

農作物可視光画像を用いたセマンティックセグメンテーションによる 葉面上水分検出法

Leaf Surface Moisture Detection Using Semantic Segmentation of Visible-Light Images of Crops

宮倉 将[†] 竹石 光希[†] 村松 駿[‡] 吉田 孝博[†]
Sho Miyakura Mitsuki Takeishi Shun Muramatsu Takahiro Yoshida

1. はじめに

水分は農作物の成長にとって重要な要素である。葉面上に水分が付着することで、植物が利用できる水分の増加や葉面上の病原菌や汚れが除去されるなど、葉面の濡れは植物へ良い効果をもたらす[1]。一方、葉面上に水分が付着すると、葉から栄養が流出したり、葉面が長時間濡れるとその水分や高い湿度により病原菌を介して病害を誘発させたりしてしまう[1]。よって葉の濡れ具合を正確に検出することは植物を管理する上で非常に重要である。しかし葉の濡れ方は植物の種類によって異なり[2]、同種の植物の葉でもその葉の位置や大きさ、向きによって濡れ方が異なる。そのため葉面 1 枚 1 枚に付着している水分を検出し、過不足なく水を与えることは、農業の生産性向上や効率の良い水資源の活用、さらに病害予防につながる。

葉面上の水分検出についての従来手法には課題がある。熱画像やマルチスペクトル画像を用いた手法[3][4][5]では、撮影時に周囲温度や日照条件の影響を受けやすい。また画素数が限られ、撮影機器も高価という課題がある。電子センサを搭載した人工葉を用いる手法[6]では、センサ以外の全ての葉の状態を検出することができない。このように、従来研究では複数の葉面の水分一括検出が困難である。

そこで本研究では、複数の葉面に対する水分検出を一括して行うために、農作物可視光画像とセマンティックセグメンテーションを用いた水分検出法を提案する。さらに、農地における農作物以外の背景要素を排除することで葉面の水分検出精度を改善する手法も提案する。そして、水分検出精度評価実験を行い、提案手法の有効性を確かめた。

2. 提案手法

本研究では、入力画像に映ったものを画素単位で複数クラスに分類するセマンティックセグメンテーションを用いた葉面上の水分検出法を提案する。提案手法の処理構成を図 1 に示す。農作物可視光画像を画素単位で濡れ葉面、乾燥葉面、背景の 3 クラスに分類し、任意の形状の各葉面上の濡れ領域を検出する。なお、農作物の他に雑草や緑色の支柱など、農作物の葉と誤認する要素が多数存在するため、下記 2 つの対策手法も併せて提案する。

1 つ目は、雑草や支柱などの農作物以外の緑色成分の強い背景部分を新たに別クラスとして分類し、深層学習モデルの学習面から背景による誤認低下を図る手法（以降、クラス追加と記す）である。ここでは、濡れ葉面、乾燥葉面、緑色背景、それ以外の背景の 4 クラスで学習・分類を行う。

2 つ目は、図 1 のように水分検出の前処理として、DNN (Deep Neural Network) による検出対象葉面の抽出を行う処理を追加する手法（以降、葉面抽出追加と記す）である。

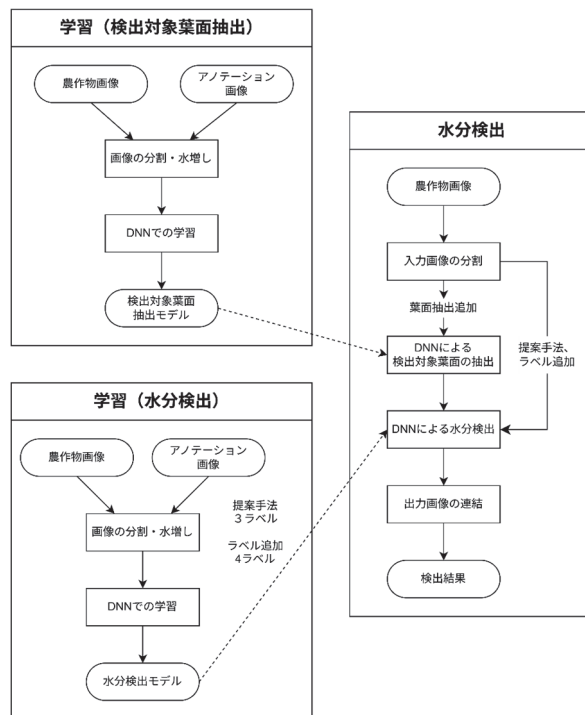


図 1 提案手法と各対策手法の処理構成

これは、各 DNN を対象葉面領域抽出と水分検出に特化させることで、深層学習モデルの構造面から改善を図る。検出対象葉面抽出部は、検出対象葉面（濡れ葉面＋乾燥葉面）、緑色背景、それ以外の背景 3 クラスで学習・分類を行い、水分検出部は、濡れ葉面、乾燥葉面、背景の 3 クラスで学習・分類する。

3. 評価方法

データセットは、農地で撮影したオクラとキュウリの農作物画像を基に作成した。葉面が乾燥した状態と、葉面を霧吹きで濡らした状態について、学習用にオクラを 2 枚ずつ、検証用にオクラとキュウリを 2 枚ずつ撮影した。撮影時の画像サイズは 4032×3024pixel である。撮影した画像について、アノテーションソフト Labelme を用いて、各クラスの領域と種類のアノテーションを目視で行った。アノテーションした画像を 200pixel シフトで縦横 1600pixel ごとに分割して、学習データセットを作成した。それに加え、画像の回転、拡大縮小、左右反転による学習画像の水増しを行い、その後、縦横 475pixel へのリサイズ、テンソル型への変換と色情報の標準化を行った。検証時にはデータの増しを行わず、縦横 475pixel へのリサイズ、テンソル型への変換と色情報の標準化のみを行った。

[†] 東京理科大学, Tokyo University of Science

[‡] 東京大学, The University of Tokyo

DNNはPyramid Scene Parsing Network (PSPNet)[7]を用い、ADE20K データセット[8]による事前学習を行った Dilated-ResNet50 モデルを基盤とし、SGD による最適化によって50エポックのファインチューニングを行った。

本研究の葉面上水分検出手法および対策手法の評価を、ADE20K データセットによる事前学習のみを行った Dilated-ResNet50 モデルによる結果との比較にて行った。

提案手法の評価には、以下3つの指標を使用した。

① MF1_{W,D} (Macro F1-score {Wet, Dry})

検出対象葉面上における水分の検出精度評価を目的として、濡れ葉面、乾燥葉面、背景の3クラスにおいて、Macro-F1 スコアを基に式(1)で定義した。

$$MF1_{\{W,D\}} = \frac{1}{2} (F1 \text{ スコア}_{\text{「濡れ」}} + F1 \text{ スコア}_{\text{「乾燥」}}) \quad (1)$$

② LSR (Leaf Shape Recall)

検出対象葉面の形状再現率の評価を目的として、検出対象葉面、背景の2クラスにおいて、式(2)で定義した。

$$LSR = \frac{\text{「検出対象葉面」の正解ピクセル数}}{\text{「検出対象葉面」のピクセル総数}} \quad (2)$$

③ FPR (False Positive Rate)

背景に生じた誤検出の評価を目的として、検出対象葉面、背景の2クラスにおいて、式(3)で定義した。

$$FPR = \frac{FP}{FP + TN} \quad (3)$$

FP : 正解「背景」→検出「検出対象葉面」

TN : 正解「背景」→検出「背景」

4. 評価結果

図2に、オクラの農作物画像で学習し、水分検出した結果の一例を示す。提案手法を用いた葉面上水分検出は、複数のオクラ葉面に対して一括して行えることが確認できた。表1に、オクラの農作物画像で学習し、水分検出した場合の評価結果を示す。提案手法により、MF1_{W,D}は79.50%を達成した。クラス追加は提案手法と比べ、MF1_{W,D}は1.93ポイント悪化したものの、LSRは0.35ポイントの改善、FPRは0.02ポイントの改善となり、意図した改善を得た。葉面抽出追加は提案手法やクラス追加と比べMF1_{W,D}とLSRが悪化したものの、FPRが最も優れた結果となり、背景における誤認を減少させる目的に適った結果となった。

表2に、学習に使用していないキュウリの農作物画像で水分検出した場合の評価結果を示す。提案手法により、MF1_{W,D}は59.24%を達成した。クラス追加は提案手法と比べLSRが改善されたものの、MF1_{W,D}は9.34ポイント、FPRは0.20ポイントの悪化が発生し、期待通りの改善が得られなかった。葉面抽出追加は提案手法と比べMF1_{W,D}とLSRが悪化したものの、FPRが最も優れた結果となり、オクラの結果と同様に背景における誤認の減少に成功した。学習に用いている有利なオクラの場合と比較して、特に



(a) 入力画像 (b) アノテーション画像 (c) 検出結果

図2 提案手法によるオクラの水分検出例

表1 オクラの評価結果 [%]

評価指標	ADE20Kのみ	提案手法	クラス追加	葉面抽出追加
MF1 _{W,D}	NaN	79.50	77.57	42.72
LSR	0.03	97.78	98.13	74.58
FPR	0.29	0.24	0.22	0.10

表2 キュウリの評価結果 [%]

評価指標	ADE20Kのみ	提案手法	クラス追加	葉面抽出追加
MF1 _{W,D}	NaN	59.24	49.90	51.38
LSR	3.86	99.65	99.72	99.57
FPR	0.16	0.30	0.50	0.13

MF1_{W,D}が悪化したものの、LSRやFPRに大きな悪化は現れなかった。この結果より、農作物の種類を問わず農地で撮影した画像を用いてファインチューニングを行うことで、FPRを保ちつつLSRを向上させることが可能である一方で、MF1_{W,D}は学習に用いた農作物に依存すると考えられる。

5. まとめ

本研究では、農地において複数の葉面に対する水分検出を一括で行うことを目的として、セマンティックセグメンテーションを用いた水分検出法、および2つの対策手法を提案した。評価の結果、学習に用いたオクラでは最大79.50%、学習に用いていないキュウリでは最大59.24%の水分検出精度を達成した。両者において提案手法はMF1_{W,D}が優れており、クラス追加はLSRに優れ、葉面抽出追加はFPRに優れた結果となった。また、キュウリのLSRがオクラのLSRと同等以上であったことから、葉面抽出の精度は学習時の作物に依存しないことも分かった。

提案手法と対策手法それぞれで優れた評価指標が異なったことから、今後はクラス追加と葉面抽出追加の併用を試す必要がある。また、水分検出精度向上に向けた各DNNモデルの最適化や多様な学習データの利用も課題である。

参考文献

- [1] Dawson, T.E. and Goldsmith, G.R., "The value of wet leaves," *New Phytol.*, 219: pp.1156-1169, 2018.
- [2] 木村 和義, "雨に対する作物の生理・生態学的研究", *農業気象*, 48巻, 1号, pp.85-88, 1992.
- [3] Dongmei Wen, Aixin Ren, Tao Ji, Isabel Maria Flores-Parra, Xinting Yang, Ming Li, "Segmentation of thermal infrared images of cucumber leaves using K-means clustering for estimating leaf wetness duration," *Int J Agric & Biol Eng.*, 13(3): pp.161-167, 2020.
- [4] Anushka Swarup, Won Suk Lee, Natalia Peres, Clyde Fraisse, "Strawberry Plant Wetness Detection Using Color and Thermal Imaging," *J. Biosyst. Eng.*, 45, pp.409-421, 2020.
- [5] Nagarajan Ramalingam, M.S., "Non-contact Multispectral and Thermal Sensing Techniques for Detecting Leaf Surface Wetness," *The Ohio State University, Ph.D. thesis*, pp.123-153, 2005.
- [6] Brian H. Nguyen, Gregory S. Gilbert, and Marco Rolandi, "A Bio-Mimetic Leaf Wetness Sensor from Replica Molding of Leaves," *Advanced Sensor Research*, Volume 2, Issue 6, 2023.
- [7] Hengshuang Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, Jiaya Jia, "Pyramid Scene Parsing Network," *IEEE Computer Vision and Pattern Recognition (CVPR)*, pp.2881-2890, 2017.
- [8] Bolei Zhou, Hang Zhao, Xavier Puig, Sanja Fidler, Adela Barriuso, Antonio Torralba, "Scene Parsing through ADE20K Dataset," *IEEE Computer Vision and Pattern Recognition (CVPR)*, 2017.