

# 小規模な正解ラベル付きデータを用いた CNNに基づくエノコログサの分けつ数の推定

中村 浩一朗<sup>1)</sup>, ○内海 ゆづ子<sup>1)</sup>, 岩村 雅一<sup>1)</sup>, 黄瀬 浩一<sup>1)</sup>

1)大阪府立大学 大学院工学研究科, 〒599-8531 大阪府堺市中区学園町 1-1

## 要旨

地球温暖化などの異常気象による農作物の不作の解決を目指して, 植物育種学の分野で農作物の収量性の向上を目指した研究が行われている. このような研究では, フェノタイピングという作業において膨大な数の植物の形状を手動で計測する必要がある. これには, 人手や手間がかかるため, 計測の自動化が必要とされている. 近年では, Deep Learning を用いて植物画像から形状を自動で計測する研究が行われているが, これには正解ラベル付きの大量の植物画像が必要になり, 用意するのは容易ではない. そこで, 本研究では, Self-supervised Learning によって小規模な正解ラベル付きデータを用いた植物の形状計測の手法を提案する. 実験では, イネ科植物のエノコログサの分けつ数を推定し, 既存研究よりも高い精度を示した.

## キーワード

フェノタイピング, 分けつ数推定, Deep learning, Self-supervised learning

## はじめに

近年, 地球温暖化などの異常気象による農作物の不作により, 食料不足は深刻な問題となっている. その中で, 植物育種学の分野で農作物の収量性の向上を目指した研究が行われている. このような研究では, 植物の形質と遺伝子の対応についての調査を行う. 遺伝子の発現には, 様々な環境パラメータが関わっている. そのため, 多様に変化させた環境下で生育した植物の形状を測定し, 植物の形質と遺伝子の発現の対応の調査が必要である. 植物の形状の計測では, 背丈や葉の枚数, 実の大きさなどを計測対象としており, これらを手動で計測すると人手や時間がかかるため, 計測の自動化が必要とされている.

このような背景から, Deep Learning を用いて植物画像から形状を自動で計測する研究が行われている(Namin et al. 2018). Deep Learning を用いた方法では, 形状に関するデータを正解ラベルとして付加した大量の植物画像を用いて教師あり学習を行うことで, 高精度な自動計測を可能にしている. 植物画像に対するラベル付けは手動による植物の形状計測によって行われる. そのため, ラベル付けされた大量の植物画像の作成は容易でない.

そこで, 本研究では, Self-supervised Learning を用いた

植物の形状計測の手法を提案する. Self-supervised Learning では, 自動で付与できるラベルを用いて植物画像の特徴表現の学習を行う. 学習された特徴表現を用いることでラベル付けされた植物画像が少量であっても形状の高精度な自動計測が期待できる. 本研究では, 最初の取り組みとして, イネ科植物のエノコログサを例にとり, 生育の指標として重要な分けつ数を推定する.

## 既存研究

本節では, 画像を用いたエノコログサの分けつ数推定の既存研究としてFahlgrenらの研究(Fahlgren et al. 2015)について述べる. Fahlgrenらは, 195枚の画像の植物の形状の測定を行い, 分けつ数は植物の縦幅と横幅の比率及び, バイオマスと相関関係があるとした. バイオマスとは, 一定の空間にある植物の総量である. そして, 縦幅と横幅の比率とバイオマスを説明変数とし, 最小二乗法を用いて分けつ数をモデル化している.

## 提案手法

本研究では, 少量のラベル付き植物画像を用いて分けつ数の推定を行う. Deep Learning の学習には多量の学習データが必要になるので, このデータをそのまま分けつ数推定の

学習に使用しても高精度な推定は不可能である。そのため、まず、分けつ数の推定とは関係のなさそうなタスク (pretext task) で大量の植物画像からその特徴表現を学習し、得られる植物画像の特徴表現を分けつ数推定の学習に使用する。本研究では、ラベル付けされていない植物画像を用いて、画像処理により自動習得できる値を推定するタスクを pretext taskとして、特徴表現の学習を行う。この、画像処理で自動的にラベルを付与し、学習する手法は Self-supervised learningと呼ばれる。使用するラベルとしては、Fahlgren らの研究 (Fahlgren et al. 2015) を参考にして、植物の縦幅と横幅の比率及び、画像中の植物のピクセル領域の値を使用する。本研究では、VGG16 (Simonyan et al. 2014) を用いて、1枚の植物画像を入力とし、縦幅と横幅の比率または、画像中の植物のピクセル領域の値を予測するように学習を行う。そして、識別を行う全結合層の直前の出力を特徴量として用いる。そして得られた特徴量とSVRを用いて、分けつ数の推定を行う。

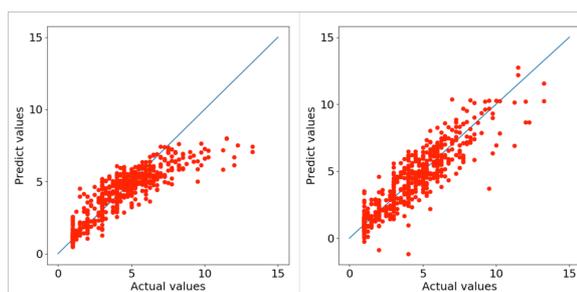
## 実験

本研究では、Fahlgrenらの研究 (Fahlgren et al. 2015) で使用されたエノコログサを側面から撮影した画像データセットを用いた。Pretext taskで用いるラベルの付いていない10,000枚の植物画像を用いた。これらの画像に対し、植物を対象とした画像解析ソフトウェアである PlantCV (Gehan et al. 2017) を用いて植物の縦幅と横幅の比率及び、画像中の植物のピクセル領域の値を取得し、それらの値の大小の順に従ってデータセットを4クラスまたは8クラスに分類し4種類のデータセットを作成した。それぞれのデータセットを用いて、VGG16 (Simonyan et al. 2014) の ImageNetで学習済みのpre-trainedモデルを用いて識別問題を行い、4つの特徴抽出器を作成した。分けつ数の推定には577枚の分けつ数をラベルとして付加した植物画像を用いた。そして、4つの特徴抽出器から得られた特徴量とSVRを用いて分けつ数の推定を行い、精度を評価した。SVRは、カーネルに多項式カーネルを用い、コストパラメータC = 0:001 で推定した。分けつ数の推定精度は6-fold cross-validationで絶対平均誤差を用いて評価した。

Fahlgren らの研究 (Fahlgren et al. 2015) 及び4つの特徴抽出器を用いた場合とpre-trained モデルを特徴抽出器とした場合のそれぞれの精度を表1に示す。Fahlgrenらは646

表1 分けつ数の推定精度

		絶対平均誤差
Fahlgrenらの研究		0.98
pre-trainedモデル		0.82
縦幅と横幅の比率	4クラス	<b>0.80</b>
	8クラス	1.01
ピクセル領域	4クラス	1.03
	8クラス	1.09



(a)pre-trained (b)縦幅と横幅の比率-4クラス

図1 分けつ数の推定値の分布

枚の画像を用いて精度評価を行なっているのに対し、提案手法はデータセットの不備によりFahlgrenらの研究で用いられたデータセットのうち577枚の画像で精度評価を行なった。表1より縦幅と横幅の比率による4クラス問題が最も精度が高く、pre-trained モデルと比較しても精度が向上したが、その他のPretext task では精度が低下していた。図1にpre-trained モデル及び、縦幅と横幅の比率による4クラス問題で作成した特徴抽出器を用いた際の分けつ数の推定値の分布を示す。横軸を実測値、縦軸を推定値として点をプロットしている。これらの点は、正しく分けつ数を推定できているほど、図中の対角線の近くにプロットされる。pre-trained モデルを特徴抽出器とした場合、分けつ数が多くなると推定精度が著しく低下していた。Pretext taskでの学習によって、そのような分けつ数の増加に伴う推定精度の低下が改善されていることがわかる。

## まとめ

本論文では、植物画像から分けつ数を推定する手法として、Self-supervised Learningによる特徴表現学習を用いた手法を提案し、精度評価を行なった。植物の縦幅と横幅の比率を用いて特徴表現を学習と、最も精度良く分けつ数の推定ができることが分かった。しかし、データセットのクラス数を増やして特徴表現を学習すると推定精度が低下した。今後の課題として、推定精度の向上のために他のpretext taskについても検討することが挙げられる。

## 引用文献

- S. T. Namin, et al. Deep phenotyping: deep learning for temporal phenotype/genotype classification. *Plant methods*, 14(1):66, 2018.
- N. Fahlgren, et al. A versatile phenotyping system and analytics platform reveals diverse temporal responses to water availability in setaria. *Molecular plant*, 8(10):1520-1535, 2015.
- H. Drucker, et al. Support vector regression machines. In *Advances in neural information processing systems*, pp.155-161, 1997.
- K. Simonyan, et al. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- C. Cortes and V. Vapnik. Support-vector networks. *Machine learning*, 20(3):273-297, 1995.
- M. A. Gehan, et al. Plantcv v2: Image analysis software for high-throughput plant phenotyping. *PeerJ*, 5:e4088, 2017.