

草姿画像を用いた植物萎れ具合高精度推定

若森和昌¹ 兼田千雅² 柴田瞬² 峰野博史^{1,3}

¹静岡大学情報学部 ²静岡大学大学院総合科学技術研究科 ³JST さきがけ

1. はじめに

近年、農業従事者の経験と勘に基づく栽培技術を機械的に再現する研究が進められている。栽培技術の中でも植物への灌水を適切に制御するストレス栽培は、高糖度な果実を生産でき、農産物市場の活性化に繋がるため、自動化が期待されている。ストレス栽培を自動化するためには、植物が受ける水分ストレスを高精度に推定し、適切なタイミングで灌水制御を行う必要がある。しかし、植物が受ける水分ストレスは、周囲の温度や相対湿度、光量などの影響で複雑に変化するため、水分ストレスの高精度かつ手軽な推定手法は実現されておらず、既存手法を用いて高糖度な果実を栽培することは困難であった。

本研究では、植物が水分ストレスを受けることで生じる萎れに着目し、カメラで手軽に収集できる草姿画像を用いて、植物の萎れ具合を高精度に推定する手法を検討する。本手法では、動体検出に用いられるOptical Flowで草姿の変化を定量化し、機械学習で萎れ具合を推定する。さらに、草姿画像だけでなく、水分ストレスに対する間接的な影響が存在する環境データを組み合わせて学習することで、植物の萎れ具合推定における環境データの影響を分析する。

2. 関連研究

植物の水分ストレス推定手法として、植物体内の水分量を直接測定する手法や、葉の固有振動数を計測する手法、草姿画像から草姿の変化を定量化する画像処理法[1][2]が提案されている。特に、画像処理法は植物に対して非接触・非破壊で推定でき、計測機器（カメラ）は他の手法に比べて安価かつ設置が容易であることから、実際の栽培現場への導入が期待できる。

従来の画像処理法では、水分ストレスを推定するために、画像から植物体だけを忠実に分離した後に、植物の変化を検出する方法が検討されている。例えば、植物体の輪郭を忠実に抽出し、その重心の変化を追跡することで萎れ具合を定量化する手法[1]は、顕著な萎れの検出が可能である。しかし、植物体の重心の変化を指標とするため、軽微な萎れの検出は困難である。また、同様に植物体の輪郭を抽出した後に、植物直上部からの投影面積を算出することで萎れ具合を推定する手法[2]は、軽微な萎れも検出できるため、高精度な萎れ具合推定が期待できる。しかし、植物の輪郭抽出のために背景として青色の布を用いており、実際の栽培現場への導入には至っていない。適用先を限定せず汎用的な推定手法とするためには、軽微な萎れも検出でき、かつ複雑な背景下へも適用可能とすることが望まれる。

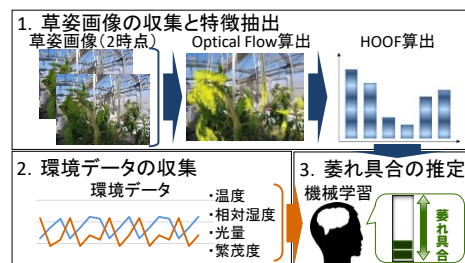


図1 植物萎れ具合推定手法の概要

3. 草姿画像を用いた植物萎れ具合推定

本研究では、高価な専門機器を必要とせず、カメラで手軽に収集できる草姿画像を用いた植物萎れ具合推定手法の検討と、萎れ具合推定における環境データの影響分析を行う（図1）。草姿画像からの特徴抽出には、2時点の画像間における物体の動きを速度ベクトルで表したOptical Flowを用いる。本研究では、Optical Flowの算出手法の中でも、植物のような非剛体の動きを追跡できるDeep Flow[3]を採用する。Deep Flowを用いることで、植物体の忠実な輪郭抽出を必要とせず、複雑背景下においても、草姿の変化を適切に定量化できると考える。一方で、Deep Flowから算出されるOptical Flowは画像サイズ分の速度ベクトルで構成され、次元数が膨大であり機械学習の説明変数には適さない。そこで、Optical Flowをヒストグラム化したHOOF (Histograms of oriented optical flow) [4]を説明変数として萎れ具合を推定する手法[5]を用いる。

萎れは葉からの蒸散速度が根からの吸水速度を上回ることで生じるが、蒸散速度は温度や相対湿度、光量、植物の繁茂度といった環境データに強く依存する。そのため、植物の萎れ具合推定に用いる説明変数には、草姿の変化を定量化したHOOFだけでなく、環境データを組み合わせることで、推定精度の向上が見込まれる。植物繁茂度の定量化には空間に散乱する光量を計測する散乱光センサを用いる。植物群落上部と下部の2地点の散乱光量の比 (Relative Light Intensity:RLI) を算出することで、植物の葉面積指数を推定できる[6]。RLIを繁茂度の指標とすることで、繁茂度に依存した萎れも推定可能となる。

萎れ具合推定における正解データには、水分ストレスとの関連が強く、非破壊計測が可能な茎径を用いる。茎径を用いた水分ストレス指標として、植物の成長に伴う茎径の増大を考慮したRSD (Relative Stem Diameter) が提案されている[7]。RSDは現在の茎径 SD_t を現在までに観測された最大の茎径 $MaxSD_t$ で割ったものである。しかし、RSDでは $MaxSD_t$ が大きくなるほど茎径の縮小具合の影響が小さくなり、植物の成長を十分に考慮できない。そのため、本研究では現在の茎径 SD_t と最大茎径 $MaxSD_t$ との差であるDSD (Difference in Stem Diameter) を用いる。

4. 基礎実験

4.1. 実験方法

草姿画像と環境データを用いた萎れ具合推定の基礎実験として、機械学習に用いる説明変数に草姿画像から得

Estimation of plant wilting using plant posture image

Kazumasa Wakamori¹, Yukimasa Kaneda², Shun Shibata², Hiroshi Mineno^{1,3}

¹ Faculty of Informatics, Shizuoka University

² Graduate School of Integrated Science and Technology, Shizuoka University

³ JST PRESTO

表 1 訓練, 検証, 評価データの詳細

項目	訓練データ	検証データ	評価データ
収集場所	処理区 1	処理区 2	処理区 2
収集期間	2016/8/19 ~ 8/29	2016/8/19 ~ 8/24	2016/8/25 ~ 8/29
データ数	3510	1370	1926

られるHOOFのみを用いた場合, 環境データのみを用いた場合, HOOFと環境データを共に用いた場合の三種類の条件における推定精度の比較実験を行った. 本実験は, 静岡県農林技術研究所のトマト低段密植栽培実験現場内の2つの栽培処理区に小型カメラ (GoPro HERO4 Session) と無線散乱光センサノード[8], 茎径センサを設置し, 2016年8月19日から8月29日の9時から17時の間, 1分間隔で収集したデータを用いて実施した. 無線散乱光センサノードでは散乱光と温度, 相対湿度を計測し, 茎径センサはレーザラインセンサ (HL-T1) を用いて茎径を計測する. 表 1に本実験に用いる訓練, 検証, 評価データの詳細を示す. 機械学習の説明変数として用いるHOOF (6次元) は収集した連続草姿画像から10分間隔で算出し, 環境データには過去10分間の温度, 相対湿度, 光量, RLIを用いた. 学習器には代表的な非線形回帰手法の一つであるRandom Forestを用い, 評価に用いる誤差指標は平均絶対誤差 (MAE), 二乗平均平方誤差 (RMSE), 相対絶対誤差 (RAE), 相対二乗誤差 (RSE) とした.

4.2. 実験結果

表 2 に評価データに対する推定誤差を, 図 2 に推定結果を示す. 表 2 から HOOF と環境データを組み合わせることで本実験に用いた全ての誤差指標において誤差を削減でき, 特に RSE において HOOF のみでは 0.8243, 環境データのみでは 0.8620 であったが, 両者を組み合わせることで 0.7553 まで誤差を削減できた. また図 2 から, HOOF を用いた場合は DSD の局所的変化のタイミングを捉え, 環境データを用いた場合は DSD の大域的变化の概形を捉えていることがわかる. DSD の局所的変化は植物が一定の水分を失った際, または吸収した際に生じると考えられるが, 水分を失うまたは吸収した影響が茎だけでなく草姿にも表れたことから, 草姿の変化を定量化した HOOF を用いることで, 局所的変化のタイミングを捕捉できたと考える. 一方, DSD の大域的变化は植物の蒸散速度の影響であると考え. 植物には根から吸収した水分を茎や葉に押し上げる根圧が存在するが, 葉からの蒸散速度が小さい場合, 押し上げられた水分が蒸散されず, 茎への圧力が高まるため, 蒸散速度の変化に伴い DSD にも大域的变化が生じる. 蒸散速度は周囲の環境に強い影響を受けることから, 環境データを用いた推定で DSD の大域的变化を捕捉できたと考える. 以上から, 草姿の変化を定量化した HOOF と環境データは萎れ具合推定において異なる特徴を有するため, 両者を組み合わせることで異なる特徴を重畳させた推定モデルを構築できる. 実際に, HOOF と環境データを組み合わせることで推定誤差を削減でき, 高価な専門機器を必要としていた萎れ具合推定を, 手軽に収集できる草姿画像から高精度に推定できる見通しを得た.

5. おわりに

本研究では, 草姿画像を用いた植物萎れ具合の高精度推定手法の検討と, 植物の萎れに間接的な影響を与える環境データの萎れ具合推定における役割を分析した. 基礎実験の結果, 草姿画像から草姿の変化を定量化した

表 2 評価データに対する説明変数毎の推定誤差

誤差指標	HOOF	環境データ	HOOF+環境データ
MAE	0.0064	0.0063	0.0059
RMSE	0.0077	0.0079	0.0074
RAE	0.8958	0.8810	0.8226
RSE	0.8243	0.8620	0.7553

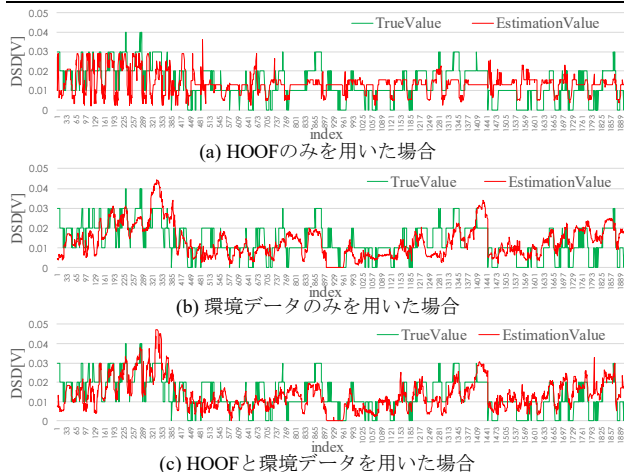


図 2 評価データに対する推定結果

HOOF と環境データには萎れ具合推定において異なる特徴を有し, HOOF と環境データを組み合わせることで, 推定精度が向上することを確認した.

今後, 草姿画像の特徴抽出に畳み込みニューラルネットワーク (CNN) の適用を検討する. 草姿の変化を定量化した HOOF のみでは DSD の大域的变化を捕捉できないが, CNN を用いて草姿画像から環境データに代わる特徴を抽出することで, 草姿画像のみを用いる場合でも, 環境を考慮した高精度な萎れ具合推定の実現を目指す.

謝辞

本研究は JST さきがけの支援を受けて実施したものである. また, 実験環境を提供いただいた静岡県農林技術研究所の前島様, 今原様に深い感謝の意を表する.

参考文献

- [1] 田附明夫, 他: 数種浸透質の添加と無酸素または通気停止処理によるキュウリ幼植物体の水ストレスの画像診断, 園芸学研究, Vol.6, No.3, pp.367-373 (2007).
- [2] 高山弘太郎, 他: デジタルカメラを用いた投影面積モニタリングによるトマトの水ストレス早期診断, 植物環境工学, Vol.21, No.2, pp.59-64 (2009).
- [3] Weinzapfel, P., et al.: Deepflow: Large displacement optical flow with deep matching, IEEE ICCV, pp.1385-1392 (2013).
- [4] Chaudhry, R., et al.: Histograms of oriented optical flow and binet-cauchy kernels on nonlinear dynamical systems for the recognition of human actions, IEEE CVPR, pp.1932-1939 (2009).
- [5] 柴田瞬, 他: Optical Flow を用いた植物萎れ具合の推定, マルチメディア, 分散, 強調とモバイル(DICOMO2016)シンポジウム, pp.66-72 (2016).
- [6] 大石直記: 散乱光センサによるトマト葉面積指数の非破壊評価, 植物環境工学, Vol.28, No.3, pp.125-132 (2016).
- [7] 大石直記: トマトの養液栽培における水分ストレスに応じた給液制御システムの開発(1)-茎径変化による水分ストレスの非破壊評価-, 生物環境調節, Vol.40(1), pp.81-89 (2002).
- [8] Ibayashi, H., et al.: A Reliable Wireless Control System for Tomato Hydroponics, MDPI Sensors, Vol.16(5), 664 (2016).