

Self-supervised Learning を用いた 画像からの単子葉植物の分けつ数推定

黄瀬 陸哉^{1,a)} 内海 ゆづ子^{1,b)} 岩村 雅一^{1,c)} 黄瀬 浩一^{1,d)}

概要: 単子葉植物における収穫量の指標の1つである分けつ数を計測することは、労働集約的である、破壊調査を伴うといった問題がある。この問題に対して、従来研究では、self-supervised learning (SSL) を用いることで、deep neural network に基づく画像からの分けつ数推定を実現している。しかし、この手法の実験では、成長度合いによって背景の映り方が異なるデータセットを使用しており、植物形状以外の情報を用いて分けつ数の推定をしている可能性がある。本研究では、画像中に植物形状の情報のみが含まれるようデータセットを正規化し、SSL を用いた手法の有効性を検証した。実験の結果、SSL を用いた分けつ数の推定手法は正規化したデータセットにおいても有効であることがわかった。

1. はじめに

世界的な人口の増加に伴い、穀物の需要が増加している。この穀物の需要をまかなうために、2050年までに2011年の収穫量の60%から110%までに収穫量を増加させる必要があると予測されている [1]。この課題に取り組むべく、植物育種学や植物遺伝学の分野では作物の品種改良の研究が盛んに行われている。

近年の品種改良の技術は、植物の遺伝型データ (ジェノタイプ) が、植物の形状や成長速度、環境応答などといった形質としてどう表現されるか (フェノタイプ) を特定することが主である。Polymerase chain reaction (PCR) 法を始めとするジェノタイプ技術の急速な発展により、高スループットな作物のジェノタイプの特定ができるようになった。しかし、フェノタイプの特定のための植物の定量計測 (フェノタイピング) の技術の発展は遅れをとっており、フェノタイピングが現在の品種改良研究のボトルネックになっている。そのため、高スループットなフェノタイピング技術の研究開発が急がれている。

穀物のうち、イネ、小麦、トウモロコシなどの単子葉植物には分けつという形質がある。分けつの例を図1に示す。分けつとは、単子葉植物の根からの枝分かれのことを言う。この数は単子葉植物の収穫量を決定する指標であ

り [3] [4]、単子葉植物のフェノタイピングにおいて分けつ数を数えることは重要な役割を担う。しかし、分けつ数を手作業で数えることは時間がかかる、破壊調査が必要で継続的な調査ができないといった問題がある [5]。そのため




図1: イネの分けつの例 [2]。イネの分けつは不伸長茎部 (画像中 B) の葉の脇芽から出現し、伸長茎部 (画像中 A) からは出現しない。数字は分けつが出現した葉位を示す。

¹ 大阪府立大学 大学院工学研究科 知能情報工学分野
Osaka Prefecture University
a) kinose@m.cs.osakafu-u.ac.jp
b) yuzuko@cs.osakafu-u.ac.jp
c) masa@cs.osakafu-u.ac.jp
d) kise@cs.osakafu-u.ac.jp

に、非破壊かつ自動の分けつ数推定手法が望まれている。

そこで、本稿では、非破壊かつ自動の分けつ数推定を画像認識によって実現する。昨今の画像認識では、deep neural network (DNN) に基づく手法が主流となっており、様々なタスクで好成績を収めている [6]。そのため、画像に基づく分けつ数の推定に対しても DNN が有用であると期待できる。しかし、一般的に DNN による推定は大規模な教師データによる学習を必要とする。先述の通り、分けつ数の計測には非常に手間がかかるため、分けつの教師データを大量に集めることは困難である。そのため、教師データが少なくても分けつ数を推定できる手法が望ましい。そこで、内海ら [7] は、ラベル付けが少量しかされていないデータセットからでも分けつ数の推定を行うために、self-supervised learning を用いる手法を提案している。

しかし、この内海らの手法は精度評価に用いられたデータに問題がある。この手法の実験で使用された画像データセット [8] は、成長段階によって撮影する倍率を人為的に定められたものである。そのために、成長段階によって背景の写り方が異なっており、背景の特徴によって大まかな分けつ数推定ができてしまうという問題があった。また、フェノタイピングの自動化という観点から見れば、人為的要素がなるべく排除された状況で分けつ数が推定できることが望ましい。

そこで、本稿では画像の正規化を行ったデータセットにおいて、内海らの手法が有効であるかを検証する。また、[7] の検証していない DNN モデルについても、検証する。

2. 関連研究

本章では、既に考案されている分けつ数推定手法や、植物を対象にした DNN に基づく手法、そして self-supervised learning に関連する研究について述べる。

2.1 分けつ数の推定手法

分けつは単子葉植物の生育状態の把握のための指標としても一般的に用いられている。そのため、旧来から分けつ数の推定手法は多く考案されてきた。Flowers らは、リモートセンシングを用いて圃場の近赤外光、可視光の反射率を測定し、分けつ密度の推定を行う手法を提案している [9]。また、Scotford と Miller は、トラクターに取り付けた分光器を使い、normalized difference vegetation index を測定し、分けつ密度の推定を行う手法を提案している [10]。しかし、これらの分けつ数の推定手法では大域的に見た分けつの密度しか推定できず、個体の分けつ数を調査することには適していない。また、大規模な圃場が必要であったり、撮影のために晴天の日を選ぶ必要があるなど、計測の制約条件が厳しい問題もある。

これに対して、植物画像を用いて植物個体の分けつ数を推定した手法が考案されている [5] [8] [11]。Boyle らや

Fahlgren らは、可視光で撮影された画像から画像処理を用いて、分けつ数を推定した [5] [8]。これらの手法では、発見的な特徴量を用いて回帰推定を行っており、特徴量の次元数が小さいために回帰式の表現力が低いという問題がある。また、Wu らは可視光線と X 線による撮影を組み合わせさせて高精度な分けつ数推定を実現した [11]。しかし、この手法では大掛かりな設備と莫大な費用が必要であることから、一般的に用いるには現実的ではない。

2.2 植物を対象にした DNN に基づく手法

近年の画像認識では DNN に基づく手法の研究が盛んであり、これは植物を対象にした研究においても例外ではない。Wang らは、麦の圃場において、トラクターに取り付けたカメラによって上方から撮影された麦の画像から、DNN に基づいて成熟度を推定する手法を提案している [12]。この手法では、麦の個体の分別をせずに平均的な成熟度を推定するために、個体の分けつ数の調査への応用は難しい。また、Jin らは、刈り取られた麦を上方から撮影した画像から DNN に基づく物体検出によって茎の切り口の数を数える手法を提案している [13]。麦の茎の数は分けつ数に近い指標であるが、地上からの枝分かれは分けつには含まれないので、この手法は分けつ数推定とは異なる問題に対してのものである。また、この手法では刈り取った後にしか使えず、継続的な調査ができない。

その他の分けつ数の推定に近い問題には leaf counting がある [14] [15]。これらの手法では、シロイヌナズナやタバコのように葉が放射状に広がる植物 (ロゼット植物) の葉の計数を目的とし、上方から撮影した画像に対し、DNN に基づいた葉の数の回帰推定を行っている。しかし、単子葉植物の分けつはロゼット植物の葉とは異なり、上方から撮影された画像を用いて計数することが難しく、この手法を分けつ数の推定に応用することは難しい。

2.3 Self-supervised Learning

Self-supervised learning は大規模なラベル付きデータを収集することが現実的ではない場合に DNN を用いるための手法として考案されてきた。深層学習では従来、小規模な教師データのみで DNN を学習すると十分な特徴表現を得られないという考えから、CIFAR-10 [16] や ImageNet [17] といった大規模なラベル付データセットによる学習が主流であった。これに対して、self-supervised learning では、利用可能な大規模なラベル無しデータから自動でラベル付けの可能な問題を用いて特徴表現を得ることで、データセットのラベル付けを少なくすることを可能にした。

自動でラベル付け可能な問題として、入力画像をそのままラベルとする、すなわち入力画像を再構成する方法 (auto encoder) がある [18] [19] [20]。Hinton らは、encoder-decoder 型の auto encoder モデルを構成することで、入

力画像の特徴表現を学習する手法を提案している [18]. Vincent らは、ノイズを付与した入力画像に対し、ノイズを除去するように auto encoder モデルを学習させる手法を提案している [19]. また、Zhang らはカラー画像をグレースケール画像に変換したのち、カラー画像に再度変換するように auto encoder モデルを学習させる手法を考案している [20]. これらの手法は、画像そのものを再構成するという問題の難しさに欠点がある.

Self-supervised learning では、一見すると関係のなさそうな問題を用いても、目的の問題に対して有効な特徴表現を得られることが実験的に明らかにされている. この一見すると関係のなさそうな問題のことを pretext task と呼ぶ. すでに考案されている pretext task には、画像を分割し、その配列を判別する問題 [21] [22] や、画像を回転させ、その回転角を判別する問題 [23] などがある. Pretext task は auto encoder に比べて単純な問題でも目的とする問題に有効な特徴表現を得られるという利点があり、分げつ数推定にもその効果が期待できる.

3. 分げつ

本節では、本稿での計測対象である分げつについて述べる. 分げつは、単子葉植物において、茎に生じた葉の側芽が発達した分枝のことをいう. 分げつが出穂 (穂が出ること) するかはどうかは、分げつが発達する時期によって決定される. そのため、分げつの増減を継続的に調査していくことは収量予測に有効である. また、株の生育過程における分げつの増え方は、水や窒素量、株の密集度等の生育環境に強く影響を受けることから、これらの環境要因との関係がよく研究されている [8] [24] [25].

分げつの増え方をイネを例にとり説明する. まず種子から発芽し、茎が発達する. この茎を主稈と呼ぶ. 主稈から葉が数枚出現すると、下位の葉のわきの側芽が発達して分げつとなる. イネの場合は、出現した葉の3枚下の葉から分げつが生じるという規則に概ね従っている. 成長していくと主稈のみでなく、分げつからも新たに分げつを生じる. ここで、主稈から生じる分げつを1次分げつと呼び、 n 次分げつから生じる分げつを $n+1$ 次分げつと呼ぶ. 十分に生長したイネの分げつの状態を図案化したものを図2に示す. この図2のように、イネでは第1葉からは分げつが生じないことが多い. また、先述のように水や窒素量の多寡や株間の疎密によっては休眠する側芽が存在するので、少ない場合には分げつが1本も出ないことがある.

本稿では、この主稈と n 次分げつの総数である分げつ数を計測対象とする. 図2では、主稈が1本、1次分げつが9本、2次分げつが21本、3次分げつが10本出現しているので、分げつ数は41である.




図2: 主稈の第13葉が出現するまで生長したイネの分げつの様子 [2]. 主稈には $13 - 3 = 10$ 葉目まで分げつが生じている.

4. 内海らの手法

本節では、self-supervised learning のうち pretext task を用いることで、DNN に基づいた分げつ数推定を行った内海ら [7] の手法について述べる.

4.1 手法の概要

内海らは、分げつ数のラベル付けがされていない大量の植物画像データセットを用いて、pretext task によって DNN モデルを学習させ、そのモデルを用いて分げつ数のラベルのついた画像データセットから分げつ数の回帰推定を行った.

まずはじめに、内海らの用いた pretext task について説明する. 内海らは、植物の画像から、画像中での面積や縦横比を推定する問題を pretext task として用いて、DNN を学習している. 面積や縦横比は Fahlgren らの研究 [8] において分げつ数の推定のために用いられた特徴量であり、分げつ数に関する指標である. また、内海らが用いたデータセットは、均一な照明環境下で撮影されていたため、簡単な画像処理で自動的に植物領域の切り出しが取得可能である. これらの理由から、面積や縦横比の推定を pretext task として用いている. 面積や縦横比の推定は、これらの数値の回帰推定問題に加え、数値を離散化し、離散値を予測するクラス分類問題としても扱っている.

続いて、回帰について説明する. Pretext task により得られた DNN モデルを用いて、画像から特徴抽出を行い、この特徴量をもとに回帰推定を行った. 回帰にはデータセットのうち、分げつのラベルがつけられたものの一部を用いて回帰モデルの学習を行い、残りのデータを用いて評価を行った. 回帰モデルには、カーネルにより非線形回帰問題も扱うことが可能で、ノイズに頑健な support vector regression (SVR) [26] を用いた.

実験の結果、内海らの手法は、Hand-crafted な特徴を用いた Fahlgren ら [8] よりもより良い推定結果を示し、




図 3: 内海らの実験で用いられた画像例。




図 4: 正規化を行った画像例。

Pretext task で学習した特徴表現が分げつ数推定に有効であることが示された。

4.2 評価の問題点

この内海らの手法の実験に用いられた画像データセットには倍率に関する問題がある。データセットの一部を図 3 に示す。このデータセットは、室内環境で数週間に亘って栽培されたエノコログサを、同一照明条件の下で数日おきに 1 株ごとに横方向から撮影されたものである。画像の色空間は RGB 色空間で、画像サイズは $2,454 \times 2,056$ pixels、画像形式は PNG である。図 3 に示すように、撮影倍率は株の成長度合いに応じて 500 倍、700 倍、2500 倍、3500 倍の 4 種類から人為的に決定されており、倍率によって鉢や背景の写り方が異なっている。また、鉢や背景の写り方の違いに注目した特徴表現を DNN モデルが学習してしまい、その特徴表現で回帰推定を行ってしまうおそれがある。そのために、内海らの手法は倍率の条件が揃ったデータセットで検証することが望ましい。

5. 実験

内海らの手法が正規化したデータセットについても有効であるかを検証するために、実験を行った。

5.1 データセットの正規化

4.2 で述べた理由から、本論文では内海らの使用したデータセットの倍率の違いの影響を小さくするため、画像の正規化を行った。図 3 に示す通り、画像中の鉢は金属製の治具によって固定されている。実際の治具の一辺の長さは全て等しいと仮定し、この長さを基準に画像サイズを変更する。基準にした治具の下部や、バックスクリーンの外側の部分をトリミングした後、基準にした治具の一辺の長さが全て同じになるように画像を縮小した。そして、治具の位置を中央下に揃え、画像が正方形になるように余白部分を白で塗り潰すことで、倍率による写り方の違いを最小限にした。最終的に、DNN モデルの入力層に合うように、

224×224 pixels に画像を縮小した。以上の操作によって正規化を行った画像の例を図 4 に示す。この一連の画像処理は OpenCV*1 を使い、画像の縮小の際の画素間の補間には Bicubic 補間を用いた。

5.2 実験環境

実験には、Fahlgren らの研究で用いられたデータセットを 5.1 で正規化したものを使用した。このデータセットには、25,570 枚の画像が含まれており、そのうち 577 枚に分げつ数のラベルが付与されている。

Pretext task に使用する植物部分のピクセル領域や縦横比の計算には PlantCV [8] を使用した。ピクセル領域や縦横比は 4 あるいは 8 段階の離散値に量子化し、クラス分類問題として DNN モデルを学習させた。なお、内海らの手法では回帰問題も使用していたが、本実験では使用していない。DNN モデルには、内海らの手法で用いられた VGG16 [6] の他に、ResNet50 [27] を使用した。2 つのモデルは ImageNet で学習済みのモデルである。VGG16 では 15 層目までのパラメータを固定し、ResNet50 では 158 層目までのパラメータを固定した。学習のためにはデータセットの画像 25,570 枚のうち、80% を train データに、20% を test データに使用した。DNN の学習および回帰のための特徴抽出には Keras*2 を TensorFlow バックエンドで使用し、回帰の SVR は scikit-learn [28] を使用した。

回帰モデルには予備実験の結果から、radial basis function カーネルの SVR を使用し、コストパラメータ $C = 100$ 、許容交差 $\epsilon = 1.0$ とした。回帰推定のためのデータセットには、分げつ数のラベルのついた画像データ 577 枚を使用した。推定精度の評価のために 6-fold cross validation を用い、それぞれの平均絶対誤差 (Mean Absolute Error: MAE) を用いた。言及していないハイパーパラメータは全てデフォルト値である。計算機は GPU に NVIDIA® TITAN RTX™ を使用した。

正規化したデータセットでの推定精度を評価するために、Fahlgren らの手法 [8] との比較をした。Fahlgren らの手法では、分げつ数 TC を、画像中の植物部分の縦横比 HW および植物の新鮮重量 M_{fw} を用いて次式のように表現している。

$$TC = 0.220M_{fw} - 2.19HW + 5.26 \quad (1)$$

なお、この式における新鮮重量 M_{fw} は画像中の植物部分が占める面積 A_{sv} を用いて次式のように表現される。

$$M_{fw} = 3.755 \times 10^{-5}A_{sv} + 0.2704 \quad (2)$$

5.3 結果

分げつ数の推定結果を表 1 に示す。正規化した場合、推

*1 <https://opencv.org>

*2 <https://keras.io>

定誤差が最も大きい pretext task として ResNet50 に縦横比の 4 クラス分類問題を解かせた場合であっても, Fahlgren らの手法に上回る推定精度を示した. このことから, 内海らの手法は正規化をしたデータセットであっても有効であることが明らかとなった. また, DNN モデルに VGG16 を用いた場合の, 正規化をしたデータセットと正規化をしていないデータセットでの推定結果を比較すると, いずれにおいても正規化を用いた場合の推定結果が正規化を用いなかった場合よりも高い推定精度を示した. これは, 正規化をすれば画像中に含まれる倍率の違いの情報を元に分けつ数推定をすることができなくなり, 正規化をしない場合に比べて推定精度が下がるという予想に反する結果である. この理由としては, 画像中の背景や鉢の情報が正規化によって失われたことで, DNN モデルが植物部分のみに注目することが可能になり, 分けつ数推定のための特徴表現が得やすくなったことが考えられる.

次に, 正規化した場合に推定精度が最も良かった縦横比の 4 クラス分類問題で学習させた VGG16 について, 分けつ数の実測値に対する推定値をプロットした結果を図 5 に示す. この図では, 横軸が分けつ数の実測値を示し, 縦軸が推定値を示しており, 青の直線は実測値と予測値が一致するラインである. また, プロット点の色は 6-fold validation における各 validation を示している. 比較として, Fahlgren らの手法による結果を記載している. Fahlgren らの手法のプロット点の色はそれぞれエノコログサの遺伝系統を示している. Fahlgren らの手法では分けつ数の実測値が 4 前後のサンプルに対しては予測値にばらつきがみられるのに対し, 提案手法では予測値のばらつきが小さく抑えられている.


また, 図 6, 7 に, 今回の実験で使用した全てのモデルについて, 分けつ数の実測値に対する推定値をプロットした結果を示す. この図では, 分けつ数の実測値が大きくなると, 推定精度が低くなっていることが示された. この理由として, 分けつ数のラベル付き画像データのうち, 大きい分けつ数のラベルのついた画像データが少ないことが考えられる. 単子葉植物の成長に伴う分けつ数の増加率には差があるため, 大きい分けつ数の画像データが少なくなってしまうことは避けられない. そのため, data augmentation によって大きい分けつ数のラベル付きデータを増やすことや, 分けつ数の大小に影響を受けずに分けつの特徴表現を得られるような pretext task を考えることで, さらなる推定精度の改善が見込める.

6. まとめと今後の課題

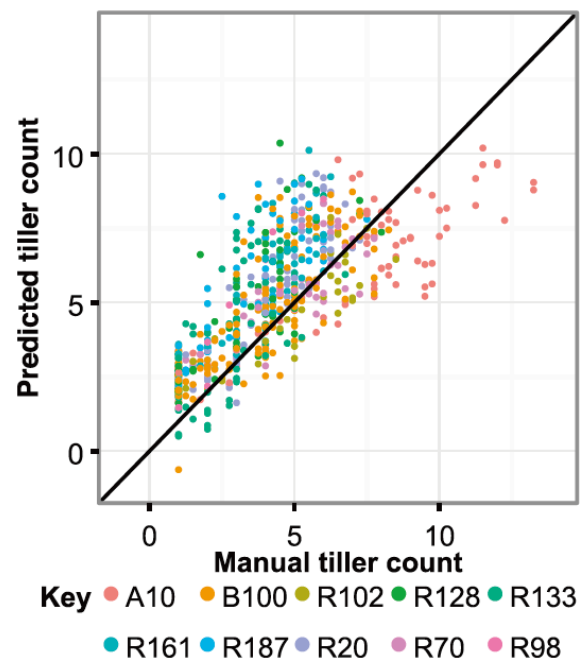
本稿では, 倍率の正規化をしたデータセットでも内海らの手法が有効であることを検証した. 内海らの提案した Self-supervised learning を用いた分けつ数の推定手法は, 画像データセットに含まれる倍率情報の違いによって分

表 1: 推定した分けつ数の MAE.

手法	Pretext task			
	ピクセル領域 4cls.	ピクセル領域 8cls.	縦横比 4cls.	縦横比 8cls.
正規化有 (VGG16)	0.80	0.81	0.78	0.78
(ResNet50)	0.83	0.84	0.88	0.87
正規化無 (VGG16) [7]	0.95	1.05	0.80	1.05
Fahlgren et al. [8]	0.98			



(a) VGG16:ピクセル領域 4 クラス分類



(b) Fahlgren et al. [8]

図 5: 分けつ数の実測値に対する予測値.


げつ数推定ができてしまうおそれがあった。そこで、画像データセットの倍率の正規化を行い、内海らの手法は倍率情報を用いなくても分けつ数推定ができることを実証した。

今後の課題としては、大きい分けつ数をもつサンプルについても高い精度で推定を行うための、data augmentationや pretext task の考案が挙げられる。また、内海らの手法がエノコログサ以外の単子葉植物についても有効であるかについても検証する。


謝辞 本研究は JSPS 科研費 JP18K18074 の助成を受けたものです。

参考文献


- [1] Ray, D. K., Mueller, N. D., West, P. C. and Foley, J. A.: Yield Trends Are Insufficient to Double Global Crop Production by 2050, *PLoS ONE*, Vol. 8, No. 6 (2013).
- [2] 星川清親: 解剖図説 イネの生長, 一般社団法人 農山漁村文化協会 (1975).
- [3] Yang, G., Xing, Y., Li, S., Ding, J., Yue, B., Deng, K., Li, Y. and Zhu, Y.: Molecular dissection of developmental behavior of tiller number and plant height and their relationship in rice (*Oryza sativa* L.), *Hereditas*, Vol. 143, No. 2006, pp. 236–245 (2006).
- [4] Lafarge, T. A. and Hammer, G. L.: Tillering in grain sorghum over a wide range of population densities: Modelling dynamics of tiller fertility, *Annals of Botany*, Vol. 90, No. 1, pp. 99–110 (2002).
- [5] Boyle, R. D., Corke, F. M. K. and Doonan, J. H.: Automated estimation of tiller number in wheat by ribbon detection, *Machine Vision and Applications*, Vol. 27, No. 5, pp. 637–646 (2016).
- [6] Simonyan, K. and Zisserman, A.: Very deep convolutional networks for large-scale image recognition, *Proc. of ICLR*, pp. 1–14 (2015).
- [7] 内海ゆづ子, 中村浩一朗, 岩村雅一, 黄瀬浩一: Pretext task を用いた植物画像からの分けつ数の推定, 電子情報通信学会技術研究報告, Vol. 119, No. 64, pp. 265–270 (2019).
- [8] Fahlgren, N., Feldman, M., Gehan, M. A., Wilson, M. S., Shyu, C., Bryant, D. W., Hill, S. T., McEntee, C. J., Warnasooriya, S. N., Kumar, I., Ficor, T., Turnipseed, S., Gilbert, K. B., Brutnell, T. P., Carrington, J. C., Mockler, T. C. and Baxter, I.: A versatile phenotyping system and analytics platform reveals diverse temporal responses to water availability in *Setaria*, *Molecular Plant*, Vol. 8, No. 10, pp. 1520–1535 (2015).
- [9] Flowers, M., Weisz, R. and Heiniger, R.: Remote Sensing of Winter Wheat Tiller Density for Early Nitrogen Application Decisions, *Agronomy Journal*, Vol. 93, No. 4, pp. 783–789 (2001).
- [10] Scotford, I. M. and Miller, P. C. H.: Estimating tiller density and leaf area index of winter wheat using spectral reflectance and ultrasonic sensing techniques, *Biosystems Engineering*, Vol. 89, No. 4, pp. 395–408 (2004).
- [11] Wu, D., Guo, Z., Ye, J., Feng, H., Liu, J., Chen, G., Zheng, J., Yan, D., Yang, X., Xiong, X., Liu, Q., Niu, Z., Gay, A. P., Doonan, J. H., Xiong, L. and Yang, W.: Combining high-throughput micro-CT-RGB phenotyping and genome-wide association study to dissect the genetic architecture of tiller growth in rice, *Journal of Experimental Botany*, Vol. 70, No. 2, pp. 545–561 (2019).
- [12] Wang, X., Xuan, H., Evers, B., Shrestha, S., Pless, R. and Poland, J.: High-throughput phenotyping with deep learning gives insight into the genetic architecture of flowering time in wheat, *GigaScience*, Vol. 8, No. 11, pp. 1–11 (2019).
- [13] Jin, S., Su, Y., Gao, S., Wu, F., Hu, T., Liu, J., Li, W., Wang, D., Chen, S., Jiang, Y., Pang, S. and Guo, Q.: Deep learning: Individual maize segmentation from terrestrial lidar data using faster R-CNN and regional growth algorithms, *Frontiers in Plant Science*, Vol. 9, No. June, pp. 1–10 (2018).
- [14] Aich, S. and Stavness, I.: Leaf counting with deep convolutional and deconvolutional networks, *Proc. of ICCVW*, pp. 2080–2089 (2017).
- [15] Dobrescu, A., Giuffrida, M. V. and Tsiftaris, S. A.: Leveraging multiple datasets for deep leaf counting, *Proc. of ICCVW*, pp. 2072–2079 (2017).
- [16] Krizhevsky, A.: Learning Multiple Layers of Features from Tiny Images, Technical report (2009).
- [17] Russakovsky, O., Deng, J., Su, ., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C. and Fei-Fei, L.: ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, Vol. 115, No. 3, pp. 211–252 (2015).
- [18] Hinton, G. E. and Salakhutdinov, R. R.: Reducing the Dimensionality of Data with Neural Networks, *Science*, Vol. 313, No. 5786, pp. 504–507 (2006).
- [19] Vincent, P., Larochelle, H., Bengio, Y. and Manzagol, P. A.: Extracting and composing robust features with denoising autoencoders, *Proc. of ICML*, pp. 1096–1103 (2008).
- [20] Zhang, R., Isola, P. and Efros, A. A.: Colorful Image Colorization, *Proc. of ECCV*, pp. 649–666 (2016).
- [21] Noroozi, M. and Favaro, P.: Unsupervised Learning of Visual Representations by Solving Jigsaw Puzzles, *Proc. of ECCV*, pp. 69–84 (2016).
- [22] Noroozi, M., Vinjimoor, A., Favaro, P. and Pirsivash, H.: Boosting Self-Supervised Learning via Knowledge Transfer, *Proc. of CVPR*, pp. 9359–9367 (2018).
- [23] Gidaris, S., Singh, P. and Komodakis, N.: Unsupervised Representation Learning by Predicting Image Rotations, *Proc. of ICLR*, No. 2016, pp. 1–16 (2018).
- [24] 後藤雄佐, 斎藤満保: 個体群における水稲の分けつ性の解析: 第1報基肥窒素量を異にする圃場条件下での茎数増加様式, 日本作物学会紀事, Vol. 61, No. 3, pp. 356–363 (1992).
- [25] 大江真道, 後藤雄佐, 星川清親: 深水処理が水稲分けつの出現に及ぼす影響, 日本作物学会紀事, Vol. 63, No. 4, pp. 576–581 (1994).
- [26] Drucker, H., Surges, C. J. C., Kaufman, L., Smola, A. and Vapnik, V.: Support Vector Regression Machines, Vol. 1, pp. 155–161 (1997).
- [27] He, K., Zhang, X., Ren, S. and Sun, J.: Deep Residual Learning for Image Recognition, *Proc. of CVPR*, pp. 770–778 (2016).
- [28] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E.: Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, Vol. 12, pp. 2825–2830 (2011).




(a) ピクセル領域 4 クラス分類



(b) ピクセル領域 8 クラス分類




(c) 縦横比 4 クラス分類




(d) 縦横比 8 クラス分類


図 6: VGG16 における分けつ数の実測値に対する推定値.




(a) ピクセル領域 4 クラス分類



(b) ピクセル領域 8 クラス分類



(c) 縦横比 4 クラス分類



(d) 縦横比 8 クラス分類

図 7: ResNet50 における分けつ数の実測値に対する推定値.