

論文

# AIによる葉の振動波形を用いた植物の灌水制御に関する検討

## Plant irrigation control using AI with vibration measurement of leaf

白川 貴志<sup>\*</sup>・中川 裕<sup>1</sup>・佐野 元昭<sup>2</sup>・杉本 恒美<sup>3</sup>

<sup>\*</sup> <sup>123</sup> 桐蔭横浜大学大学院工学研究科

(2024年3月9日 受理)

### I. はじめに

植物に関する間接的な情報は、市販のセンサーでも得ることが可能である。しかしながら、植物の育成状態に関する直接的な情報を得るためには、育成中の植物の葉や根圏土壌を直接採取するか、もしくは篤農家が直接目視や手で触れることによるのみ把握可能であった<sup>1-4)</sup>。ところが、音波照射加振による葉の共振周波数の日周変化により、植物の健康状態もしくは水ストレスに関する情報を非破壊的に得られる可能性が明らかになってきた<sup>5-12)</sup>。特に水ストレスの有無による葉の共振周波数の日周変化を利用すれば、植物育成に最適な灌水時期の推定を行える可能性が高い。しかしながら、どの時点で灌水を行うかの判定基準はまだ明確になっていない。そこで、本研究では植物の葉の共振周波数の日周変化に対して深層学習の適用を試みることにより、農業初心者でも手軽に使える最適な灌水制御法を確立することが目的である。

葉の共振周波数の日周変化から得られる情

報をどのようにして植物育成に必要な灌水制御に利用するかについては、人間の判断を必要としている段階であり、誰でも手軽に利用できる状態には至っていない。ところが、近年の並列計算技術の発展により、このような複雑な振動波形解析に対して深層学習いわゆるディープラーニングを活用すること自体が、一般的に用いられるような状況になってきた。この深層学習を活用すれば、人間が目視に頼ってきた波形解析の労力を劇的に軽減できるばかりでなく、特に教師データ（正解、不正解）を与えなくても、振動波形（解析データログ）のクラスタリング（種類分け）が可能となる。このことはすなわち、振動波形に対する判断が特に解析の知識が無くても行えることを意味している。

本研究では植物に水ストレスを与えた場合のアクティブな音波照射加振による葉の振動波形に対して、深層学習法の一つであるDNN（Deep Neural Network）の中でも時系列データを考慮できる「回帰型ニューラルネットワーク」RNN（Recurrent Neural Network）を改良したLSTM（Long Short Term

<sup>\*</sup> SHIRAKAWA Takashi: Researcher, Graduate School of Engineering, Toin University of Yokohama. 1614, Kurogane-cho, Aoba-ku, Yokohama 225-8503, Japan

<sup>1</sup> NAKAGAWA Yutaka: Researcher, Graduate School of Engineering, Toin University of Yokohama

<sup>2</sup> SANO Motoaki: Professor, Graduate School of Engineering, Toin University of Yokohama

<sup>3</sup> SUGIMOTO Tsuneyoshi: Professor, Graduate School of Engineering, Toin University of Yokohama

Memory)、および画像認識に特化したCNN (Convolutional Neural Network) を用いて学習を行った。

## II. 実験方法

### 1. 実験条件

#### (1) 試験植物

計測対象用の植物としては、研究室内で育成制御しやすいナス (*Solanum melongena*) を用いた。

#### (2) 葉の加振方法

葉の加振は、パラメトリックスピーカ (日本セラミック, AS101AW3PF1) が発する 40 kHz の超音波の音響放射圧を用いた。ファンクションジェネレータ (Tektronix Inc., AFG3022) から  $V_{p-p} = 1$  V の正弦波を 5 分間隔、1 s 間印加することにより起こる葉の減衰振動変位を、上方からレーザ変位計および CCD カメラで計測した。概要を図 1 に示す。




図 1 実験セットアップ

#### (3) 環境設定

日周変動を誘発するために蛍光灯のオンオフを利用して部屋の明るさを調整し、水分センサを用いて土壌の含水率変化を並行して計測した。

## 2. 育成経過

育成経過の観測より、別植物 (小松菜) と同様な葉の減衰振動推移と日周変動が確認された。育成が安定した後に水ストレスを与えることで葉の健康状態の変化を促し、深層学習に必要な各状態の振動波形データを取得した。

## III. 測定結果に対する深層学習の適用

### 1. RNN (Recurrent Neural Network) の適用

#### (1) RNN, LSTM について

水ストレスなどの有無による葉の共振周波数の日周変化データをディープニューラルネットワーク (DNN) に入力しデータの変化傾向の違いを自律的に学習させ、水ストレスの有無を判定できるかどうかについての検討を行う目的で、DNN の中でも時系列データを考慮できる「回帰型ニューラルネットワーク」RNN (Recurrent Neural Network) を改良した LSTM (Long Short Term Memory) を用いた。Python を利用してナス葉の固有振動数変化を学習させ、短期変化データを入力すると固有振動数の先行きを予測する試行を行った。

RNN (Recurrent Neural Network) とは「回帰型ニューラルネットワーク」と訳される、時系列データを考慮できるニューラルネットワークで時系列データ、音声データ、機械翻訳、自然言語処理などで使用される。LSTM (Long Short Term Memory) とは RNN の拡張として登場した時系列データに対するモデルで Long term memory (長期記憶) と Short term memory (短期記憶) という用語から取られ、長期短期記憶と訳される。中間層のユニットを LSTM block (Constant Error Carousel) と呼ばれるメモリと 3 つのゲートを持つブロックに置き換えることで実現されている、長期依存性の問題を解決できたモデルである。この LSTM を

取得データに対して適用する。

(2) LSTMの適用結果

時系列データに特化した深層ニューラルネットワーク (DNN) の一種であるRNNを改良したLSTMを受信波形結果に適用し、波形変化の未来予測を検討した。10日間のナス葉振動数推移 (5分間隔) を図2に示す。横軸は日数、縦軸は葉振動数を表す。




図2 10日間のナス葉振動数推移




図3 葉振動数推移に対するLSTMの適用 (全データ2880, 入力データ36)

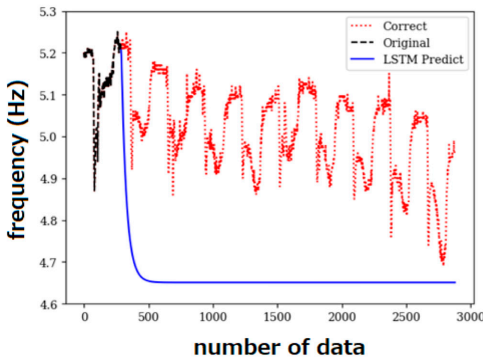


図4 葉振動数推移に対するLSTMの適用 (全データ2880, 入力データ288)

ある範囲の時刻データを入力データとし、

その直後の数値を正解データと設定する。この範囲と正解データを移動させながら学習を進める。図3に全データ数2880、入力データ36に対して正解データ+1番目(37番目)の学習予測結果を、図4に全データ数2880、入力データ288に対して正解データ+1番目(289番目)の学習予測結果を示す。

図3では予測が大きく逸れ、図4では半日ほどの傾向は予測できているが、その後の日周変動は予測できていない。

予測が逸れる原因の一つに、入力データの細かい変化の影響が挙げられる。そのため、元データの平滑化処理を行った上で再度LSTMを適用した。図5、6は、元データ

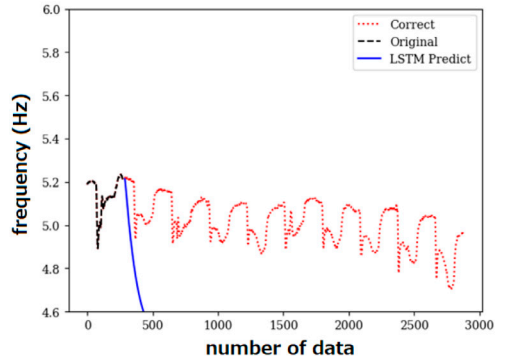


図5 平滑後葉振動数推移に対するLSTMの適用 (全データ2880, 入力データ36)

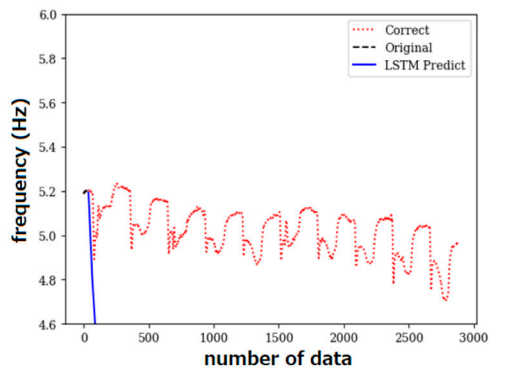


図6 平滑後葉振動数推移に対するLSTMの適用 (全データ2880, 入力データ288)

に移動平均幅5で平滑化を行った上で、予測に用いる利用データ数36、288のLSTM適用結果となる。

多少の改善は見られたが、その後の日周変動の予測までは十分ではない。機械学習にとって重要である入力データの最適処理、学習環境の設定などの問題で理想的な予測が出力されていない結果となった。

## 2. CNN (Convolutional Neural Network) の適用

### (1) CNN について

次に、葉の振動波形に対して深層学習法の一つである Deep Neural Network (DNN) の中でも画像認識に特化した Convolutional Neural Network (CNN) を用いて学習を行った。学習データを葉の健康状態に応じて複数にクラス分けし、新規データがどのクラスに該当するかを判定させる。

CNN (Convolutional Neural Network) とは画像認識に特化した Deep Learning の1つで基本的には、「畳み込み層」&「プーリング層」の組み合わせを複数回繰り返したあと、最後に全結合して出力する。

### (2) CNN の適用結果

画像認識に特化した深層ニューラルネットワーク (DNN) の一種である畳み込みニューラルネットワーク (CNN) を、水ストレスの有無に応じた受信波形の結果に適用し、クラスタリングの可能性を評価した。図7にナスの葉の周期的な振動数変化を示す。横軸は日数、縦軸は葉振動数を表す。楕円で囲まれた領域は、各健康状態のクラスタを示している。各クラスタの状態は healthy (通常通り給水が行われている)、caution (給水をストップし、振動数に変化が現れる)、dan-




図7 平滑後葉振動数推移に対する LSTM の適用 (全データ 2880, 入力データ 288)

ger (給水を再開するが、振動数は大きく変化している)、recover (給水を継続、振動数は元に戻る) の4区分となる。各波形や日周変動の変化は水ストレスに応じているのだが、葉の画像や直接目視では判定が難しい。

図8に示すように、各取得波形の振幅最大値、最小値、データ数を揃えた画像化を行う。図9は各4クラスタの代表的な変換後画像となる。クラスタ毎に100枚の画像を準備し、CNNの学習に用いる。

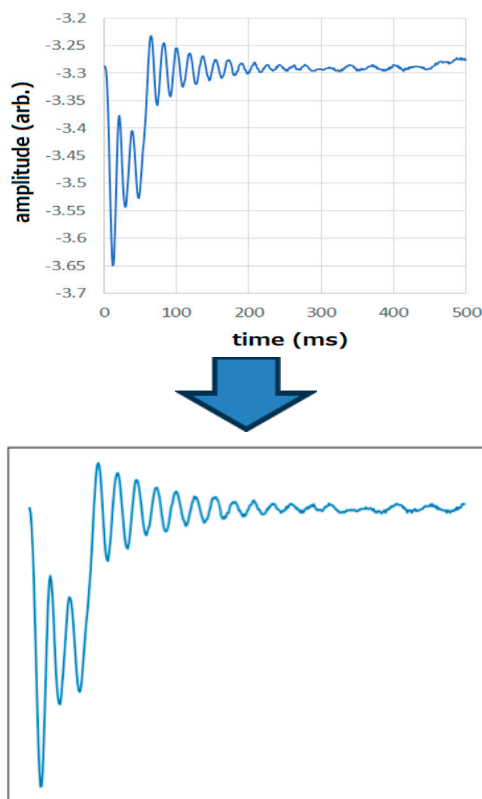


図8 取得波形の画像化

各クラスタ画像の特徴としては、caution クラスタ期間内には給水を止めているにも関わらず healthy と caution クラスタ画像は人間の目には差異が認められない。それに対して danger クラスタ画像は波形にひずみが生じていることが多い。これは波形だけではなく、カメラ画像にも萎れの様子が現れてくる。recover クラスタ画像は healthy と caution クラスタ画像と同じ挙動へと回復する上、振




図9 各4クラスの変換後画像

幅差が増加している傾向がある。図7では recover クラスの日周変化も healthy と caution クラスに比べて明確になっているが、これらが水ストレスからの回復によるものなのか、植物の生長によるものかは不明である。

各クラス内のトレーニング画像から特徴を抽出し、学習された特徴をクラスタリングデータとして使用する。新しい波形画像に事前に学習されたクラスタリングデータを適用して認識とクラスタリングを行う。図10はこのプロセスのフローチャートを示している。

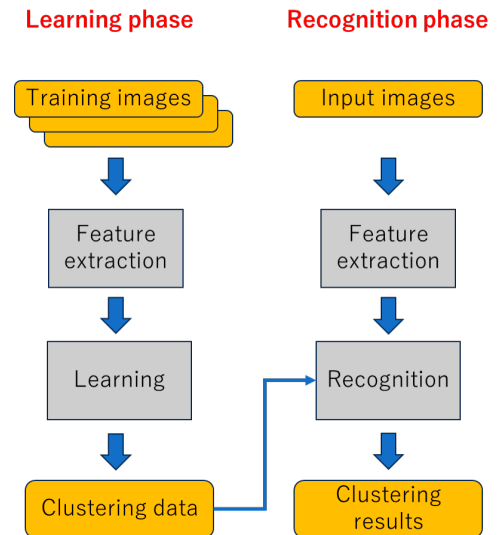


図10 CNNによる学習プロセスのフローチャート

学習プログラムは Google Colaboratory 上で Python を用いて作成した。画像をピクセル単位で数値化し、フィルタを通して画像の特徴を抽出する（畳み込み）。その後、画質を粗くすることによって画像のズレを補正する。画質を粗くする事で境界があいまいになり、画素が多少シフトしても同じものだと認識できるようになる（プーリング層）。これらの処理を繰り返すことにより学習を進め、全結合して学習済みモデルとして出力する。

前述した各クラスの画像を数値データに変換し、ニューラルネットワークのモデルを作成する。総データを学習データとテストデ

ータ (8:2) に振り分け、epoch = 100 の条件で学習を行った。正解率、誤差をグラフ化した結果を図 11,12 に示す。横軸は epoch (試行回数)、図 11 の縦軸は正解率、図 12 の縦軸は誤差を表す。




図 11 CNN による学習結果の正解率




図 12 CNN による学習結果の誤差

この学習済みモデルを使用し、新規データのクラスタリングが正しく行われるかを試みる。各 4 クラス healthy、caution、danger、recover から学習時には使用していなかった新規データを 5 つずつ、計 20 データ用意して判定を行う。healthy クラスの画像が healthy と判定されれば正解、それ以外のクラスと判定されれば不正解とする。新規データを替えてこのクラスタリング試行を 20 回行った正解率を図 13 に示す。




図 13 CNN によるクラスタリング試行の正解率

今回の試行では、新しい波形データのクラスタリングは 90% 以上の精度で行われた。精度をさらに向上させるためには、過学習の防止、ハイパーパラメータの最適化、自動化など、CNN プログラムの改善が必要となる。

#### IV. 結論

本研究では植物に水ストレスを与えた場合のアクティブな音波照射加振による葉の振動波形に対して、深層学習法の一つである DNN の中でも時系列データを考慮できる RNN を改良した LSTM、画像認識に特化した CNN を用いて学習を行った。

LSTM を適用して植物の萎れを予測するためには、機械学習にとって重要である入力データの最適処理、学習環境の設定などの問題を解決する必要性が示唆された。

CNN を適用して葉の健康状態に応じて振動波形データを複数にクラス分けして学習、新規データがどのクラスに該当するかを判定させた結果、クラスタリングが高精度で行われた。水ストレスを受けつつある波形データが CNN のクラスタリングにより検出されることで、最適な灌水タイミングを自動検出できる可能性が示された。

謝辞

本研究は、JSPS 科研費 21K05855 の助成を受けて実施されたものである。

【参考文献】

- 1) 仁科他, 農業環境工学関連7学会2005年合同大会講演予稿集, p.390, (2005)
- 2) 稲村實, 光技術コンタクト, Vol.44, No.4, pp.203-208, July (2006)
- 3) 特開2005-308733「植物の受けるストレスの測定方法及び装置」長崎県(兵頭竜二)
- 4) Tsuneyoshi Sugimoto, Yutaka Nakagawa, Takashi Shirakawa, Motoaki Sano, Motoyoshi Ohaba, and Sakae Shibusawa, "Study on Water Distribution Imaging in the Sand Using Propagation Velocity of Sound with Scanning Laser Doppler Vibrometer", Jpn. J. Appl. Phys. Vol.52, 07HC04, (2013.07)
- 5) Motoaki Sano, Tsuneyoshi Sugimoto, Hiroshi Hosoya, Motoyoshi Ohaba, and Sakae Shibusawa, "Basic Study on Estimating Water Stress of a Plant Using Vibration Measurement of Leaf", Jpn. J. Appl. Phys. Vol.52, 07HC13 (2013.7)
- 6) Motoaki Sano, Tsuneyoshi Sugimoto, Takashi Shirakawa, Kaoru Yamagishi, Toshiaki Sugihara and Sakae Shibusawa, "Estimation of water stress of plant by vibration measurement of leaf using acoustic radiation force", Motoaki Sano, Yutaka Nakagawa", Acoust. Sci. & Tech. 36, 3, pp.248-253, (2015.6) [doi:10.1250/ast.36.248]
- 7) 内川千春, 杉本恒美, 佐野元昭, 大平武征, 中川裕, 白川貴志, "植物の葉の固有振動数の日周変動を用いた灌水制御についての検討", 桐蔭論叢, 第38号, pp.121-126, (2018.6)
- 8) 杉本恒美, 佐野元昭, 内川千春, 大平武征, 中川裕, 白川貴志, "音波振動を用いた植物の育成状態評価に関する検討", 日本生物環境工学会, 2018年東京大会講演要旨集, OS45, pp.272-273, (2018.9.20, 東京農工大)
- 9) 佐野元昭, 内川千春, 大平武征, 白川貴志, 中川裕, 杉本恒美, "CCDカメラを用いた葉の固有振動計測による植物の水分ストレスの検出2", 日本生物環境工学会, 2018年東京大会講演要旨集, P3-08, pp.194-195, (2018.9.21, 東京農工大)
- 10) 佐野元昭, 内川千春, 大平武征, 白川貴志, 中川裕, 杉本恒美, "映像の矩形分割による葉の固有振動数計測法を用いた植物の水分ストレス推定", 桐蔭論叢, 第38号, pp.109-114, (2019.6)
- 11) 内川千春, 杉本恒美, 佐野元昭, 大平武征, 中川裕, 白川貴志, "画像解析による植物の葉の固有振動数計測", 桐蔭論叢, 第38号, pp.115-120, (2019.6)
- 12) 大平武征, 杉本恒美, 佐野元昭, 中川裕, 白川貴志, 内川千春, "小松菜を定植した培養土中の音波伝搬速度と体積含水率の検討(Ⅲ)", 桐蔭論叢, 第38号, pp.121-126, (2019.6)