

深層学習を用いた植物の水分ストレス推定手法の検討

若森和昌¹ 柴田瞬¹ 峰野博史²

概要: 近年、熟練農家の経験と勘に基づく高度な栽培技術の形式知化に関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、形式知化が期待されている。ストレス栽培の形式知化では、植物が受ける水分ストレスを高精度に推定し、植物への灌水タイミングを適切に定義する必要がある。しかし、植物が受ける水分ストレスは栽培環境に応じて複雑に変化するため、水分ストレスの手軽かつ高精度な推定手法は実現されておらず、既存手法を用いて手軽に高糖度な果実を栽培することは困難だった。本研究では、手軽に収集できる草姿画像に深層学習の一種である畳み込みニューラルネットワークを適用することで、植物の水分ストレスを高精度に推定する手法を検討する。トマト栽培実験環境下で収集したデータを用いて基礎評価を行ったところ、提案手法は Optical Flow と機械学習を用いた既存手法に比べ MAE で約 21.9% の推定誤差削減を実現でき、ストレス栽培の再現に有効な水分ストレス推定手法であることを確認した。

A study on Plant Water Stress Estimation Using Deep Learning

KAZUMASA WAKAMORI¹ SHUN SHIBATA¹ HIROSHI MINENO²

1. はじめに

日本の農業就業人口は年々減少しており、特に熟練農家の離農に伴う高度な栽培技術の喪失が問題となっている。高度な栽培技術は、熟練農家が長年の経験と勘に基づいて習得した技術であり、近年増加傾向にある新規就農者が同様の栽培技術を習得することは難しい[1]。そこで、失われつつある高度な栽培技術を効率的に伝承することを目的とし、ICT を利活用して栽培技術を形式知化する研究が進められている。高度な栽培技術を形式知化することで、新規就農者は高度な栽培技術を手軽に再現し、安定した生産量や収入を得ることができる。さらに未就農者の農業に対する懸念事項として挙げられる肉体的な重労働や収入の不安定性を解消でき、新規就農者数の更なる増加に繋がる。

高度な栽培技術の中でも、植物に対して適度な水分ストレス(乾き状態)を付与するストレス栽培は、高糖度な果実を生産でき、果実の市場価値の向上に繋がることから形式知化が期待されている。ICT を利活用したストレス栽培の形式知化では、植物が受けてい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ため、様々な水分ストレスの推定手法が提案されてきた。その中でも植物体を撮影した草姿画像を用いる画像処理法は一般に普及しているカメラを用いて、植物に対し非破壊かつ非接触に推定できることから、農業経験の浅い新規就農者でも手軽に利用できる。既存の画像処理法では草姿画

像から植物の萎れを定量化することで水分ストレスを推定する。しかし、既存手法では植物体の忠実な背景分離を必要とするため複雑背景下への導入が難しいことや、ある二時点間の相対的な萎れを用いるため萎れの絶対量を考慮できないことから、実際の栽培現場における高精度な水分ストレス推定は困難であった。

本研究では、草姿画像を用いた植物水分ストレス推定において、深層学習の一種であり画像認識の分野への応用で効果の出ている畳み込みニューラルネットワーク(CNN)を用いた手法を検討する。CNNを用いて植物の萎れに関する特徴抽出を実現することで複雑背景下でも萎れ具合の絶対量を捉え、草姿画像を用いた水分ストレス推定の高精度化が期待できる。これまでに、CNNを用いた水分ストレス推定手法として、Remarkable moving objects detected by adjacent optical flow (ROAF)を用いて入力画像を加工することで推定精度を向上させる手法を提案している[2]。ROAFは動体検出に用いるOptical Flowで植物の萎れを検出し、CNNに萎れた部位に着目した学習を行わせることで特徴抽出性能の向上を図る手法であり、ROAFを草姿画像に適用することで水分ストレス推定の精度が向上することが示されている。ROAFを適用することでCNNの特徴抽出性能が向上する場合、少ない訓練データからでも高い推定精度が期待できるが、これまでに行われたROAFの性能評価は、一定量の訓練データを用いた評価のみであった。少ない訓練データを用いた場合でも高い推定精度が得られるとしたら、ROAFは訓練データ数の削減に有効な手法であることが明らかとなる。また、これまでに既存の画像処理法と深層学習を用いた水分ストレス推定手法の比較が行

¹ 静岡大学大学院総合科学技術研究科

Graduate School of Integrated Science and Technology, Shizuoka University

² 静岡大学学術院情報学領域/JST さきがけ

College of Informatics, Academic Institute, Shizuoka University / JST, PRESTO



図 1 Optical Flow と機械学習を用いた水分ストレス推定手法

われていないことから、本稿では訓練データ数に応じた ROAF 適用画像の特徴抽出性能の評価と、既存の画像処理法との比較を行うことで、深層学習を用いた水分ストレス推定手法の高度化に向けた検討を行う。

以降、2 章では関連研究を述べ、3 章では深層学習を用いた植物の水分ストレス推定手法を述べる。4 章では本手法の基礎評価結果を述べ、最後に 5 章で本論文をまとめる。

2. 関連研究

2.1 土壌水分量に基づく水分ストレス推定手法

土壌水分法は土壌内の水分量に基づいて植物の水分ストレスを推定する。植物の水分ストレスは葉からの蒸散量が根からの水分吸収量を上回ることによって生じるため、根からの水分吸収量と密接な関係がある土壌内の水分量を計測することで水分ストレスを推定できる。土壌水分量の計測手法には、土壌水分計にて土壌内の水分張力[3]や誘電率[4]を計測する方法が存在する。しかし、土壌水分法を用いて水分ストレスを高精度に推定できる条件は土壌内が湿潤であり、水分が一様に分布している場合に限られる。少量の灌水を頻繁に行うことが想定されるストレス栽培では、土壌が乾燥状態あるいは水分の分布が不均一になりやすく、土壌水分法は推定精度に課題が残る。

2.2 植物体の変化に基づく水分ストレス推定手法

植物体の変化を直接計測することで水分ストレスを推定する手法として、葉の振動数[5]や茎径[6,7]を用いる手法がある。葉の振動数を用いる手法は超音波スピーカで葉に振動を与えた際の葉の振動を計測することで水分ストレスを推定する。茎径を用いる手法では、植物の茎は水分ストレスが付与されると収縮する特性があることから、茎径の変化を経時的に計測することで水分ストレスを推定する。この二手法は植物に対し非破壊かつ経時的に水分ストレスを評価できることから、水分ストレスに応じた自動灌水システムへの応用が可能である。しかし、葉の振動や茎径の計測にはレーザ変位センサなど一台十数万円程度の高価な計測機器を必要とするため、新規就農者の手軽な利用は難しい。また、植物の茎は加齢に伴い硬化するため、植物の生育に応じて測定機器の位置を変更する必要がある。さらに、茎径の計測では計測機器を茎に直接取り付けるが、取り付け時に強く固定すると植物の生育に悪影響を与え、固定が

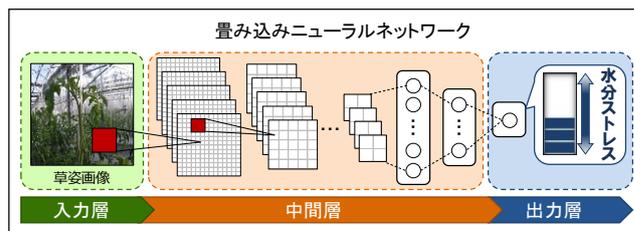


図 2 深層学習を用いた水分ストレス推定手法

弱いと安定した計測が行えず、利用者は機器の設置に関する技術習得も必要となる。新規就農者でも手軽に利用可能な水分ストレス推定手法とするには、一般に普及している安価な機器を用い、かつ植物に対して非接触で手軽に計測可能な手法が望まれる。

2.3 萎れに基づく水分ストレス推定手法

植物体の萎れ具合を用いて水分ストレスを推定する手法として画像処理法がある。画像処理法に用いる草姿画像は、一般に普及しているカメラを用いて植物に対し非接触で収集できることから、新規就農者が手軽に利用できる手法といえる。画像処理法には草姿画像から植物体を忠実に分離し、植物体の変化を定量化することで水分ストレスを推定する手法[8]がある。この手法では顕著な萎れだけでなく軽微な萎れ具合も定量化し、水分ストレスの推定が可能である。しかし、輪郭抽出のために単色の単純背景を用いており、複雑背景を有する実際の栽培現場への導入は困難である。そこで、複雑背景下でも適用可能な手法として、図 1 に示す Optical Flow と機械学習を用いた推定手法を提案した[9,10]。二時点間の草姿画像から検出された Optical Flow を Histograms of oriented optical flow (HOOF) に変換することで、複雑背景下においても適切に草姿の変化を定量化できることを示した[9]。また、HOOF を説明変数として機械学習で水分ストレスを推定する手法を検証した[10]。しかし、Optical Flow は二時点間の相対的な萎れを示すため、萎れの絶対量に関する特徴を抽出できず、推定精度に課題が残る。そのため、実際の栽培現場における草姿画像を用いた高精度な水分ストレス推定手法は確立されておらず、草姿画像を用いた植物水分ストレス推定手法は実用化されていない。

3. 深層学習を用いた植物の水分ストレス推定

3.1 概要

本研究では、手軽かつ高精度な水分ストレス推定手法を実現するため、草姿画像に対し深層学習を適用した植物の水分ストレス推定手法を検討する。提案手法の概要を図 2 に示す。提案手法では、深層学習の中でも画像の空間情報を考慮した学習が可能な CNN を特徴抽出器として用いることで、草姿画像から萎れに関する特徴を自動抽出し、植物の水分ストレスの高精度な推定モデルを構築する。

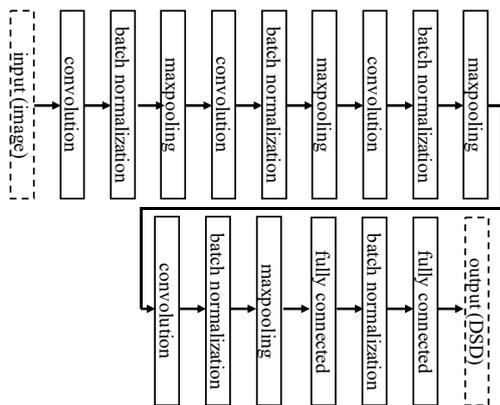


図 3 ネットワーク構造

表 1 各層の詳細設定

層種	パッチ	ストライド	出力マップサイズ	活性化関数
input	-	-	144×144×3	-
conv1	3×3	2	72×72×24	PReLU
norm1	-	-	72×72×24	-
pool1	2×2	2	36×36×24	-
conv2	3×3	1	36×36×48	PReLU
norm2	-	-	36×36×48	-
pool2	2×2	2	18×18×48	-
conv3	3×3	2	9×9×64	PReLU
norm3	-	-	9×9×64	-
pool3	2×2	2	5×5×64	-
conv4	3×3	2	3×3×64	PReLU
norm4	-	-	3×3×64	-
pool4	2×2	2	2×2×64	-
fc1	-	-	64	PReLU
norm5	-	-	64	-
fc2	-	-	1	-

3.2 ネットワーク構造

提案手法のネットワーク構造を図 3 に、各層の詳細設定を表 1 に示す。水分ストレス推定に用いるネットワークは、入力側から畳み込み層—正規化層—プーリング層の 3 層を 4 連結し、続いて全結合層—正規化層—全結合層を連結した構造とする。一般物体認識向けに設計されたネットワークである VGG[11]や Residual Network (ResNet) [12]はパラメータを有する畳み込み層と全結合層の数が 16 以上あり、パラメータ数が膨大な CNN である。パラメータ数が膨大な CNN は多くの訓練データを必要とするが、VGG や ResNet は一般物体認識を目的としているため imageNet と呼ばれるインターネット上のラベル付き画像データベースから収集した膨大なデータを用いて十分に訓練できる。しかし、本研究の目的である植物の水分ストレスに関するラベル付きデータセットを有する画像データベースは存在せず、訓練データは独自に収集しなければならず、imageNet のような大規模なデータセットを確保するのは難しい。パラメータ数に対して訓練データ数が少ない場合、過学習に繋がることから、ネットワークに含まれるパラメータ数を

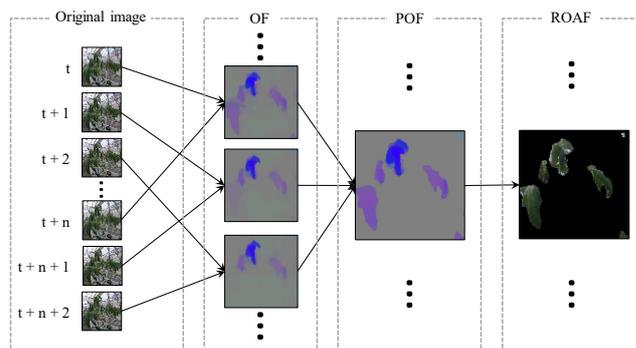


図 4 ROAF の生成過程[2]

抑える必要がある。そこで、提案手法のネットワークはパラメータを有する畳み込み層と全結合層を計 6 層とし、VGG や ResNet に比べパラメータ数を抑えた構造とする。また、各正規化層には大きな学習係数を設定しネットワークの学習速度を向上できる Batch Normalization[13]を適用する。1 つ目の全結合層は 256 個のユニットを有し、出力には過学習を防ぐためにドロップアウト[14]を適用する。最後の全結合層は 64 個のユニットを有し、入力草姿画像に対する水分ストレスの強度を実数値で出力する。さらに、Batch Normalization と同様に学習速度向上を目的に、各層におけるユニットの重みの初期値には He の初期値[15]を用いる。

3.3 入力画像の加工

CNN への入力画像には ROAF[2]を適用する。ROAF は Optical Flow を用いて検出した物体の動きに基づいて、画像内の学習に不要な部分を除去する手法であり、草姿画像に適用することで植物の萎れに関する特徴抽出性能の向上が期待できる。ROAF の詳細な生成過程を図 4 に示す。まず n 時点離れた 2 つの原画像に対し、動体検出に用いる Optical Flow (OF) を適用することで植物の動きに特化した画像を生成する。本研究では Optical Flow の算出アルゴリズムとして植物のような非剛体の動きに追従可能な Deep Flow[16]を用いる。その後、Deep Flow を用いて算出した Optical Flow をプーリング処理し Pooled Optical Flow (POF) を生成する。Optical Flow は一定の二時点間の差分であるため、Optical Flow のみでは二時点以外で生じた萎れを抽出できない。そこで、一定期間の OF に対し画素毎の最大プーリングを適用することで、二時点以外で生じた萎れも抽出した画像を POF として生成する。最後に POF で原画像をマスクすることで植物の萎れ部分のみを抽出した ROAF を生成する。POF は水分ストレスの付与に伴い萎れが生じた部位の位置情報を有するが、原画像は POF には存在しない植物の色や形状といった情報を有する。そこで、異なる情報を有する POF と原画像をマスク処理することで、植物体の萎れに関する着目すべき部位を際立たせた画

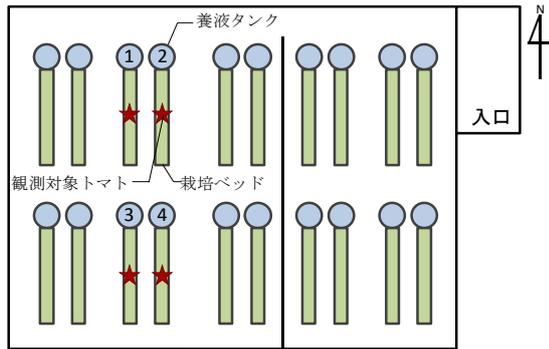


図 5 養液栽培実験温室

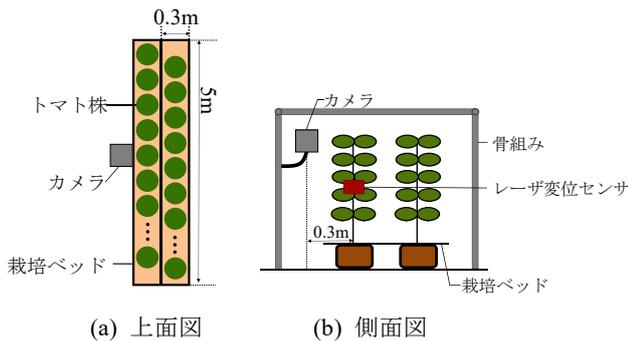


図 6 栽培処理区毎の機器設置環境

像を生成できる。マスク処理では、萎れが生じなかった部位、つまり POF の値が 0 の画素を原画像において黒色 (RGB チャネルの各値を 0) とすることで、CNN の畳み込み処理において萎れが生じた部位に着目した学習が可能となる。また、畳み込み処理を行う際、カーネル内の全ての値が 0 である場合、同カーネルの結合先への情報伝達は行われないため、マスク処理で萎れに関係しない部位の値を 0 にすることで、同部位の情報が次の層へ伝達されることを防止できる。そのため、CNN へ入力する草姿画像として ROAF を用いることで、植物体の萎れが生じた部位のみに着目した学習が可能となる。

3.4 水分ストレスの指標

CNN を用いた水分ストレス推定における目的変数には、水分ストレスと密接な関係のある茎径を用いることとする。植物の茎は水分ストレスの付与に伴い縮小する[6,7]ため、茎径を計測することで植物が受けている水分ストレスを定量化する。茎径はレーザ変位センサを用いて非破壊かつ経時的に計測でき、計測に伴う植物への影響を最小限に抑えつつ、水分ストレスの経時的な変化を計測できる。ただし、茎径と水分ストレスには密接な関係が存在するが、植物の成長に伴い茎径も増大するため、目的変数として成長に伴う茎径の増大を除去する必要がある。そこで、現在の茎径と現在までの最大茎径の差を取ることで成長に伴う茎径の増大の影響を除去し、水分ストレス付与に伴う茎の収縮のみを表す指標として DSD (Difference in Stem Diameter) を

表 2 基礎評価用データの内訳

データ種	処理区	期間	データ数[件]
訓練データ	2, 3, 4	2016/08/05-2016/08/31	25148
検証データ	1	2016/08/05-2016/08/12	2551
評価データ	1	2016/08/13-2016/08/31	5940

用いる。式(1)に時点 t における DSD を示す。本研究では DSD を水分ストレスの指標として用い、回帰モデルを構築する。

$$DSD_t = \max(SD_0, \dots, SD_t) - SD_t \quad (1)$$

4. 基礎評価

4.1 概要

提案手法である CNN を用いた植物の水分ストレス推定手法の有効性を示すため、訓練データ数に応じた ROAF 適用画像の特徴抽出性能の評価、および既存手法である Optical Flow と機械学習を用いた推定手法との性能比較を実施した。図 5 に示す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 4 つの養液栽培処理区に、図 6 に示す形で屋外用小型カメラ (GoPro Hero4 Session, Woodman Labs 製) と茎径計測用レーザ変位センサ (HL-T1, Panasonic 製) を設置し、2016 年 8 月 5 日から 8 月 31 日の 9 時から 17 時の間に 1 分周期で収集したデータを用いて実施した。収集したデータにおける訓練データ、検証データ、評価データの内訳を表 2 に示す。養液栽培における萎れは数分で草姿に現れるため、ROAF の適用における Optical Flow の算出間隔は 10 分とし、Pooled Optical Flow は推定時点から過去 5 分間分の Optical Flow をプーリングしたものとした。本実験における CNN の実装には Chainer[17]、その他の機械学習アルゴリズムの実装には Scikit-learn[18]を用い、GPU NVIDIA GeForce GTX 1080 を搭載した PC で実施した。

性能評価では回帰問題における誤差指標として一般的である平均絶対誤差 (MAE)、二乗平均平方誤差 (RMSE)、相対絶対誤差 (RAE)、相対二乗誤差 (RSE) を用いた。各指標の算出式を以下に示す。

$$MAE = \frac{1}{N} \sum_i^N |y_i - \hat{y}_i| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_i^N (y_i - \hat{y}_i)^2} \quad (3)$$

$$RAE = \frac{\sum_i^N |y_i - \hat{y}_i|}{\sum_i^N |y_i - \bar{y}|} \quad (4)$$

$$RSE = \frac{\sum_i^N (y_i - \hat{y}_i)^2}{\sum_i^N (y_i - \bar{y})^2} \quad (5)$$

N はデータ数、 y_i と \hat{y}_i はそれぞれ時点 i の真値と推定値、 \bar{y} は

真値の平均値を表す。RAE と RSE は真値の平均値との相対的な誤差指標であり、RAE と RSE が 1 未満である場合、真値の平均値に比べ推定が高精度であることを示す。

4.2 入力画像加工と訓練データ数の検討

4.2.1 目的と方法

CNN の入力画像に ROAF を適用することで、少ない訓練データで効率的に特徴を抽出できると考える。ROAF 適用画像と訓練データ数の関係を分析するため、原画像と ROAF 適用画像に対し、訓練データを間引くことでデータ数を削減した場合の推定精度を分析した。表 3 に訓練データの間引き率とデータ数の関係を示す。訓練データの間引

表 3 訓練データの間引き率とデータ数

データ間引き率[%]	データ数[件]
0	25148
20	20119
40	15090
60	10060
80	5030
90	2515

き率は 0%~90%までとし、間引き率 20%, 40%, 60%, 80% のデータは訓練データを連続した 5 個ずつのブロックに分割し、各ブロックの先頭からそれぞれ 1 個, 2 個, 3 個, 4 個のデータを単純に間引いたデータとした。間引き率 90% は訓練データを連続した 10 個ずつのブロックに分割し、各ブロックの先頭から 9 個のデータを単純に間引いたデータとした。原画像と ROAF 適用画像において、各間引き率の訓練データを用いた際の推定精度を誤差指標 MAE と RMSE を用いて比較した。CNN のハイパーパラメータである学習率とバッチサイズ、ドロップアウト率はランダムサンプリングを用いたチューニングを実施し、原画像を用いた CNN にて選択されたハイパーパラメータを表 4 に、ROAF 適用画像を用いた CNN にて選択されたハイパーパラメータを表 5 に示す。

4.2.2 結果と考察

訓練データの間引き率に対する推定誤差として MAE を図 7(a)に RMSE を図 7(b)に示す。Org は原画像を用いた場合の推定誤差を、ROAF は ROAF 適用画像を用いた場合の推定誤差を示している。図 7 から原画像は訓練データの間引き率の増大にともない、推定誤差も増加傾向にあるが、

表 4 原画像を用いた CNN におけるハイパーパラメータ

ハイパーパラメータ	訓練データ間引き率[%]					
	0	20	40	60	80	90
学習率	1.71×10^{-6}	6.91×10^{-6}	7.21×10^{-6}	1.64×10^{-6}	1.82×10^{-5}	1.04×10^{-6}
バッチサイズ	69	87	26	29	10	12
ドロップアウト率	0.51478	0.40974	0.59618	0.33672	0.49249	0.61638

表 5 ROAF 適用画像を用いた CNN におけるハイパーパラメータ

ハイパーパラメータ	訓練データ間引き率[%]					
	0	20	40	60	80	90
学習率	2.03×10^{-5}	7.72×10^{-5}	4.39×10^{-5}	2.17×10^{-5}	4.57×10^{-5}	4.39×10^{-5}
バッチサイズ	87	74	20	16	89	62
ドロップアウト率	0.53697	0.67461	0.67140	0.48448	0.50948	0.40233

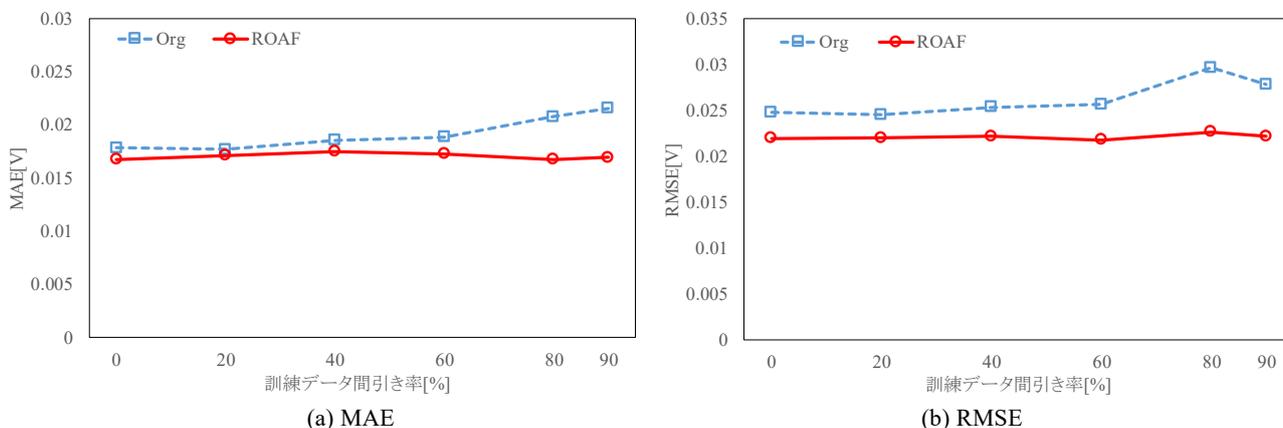


図 7 訓練データの間引き率に対する推定誤差

ROAF 適用画像は訓練データの間引き率に依存せず、低い推定誤差を維持している。そのため、入力画像に ROAF を適用することで原画像に比べ推定誤差を削減できるだけでなく、少ない訓練データでも高精度な推定モデルを構築できることが明らかとなった。ROAF 適用画像では背景や植物の萎れていない部位など学習に不要な部分がマスクされることで、CNN が訓練時に効率的に萎れに関する特徴を抽出し、少量の訓練データにおいても高い推定精度を維持できたと考える。ROAF のように入力画像を加工することで、少量の訓練データにおいても高精度な推定モデルを構築できるようになり、訓練データの収集に要する労力を削減できると考える。そのため、農業に代表されるような大規模な訓練データ数の確保が困難な分野に適した手法といえる。

4.3 提案手法と既存手法の性能比較

4.3.1 目的と方法

既存手法である Optical Flow に対し機械学習を用いた水分ストレス推定手法 (図 1) [9,10]と、本提案手法である CNN を用いた水分ストレス推定手法 (図 2) の性能比較を行う。既存手法における Optical Flow は 144×144 ピクセルの連続草姿画像から 10 分間隔で算出し、ピン数 6 の HOOF に変換した。既存手法に適した機械学習アルゴリズムとして代表的な非線形回帰手法である Support Vector Regression (SVR) と Random Forest (RF) を用いた。SVR のカーネル関数にはガウシアンカーネルを用い、両アルゴリズムのハイパーパラメータはグリッドサーチを用いて、SVR では C と ϵ 、 γ を、RF では木の数、木の最大深さ、説明変数の選択数をチューニングした。チューニングの結果、RF にて選択されたハイパーパラメータを表 6 に、SVR にて選択されたハイパーパラメータを表 7 に示す。

4.3.2 実験結果・考察

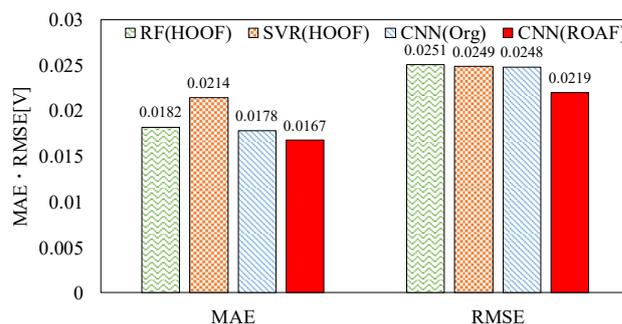
既存手法と、提案手法である CNN を用いた推定手法における推定誤差として、MAE・RMSE を図 8(a)、RAE・RSE を図 8(b)に示す。RF (HOOF) と SVR (HOOF) は説明変数としてともに HOOF を用い、機械学習アルゴリズムとしてそれぞれ RF または SVR を用いた推定結果である。CNN (Org) と CNN (ROAF) は図 3 に示した CNN において入力画像としてそれぞれ原画像 (Org) または ROAF 適用画像 (ROAF) を用いた推定結果である。図 8 から提案手法 CNN (ROAF) の MAE は 0.0167、RMSE は 0.0219 と最も推定誤差が低く、HOOF を説明変数として SVR を用いて推定した SVR (HOOF) に比べ MAE で約 21.9%、RMSE で約 11.7%の誤差を削減できた。また、提案手法である CNN (ROAF) では RAE が 0.8939、RSE が 0.8410 と 1 未満であることから、真値の平均値に比べ、高精度に推定できたことがわかる。CNN (ROAF) は、既存手法に比べ植物の水分ストレスを高精度に推定できたことから、提案手法は水分ストレスの形式知化において有効な手法と考える。

表 6 RF のハイパーパラメータ

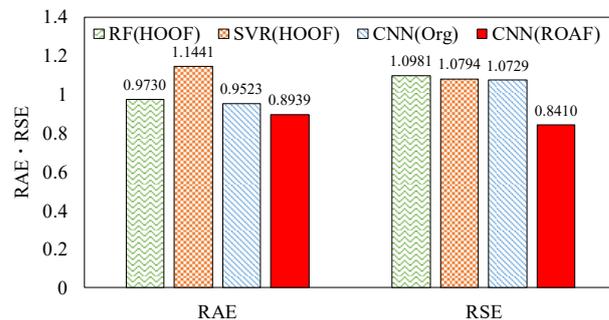
ハイパーパラメータ	値
木の数	8
木の最大深さ	4
説明変数の選択数	6

表 7 SVR のハイパーパラメータ

ハイパーパラメータ	値
C	0.06250
ϵ	0.03125
γ	0.03125



(a) MAE・RMSE



(b) RAE・RSE

図 8 既存手法と提案手法の推定誤差

4.3.3 詳細分析

各手法の性能評価に関して、評価データ全体における真値と推定値の相関を分析する。DSD の真値と各推定手法における推定値の散布図を図 9 に示す。真値と各推定手法の推定値の相関係数 R は、図 9(d) に示す CNN と ROAF 適用画像を用いた CNN (ROAF) が最も高いことがわかる。これは、既存手法に比べ CNN を用いるだけでなく入力画像に ROAF を適用することで真値の傾向を捉えていることを示している。しかし、ROAF 適用画像を用いた場合でも相関係数 R は約 0.4 と真値の傾向と大きく外れている推定値が存在し、推定精度に改善の余地がある。そこで、CNN から抽出された特徴と DSD の関係を分析することで、推定精度向上に向けた検討を行う。

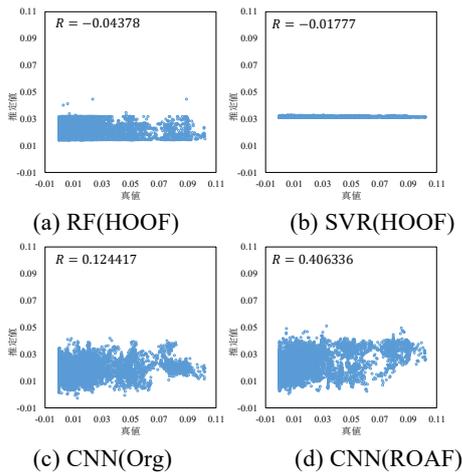


図 9 真値と各手法の推定値の散布図

図 10 に評価データの ROAF 適用画像から抽出された特徴と DSD の散布図を示す。CNN の最終層である全結合層の 64 ユニットのうち、評価データ期間の初日である 2016 年 8 月 13 日の DSD と相関が高い 5 ユニットの値を ROAF 適用画像から抽出された特徴の代表例として示す。図 10(a) に示す 2016 年 8 月 13 日において、ROAF 適用画像から抽出された特徴と DSD の相関係数 R は約 0.7 であり、データ間の高い相関が確認できる。しかし、図 10(b) に示す 2016 年 8 月 31 日では ROAF 適用画像から抽出された特徴と DSD の相関が低い。そのため、入力画像に ROAF を適用した場合でも CNN を用いて抽出できる特徴と DSD の関係は経時的に変化し、植物の生育ステージの変化に対し草姿画像から水分ストレス推定に必要な特徴を十分に抽出できていないことがわかる。この原因は訓練データ数の不足と草姿画像以外の重要な説明変数の存在であると考えられる。訓練データ数の不足に関しては本実験で使用したデータ以上の訓練データを確保できないため、現在、更なるデータ収集のための栽培実験準備を進めている。

草姿画像以外の重要な説明変数として、植物の周囲の環境データについて検討する。植物の水分ストレスは葉からの蒸散速度が根からの吸水速度を上回ることによって生じるが、蒸散速度は周囲の温度や相対湿度、飽差といった環境データに強く依存する。そのため、周囲の環境変化は植物の水分ストレス状態に影響を与えると考え、実験データを収集した栽培環境下で収集した温度、相対湿度及び飽差 (Vapour Pressure Dificit : VPD) と DSD の関係を分析する。図 11 に環境データと DSD の散布図を示す。図 11(a) に示す 2016 年 8 月 13 日には環境データと DSD の相関は低いが、図 11(b) に示す 2016 年 8 月 31 日には相関が高い。一方で、図 10 に示した CNN から抽出された特徴と DSD の関係では、2016 年 8 月 13 日には高い相関が存在するが、2016 年 8 月 31 日は低い相関であった。つまり、水分ストレスの推定において、CNN で草姿画像から抽出された特徴と環境データ

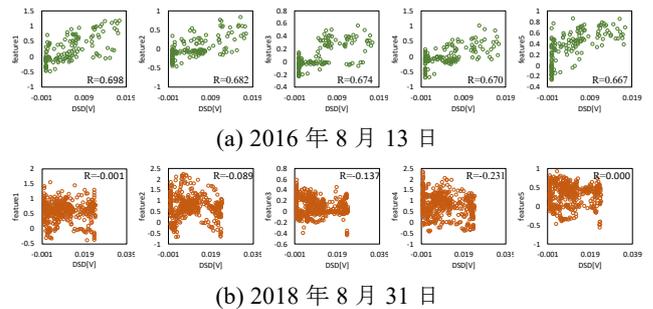


図 10 ROAF 適用画像から抽出された特徴と DSD の散布図

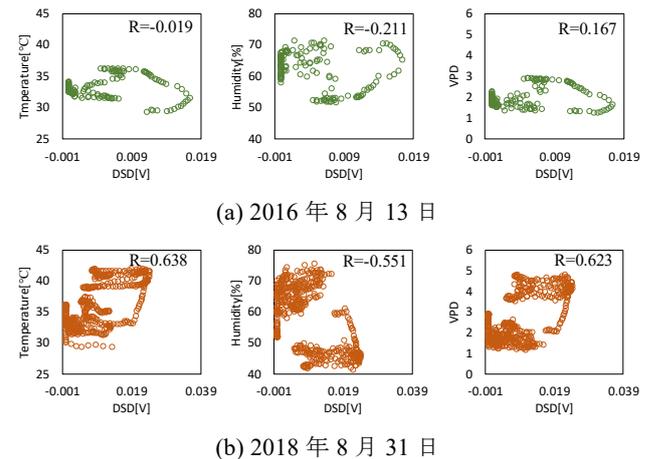


図 11 環境データと DSD の散布図

の重要度は経時的に変化すると考えられる。高精度な水分ストレス推定を実現するためには、草姿画像だけでなく環境データといった異種データを組み合わせ、かつデータ間の経時的な関係の変化にも追従できる推定手法が重要と考える。これまでに、草姿画像と環境データを組み合わせて深層学習で特徴抽出し、経時的に特性が変化するデータに特化した予測手法である Sliding window-based support vector regression[19]を用いて回帰モデルを構築することで高精度に水分ストレスを推定できることを確認している[2]。本実験での分析で明らかとなった草姿画像から得られる特徴と環境データの経時的な関係変化に適した手法であると言えるため、高精度な推定を実現できたといえる。さらに、Recurrent Neural Network (RNN) や Long-short Term Memory (LSTM) を適用すること深層学習自体で経時的な変化を考慮した学習を行うことで、入力データに対する水分ストレスを end-to-end で学習でき、更に高精度な水分ストレス推定モデルの構築が期待できる。

5. おわりに

本研究では、ストレス栽培の形式知化に向け、CNN を用いた植物の水分ストレス推定手法を検討した。CNN の入力画像に対し、植物の萎れに関する特徴抽出性能の向上が期待できる ROAF を適用することで、原画像に比べ少量の訓

練データからも高精度な推定が可能であることが明らかとなった。さらに、既存手法である Optical Flow を HOOF に変換し機械学習を用いて推定する手法を比較したところ、CNN の入力画像に ROAF を適用することで推定誤差を MAE で約 21.9%削減でき、既存手法に比べ熟練農家のストレス栽培を高精度の再現できる見通しを得た。

今後の課題は、画像だけでなく植物の生育に大きな影響を与える環境データを組み合わせ、RNN や LSTM を用いてデータ間の経時的な関係変化に追従する高精度な水分ストレス推定手法の確立である。そして、実際の灌水制御への適用に向けて、水分ストレスの推定だけでなく果実の糖度に影響を与える要因を詳細に分析し、提案手法を用いた水分ストレス栽培のシステム化に向けた検討を進める。

謝辞

本研究は JST さきがけ (JPMJPR15O5) の支援を受けたものである。また、栽培データ収集環境をご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] 農林水産省：農林水産統計 平成 27 年新規就農者調査，農林水産省（オンライン），入手先（<http://www.maff.go.jp/j/tokei/kouhyou/sinki/attach/pdf/index-1.pdf>）（参照 2017-04-03）。
- [2] Kaneda, Y., Shibata, S., Mineno, H.: Multi-modal sliding window-based support vector regression for predicting plant water stress, (submitted to Knowledge-Based Systems).
- [3] Richards, L. A. and Gardner, W.: Tensiometers for measuring the capillary tension of soil water, *Journal of the American Society of Agronomy*, Vol.28, No.5, pp.352-358 (1936).
- [4] Topp, G. C., Davis, J. L. and Annan, A. P.: Electromagnetic determination of soil water content: measurements in coaxial transmission lines, *Water resources research*, Vol.16, Issue 3, pp.574-582 (1980).
- [5] Sano, M., Nakagawa, Y., Sugimoto, T., et al.: Estimation of water stress of plant by vibration measurement of leaf using acoustic radiation force, *Acoustical Science and Technology*, Vol.36, No.3, pp.248-253 (2015).
- [6] Wang, X., Meng, Z., Chang, X., Lv, M., et al.: Determination of a suitable indicator of tomato water content based on stem diameter variation, *Scientia Horticulturae*, Vol.215, No.27, pp.142-148, (2017).
- [7] Meng, Z., Duan, A. and Chen, D.: Suitable indicators using stem diameter variation-derived indices to monitor the water status of greenhouse tomato plants, *PloS One* 12.2 (2017).
- [8] 高山弘太郎, 仁科弘重, 山本展寛ほか: 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).
- [9] 柴田瞬, 峰野博史: Optical Flow を用いた植物萎れ具合の推定, マルチメディア、分散、協調とモバイル (DICOMO2016) シンポジウム, pp.66-72 (2016).
- [10] 若森和昌, 兼田千雅, 柴田瞬ほか: 草姿画像を用いた植物萎れ具合高精度推定, 第 79 回情報処理学会全国大会講演論文集, 5T-01 (2017).
- [11] Simonyan, K. and Zisserman, A.: Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556 (2014).
- [12] He, K., Zhang, X., Ren S., et al.: Deep Residual Learning for Image

- Recognition, *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, (2016).
- [13] Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *Proc. International Conference on Machine Learning*, pp. 448-456, (2015).
- [14] Srivastava, N., Hinton, G., Krizhevsky, A., et al.: Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, Vol.15, pp.1929-1958 (2014).
- [15] He, K., Zhang, X., Ren, S., and Sun, J.: Delving deep into rectifiers: Surpassing human-level performance on imagenet classification, *Proc. IEEE International Conference on Computer Vision*, pp. 1026-1034 (2015).
- [16] Weinzaepfel, P., Revaud, J. and Harchaoui, Z.: Deepflow: Large displacement optical flow with deep matching, *Proc. IEEE International Conference on Computer Vision*, pp. 1385-1392, (2013).
- [17] Tokui, S., Oono, K., Hido, S., et al.: Chainer: a next-generation open source framework for deep learning, *Proc. workshop on machine learning systems in the twenty-ninth annual conference on neural information processing systems*, pp.1-6, (2015).
- [18] Pedregosa, F., Varoquaux, G., Gramfort, A., et al.: Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, Vol.12, pp.2825-2830 (2011).
- [19] Kaneda, Y., Mineno, H.: Sliding window-based support vector regression for predicting micrometeorological data, *Expert Systems with Applications*, Vol.59, no.15, pp.217-225 (2016).