

An accurate and general estimation model for rice above-ground biomass using
convolutional neural network-based analysis of digital image
畳み込みニューラルネットワークを用いた可視画像解析による高精度かつ汎用的なイネバ
イオマス推定モデルの構築

京都大学大学院農学研究科 農学専攻 作物学分野 中嶋洸太

第1章 緒言

地上部全乾物重（バイオマス）は、作物の生産性を示す最も基本的な形質である。バイオマス生産性には遺伝および環境要因の両方が強く影響するため、その変動要因の解明には多様な品種および栽培条件での測定が必要である。従来の破壊的な実測には多大な労力がかかるため、これまで多くの研究でバイオマスを非破壊推定する手法が検討されてきた。しかし従来の研究では推定モデルの多様な条件に対する精度（汎用性）については十分に検証されていない。本研究では高い汎用性を示す可視画像解析技術である畳み込みニューラルネットワーク（CNN）に着目し、近接センシングにより取得した可視画像からイネバイオマスを推定するモデルを構築した。多様な品種および栽培条件、そして大きく異なる撮影方法であるドローン空撮画像に対するモデルの汎用性を検証するとともに、学習データの追加がモデルの適用範囲の拡張をもたらすか定量的に検証した。

第2章 品種に対する CNN モデルの汎用性の検証

2 年間・2 地点で移植 2 週間後から出穂約 1 週間後まで可視画像と対応する実測バイオマスを収集した。遺伝的多様性を網羅する世界のイネコアコレクション由来の 53 品種を含むイネ 59 品種を対象に 2579 点の実測バイオマスと 12183 枚の可視画像を収集した。画像は市販のデジタルカメラを用いて地上 1.5m の高さから鉛直下向きに撮影した。59 品種のうち形態的に多様な 28 品種のデータを CNN に学習させた。モデルの品種に対する汎用性を評価するために、学習済み 28 品種および未学習 31 品種に対する推定精度（決定係数 (R^2)、相対二乗平均平方根誤差 (rRMSE)) を算出した。CNN モデルは学習済み 28 品種のバイオマスを $R^2=0.95$ 、rRMSE=0.19 と従来手法と同等以上の高い精度で推定した。未学習 31 品種に対しても実測バイオマス 9.14 t ha^{-1} 未満で $R^2=0.87$ 、rRMSE=0.28 と高い精度を示した。以上より CNN モデルに多様な品種を学習させることで品種に対して高い汎用性を示すイネバイオマス推定モデルが構築できた。一方実測バイオマス 9.14 t ha^{-1} 以上では顕著な過小評価が確認された。これは当該領域における学習データの不足が原因の一つと考えられた。

第3章 栽培条件およびドローン空撮画像に対する CNN モデルの汎用性の検証

京都で単一の栽植密度のもとで栽培したイネのデータを CNN に学習させた。栽培条件に対する汎用性は学習データと同一の栽培地点だが異なる栽植条件（疎植、疑似的な欠株）および異なる栽培地点（日本（東京、千葉）、コートジボワール、マダガスカル）に分けて検

証した。加えてドローン画像に対する汎用性も検証した。ドローン画像は 20m の高さから撮影した。CNN モデルは学習データと同一地点における疎植条件 ($R^2=0.89$, $rRMSE=0.27$) および欠株条件 ($R^2=0.92$, $rRMSE=0.32$) のデータに対して高い汎用性を示した。一方、未学習の 4 地点に対する精度は低く、大きな地点間差 ($R^2=-1.32\sim 0.83$, $rRMSE=0.28\sim 1.66$) が確認された。地点間における生育環境や撮影機器などの違いが画像にも反映され、これが推定精度の地点間差を生じさせたと考えられる。土壌に学習データと異なる特徴を有していたと思われる地点に対して推定精度が低い傾向にあった。ドローン画像に対する推定精度も低かった ($R^2=0.57$, $rRMSE=0.54$)。これは学習させた近接センシング由来の画像とドローン画像の間の地上画素寸法 (GSD) やコントラストの違いが要因の一つと考えられた。以上の結果から、撮影した可視画像には栽培地点および撮影方式によって異なる特徴が含まれており、単一の地点で栽培し単一の方式で撮影した画像を学習した CNN モデルはこの点において汎用性が不足していたことが示唆された。

第4章 学習データの追加によるモデルの適用範囲の拡張

第 3 章の学習データに京都以外の 4 つの栽培地点のデータの一部を地点別または全地点同時に追加して学習させることで CNN モデルが複数地点に適用可能になるか検証した。バイオマスの分布が偏らないように選抜したデータを段階的に追加した。また、CNN モデルをドローン画像に適応させるにあたって、データの追加学習だけでなく学習させる全画像の GSD をドローン画像と揃える処理の有効性も検証した。結果、京都以外の 4 地点に対する推定精度は当該地点のデータを追加学習させるほど向上した。どの地点でもデータを 40 点加えると R^2 が 0.8 以上となった。ドローン画像に対する適応では、追加学習と GSD の統一の両方を組み合わせることで推定精度が最も高くなった ($R^2=0.79$, $rRMSE=0.38$)。以上より多様な栽培条件および撮影方式のデータを同時に学習させることで CNN モデルの適用範囲が拡張し、追加データが 40 点あれば一定以上の精度に達した。また地点別にデータを追加した場合、学習データを追加していない地点に対しても精度が向上することがあった。この結果は、さらに多様なデータを供試することで将来的にあらゆる栽培条件に対して適用可能な、真に汎用的なバイオマス推定モデルが構築できる可能性を示している。

第5章 結論

品種および栽培条件に対して汎用的なバイオマス推定手法の確立にむけて、CNN を用いた可視画像解析が有効であることが明らかになった。学習データの追加によりモデルが複数の地点やドローン画像に適用可能となり、追加データが少数でも十分な精度向上が期待できることが示された。可視画像は誰もが安価かつ簡便に取得できることから本手法は汎用性に加えてスループットと利便性も兼ね備えたバイオマス推定手法となる可能性がある。今後品種と栽培条件に汎用的なバイオマス推定モデルが構築できれば、バイオマス生産性の向上に資する遺伝、環境要因およびその交互作用の解明に貢献できると期待される。