

# 畳み込みオートエンコーダーを用いた 農作物の栽培画像処理 CNN モデル拡張の提案

A Proposal for Crop Cultivation Image Processing CNN Model Extension Using Convolutional Autoencoder

富田 隼輔<sup>†1</sup> 中畝 誠<sup>†2</sup> 山田 融<sup>†2</sup> 中村和幸<sup>†1</sup>

明治大学<sup>†1</sup> 埼玉県農業技術研究センター<sup>†2</sup>

## 1. はじめに

栽培されている農作物の状態をデータから推論するとき、栽培区画を撮影した画像データは農作物の生育を視覚的な観点から調べられる期待がある。きゅうりの収量予測で、CNN による画像処理を用いた手法[1]が提案されており、学習後 CNN モデルが可視化手法により、生育に重要とされている葉の部分を特徴量としていることが言及されている。

本研究では、画像データを入力とした CNN による回帰からきゅうりの 1 週間後の収量予測を行う。それにあたり、事前学習モデルの使用または、使用する計算機の限界に際し、画像データに対しリサイズ手法をとることで、収量に直接関わると考えられる花が潰れてしまい、予測精度を損なう問題が考えられる(図 1)。そこで次元圧縮手法として畳み込みオートエンコーダー(CAE)を用いることにより栽培画像に対応した圧縮・加工のプロセスを導入する。きゅうりの収量予測に対し、本アプローチの有効性を説明する。

## 2. 実験手法

### 2.1 学習の前提条件

画像データは、2018 年から 2021 年の 4 年間の 9 月から 12 月および、2019 年から 2021 年の 3 年間の 4 月から 7 月の 7 期間にきゅうりを栽培した施設 2 棟に対し、各区画を撮影した RGB 画像 4988 枚(全 1247 区画で区画ごとに 4 枚)を用いる。実験に際し、予測日を全体の 20%として 17 日ランダムに設定した。学習モデルは ImageNet による事前学習モデルとしての ResNet50 の CNN と Global Average Pooling を用いて収量に対応する 1 次元の実数を出力する。損失関数は平均絶対誤差(MAE)、最適化手法は Adam を用いた。学習時、それぞれの画像は ResNet50 の入力サイズである  $224 \times 224$  にリサイズするのだが、CAE を導入した手法では  $448 \times 448$  にリサイズしたのち、CAE の圧縮によって  $224 \times 224$  としている。



図 1 リサイズしたきゅうりの画像例



図 2 CAE により ResNet50 の入力サイズに圧縮

### 2.2 畳み込みオートエンコーダー(CAE)

オートエンコーダはデータの効果的な圧縮・再構成ができる手法として次元削減した特徴量抽出や、ノイズを除去した再構成などで用いられている[2]。特に、CAEはエンコーダに畳み込み層、デコーダに転置畳み込み層を用いたオートエンコーダで、画像の形状やパターンを認識できることから、画像のノイズ除去の分野でよく用いられている[3]。エンコーダ  $F_\phi$  でデータ  $X = (x_1, \dots, x_N)$ ,  $x_n \in \mathbb{R}^D$  を低次元の潜在変数データ  $Z = (z_1, \dots, z_N)$ ,  $z_n \in \mathbb{R}^M$  に圧縮、デコーダ  $F_\psi$  で  $Z$  からデータ  $\hat{X} = (\hat{x}_1, \dots, \hat{x}_N)$ ,  $\hat{x}_n \in \mathbb{R}^D$  を再構成する際、オートエンコーダ  $F_\omega$  は以下のように表せる。

$$F_\omega(X) = F_\psi \circ F_\phi(X)$$

$F_\omega$  は、 $X$  と  $\hat{X}$  の MSE が最小となるようにパラメータを最適化する。

### 2.3 CAE による操作

CAE の導入にあたって、以下の 2 ステップから説明する。また、使用する CAE モデルの説明として上記数式の次元  $D, M$  から説明する( $D$  は全て  $448 \times 448 \times 3$  となっているため省略)。

#### ・ステップ 1

画像データを ResNet50 の入力サイズに圧縮することを考える。リサイズしたサイズ  $448 \times 448$  の画像に対し、 $M = 224 \times 224 \times 3$  の CAE1 を用いる(図 2)。

<sup>†1</sup> SHUNSUKE TOMITA, KAZUYUKI NAKAMURA,  
Meiji University

<sup>†2</sup> MAKOTO NAKAUNE, TORU YAMADA  
Saitama Agricultural Technology Research Center




図 3 CAE2 による平均的な色の抽出




図 4 CAE3 による差分画像の圧縮

図 2 に見られるように、単純にオートエンコーダを用いると画像全体が葉の平均的な色に近づいてしまい、純粋なリサイズ時よりも花が重要視されない恐れがある。

#### ・ステップ 2

ステップ 1 で陥った画像全体の平均的な色を取り出すことを考える。  $M = 448 \times 448 \times 1$  の CAE2 を用い、元画像  $x$  と再構成した画像  $\hat{x}$  の絶対差  $|x - \hat{x}|$  をとる(図 3)。これにより得られた差分画像を  $M = 224 \times 224 \times 3$  の CAE3 で圧縮し(図 4)、収量予測に用いる。図 3、図 4 は同じ画像を用いており、加工の前後で比較すると、捕食シートが色濃く残るものの、花の箇所が強く現れていることが見られる。

## 2.4 学習の条件

以上のステップ 2 の操作を行い、操作なしを model A、操作ありを model B として、これらの 2 つのモデルを比較する。

## 3. 結果と考察



モデルのテストデータによる評価にあたって、全体的な評価としての MAE(表 1)と、データごとの予測値で比較を行った(図 5)。

model A, B によるテストデータによる MAE は表 1 である。値は小数第 3 位を四捨五入したものとなっている。全体的な評価として MAE のオーダーが 100 代なのに対し、差が 2 程であることからこの 2 モデルの性能は微小な差であることがわかる。これにより、本タスクにおいて model B で用いた手法は適用可能であると考えられる。

テストデータごとの予測値での比較として、2 モデルの予測値の差の大きさからモデルの性質を調べた。図 4 は 2 モデル間の予測値の差を 1000, 100 で区切りその中から 10 データを無作為に取り出したものである。図 4 の左(1000 以上)を見ると、データ 1, 8, 9 で見られるように model B 予測値が model A よりも大きくなる、または小さくなることにより、正解値に近づいている一方で、5, 6, 7 で見られるようにその逆もある。図 6 は右から図 5 左の 1, 7 番目に対応

表 1 テスト結果

	model A	model B
MAE	606.67	608.81

図 5 model 間での予測値の差の大きさごとの比較  
左:1000 以上, 中央:100 以上 1000 未満, 右:100 未満図 6 収量予測に対応した画像での比較  
画像は左から、図 4 左の 1, 7 番目に対応したもの

したものである。どちらも model B が model A よりも多めに収量予測しており、どちらも差分画像で花が複数見えていることから収量と花の数による傾向が考えられる。

## 4. まとめ

本研究では 1 週間後のきゅうりの収量予測をテーマに、画像データを入力とする CNN を用いた回帰を行った。その際にリサイズの際に潰れてしまう花にフォーカスし、CAE を用いた加工・圧縮の操作をする手法を導入した。学習の結果から、元画像を入力とするモデルとの比較で予測精度が改善する箇所があり有効性が見られた。

今回得られた結果から、2 モデルの特徴を比較してさらに収量予測に関わる視覚的な特徴量に言及し、両者を組み合わせることで全体的な精度向上を図れる期待がある。一方で、今回の手法で用いた差分画像は相対的な画素値からなるため、データ拡張のように撮影画像と同一に考える手法をとるのは難しい。

## 参考文献

- [1] 下村真生, 中畝誠, 山田融, 塚沢和憲, 中村和幸: CNN を用いた農作物の収量予測と Grad-RAM による可視化の検討, 2020 年 情報科学技術フォーラム (FIT), 2020
- [2] Dor Bank, Noam Koenigstein, Raja Giryes: Autoencoders. arXiv 2020, arXiv:2003.05991.
- [3] Mathew Y. W. Teou: Convolutional Autoencoder for Image Denoising: A Compositional Subspace Representation Perspective. IEE International Conference on Artificial Intelligence in Engineering and Technology, 2021