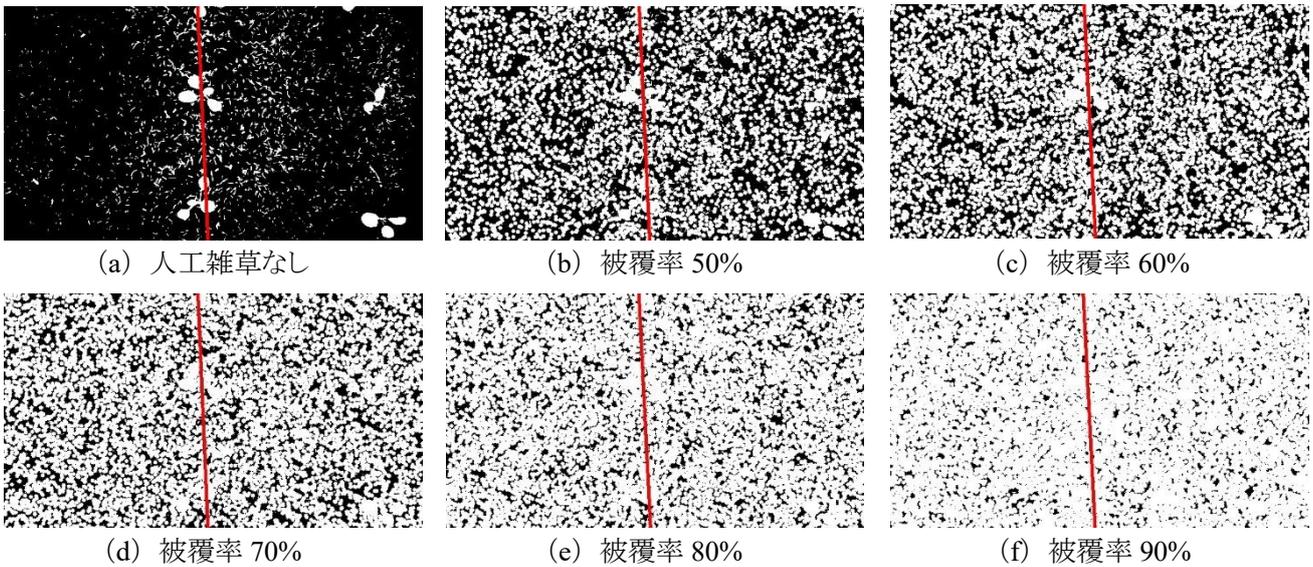


図 7 作物列検出結果の例

表 1 提案手法で取得したパラメータと真値との比較結果. 各画像における推定値と真値の差の絶対値を平均した値を示す.

被覆率 [%]	ρ [pixel]	θ [deg]
26 (人工雑草なし)	7.5	1.1
50	7.3	1.5
60	7.7	1.6
70	7.6	1.5
80	7.4	1.5
90	8.0	1.5

め, ここでは画像の中央に最も近い作物列だけを精度検証の対象とした. 供試画像は, 1列の畝を始端から終端まで走行して撮影した画像系列を 1秒間隔で抜き出した 30枚とした.

提案手法による作物列検出と真値との比較結果を表 1 に示す. また, 提案手法による作物列検出

結果の例を図 7 に示す. 提案手法で得られた ρ , θ の真値との差の絶対値は, 全ての条件で各 7.3 pixel から 8.0 pixel, 1.1 deg から 1.6 deg の範囲内であった. これらの値は十分小さく, 異なる条件間での変動もほとんどないことから, 提案手法は雑草量の影響を受けにくいことが示された.

4. 結論

雑草が多く存在する場合でも使用可能な作物列検出手法を提案した. 提案手法では, 土壌領域だけを抽出した深度画像に対して波形面をフィッティングすることで, 作物列直線のパラメータを取得する方法を用いた. 実際のキャベツ畑で撮影した画像に人工雑草を描画して提案手法を適用し, 提案手法は雑草量による影響を受けにくいことを示した.

今後は, 1つの畝に複数列の作物列が存在する場合や畝が直線状ではない場合に対応する方法を検討する必要がある.

参考文献

- [1] An Official Website of the European Union: Farm to Fork Targets – Progress[web page],
URL:https://ec.europa.eu/food/plants/pesticides/sustainable-use-pesticides/farm-fork-targets-progress_en, accessed: 2021-10-21.
- [2] 農林水産省: みどりの食料システム戦略～食料・農林水産業の生産力向上と持続性の両立をイノベーションで実現～,
URL:<https://www.maff.go.jp/j/kanbo/kankyo/seisaku/midori/attach/pdf/index-7.pdf>, accessed: 2021-10-21.
- [3] 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, pp. 5128-5135, 2016.
- [4] M. Louargant, G. Jones, R. Faroux, J. Noël, 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, vol. 10, no. 5, pp. 1-18, 2018.
- [5] M D. Bah, A. Hafiane. and R. Canals: Deep Learning with Unsupervised Data Labeling for Weed Detection in Line Crops in UAV Images, Remote Sensing, vol. 10, no. 11, pp. 1-22, 2018.
- [6] Nobuyuki Otsu: Threshold Selection Method From Gray-Level Histograms, IEEE Transaction on Systems, Man, and Cybernetics, vol. 9, no. 1, pp. 62-66, 1979.

太田薫平: 2018年3月北海道大学大学院農学院修士課程修了. 2018年4月農業・食品産業技術総合研究機構研究員. 2020年4月東京大学大学院工学系研究科博士課程入学. 農作業安全, 農業ロボットの研究に従事.

ルイ笠原純ユネス: 2019年9月東京大学大学院工学系研究科精密工学専攻博士課程修了. 博士(工学). 東京大学大学院工学系研究科精密工学専攻特任研究員を経て, 2020年10月同特任助教, 現在に至る. 機械学習, インフラ自動点検システムの研究に従事.

山下淳: 2001年3月東京大学大学院工学系研究科精密機械工学専攻博士課程修了, 博士(工学). 静岡大学助手, 助教, 准教授を経て, 2011年10月東京大学大学院工学系研究科精密工学専攻准教授, 現在に至る. 知能ロボット, コンピュータビジョン, 画像処理の研究に従事.

浅間一: 1984年東京大学大学院工学系研究科修士課程修了. 1986年理化学研究所研究員補. 同副主任研究員等を経て, 2002年東京大学人工物工学研究センター教授. 2009年同大学院工学系研究科教授. IEEE フェロー. 日本ロボット学会フェロー. 日本機械学会フェロー.