

農業分野の回帰問題における少数部分ラベルの予測精度向上 —リサンプリングを用いた画像データによる深層学習

富田 隼輔[†] 中畝 誠[‡] 山田 融[‡] 塚沢 和憲[‡] 中村和幸[†]

明治大学[†] 埼玉県農業技術研究センター[‡]

1. はじめに

近年日本の農業の課題として、担い手の減少・高齢化の進行等による労働力不足と熟練者でなければできない作業が多いことがあげられる。なかでも農作物の収量予測は熟練者の経験からの判断によるため、労働力不足が問題である現状では、AIによる生産量予測により、生産者の収益の安定性の向上や簡易化が期待される。これまできゅうりに関しては、CNNを用いた収量予測と可視化手法を適用した事例[1][2]があるが、予測精度の観点から未だ十分でない。

本研究では、画像データ(図1)を入力とするCNNによる回帰により収量を予測するタスクを扱う。このようなタスクでは、収量のデータ分布の裾確率が低くなり、当該領域の予測精度が上がりにくくなる問題が発生しやすい。そこで分類タスクにおける不均衡データ問題[3]がある場合に用いられるリサンプリング手法を、連続値をとる目的変数の分布に応用し、データ分布を一様分布に近づけるアプローチを導入した。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、埼玉県農業技術研究センターにおいて2018年から2020年の3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6期間にきゅうりを栽培した施設2棟に対し、各区画を撮影した画像4220枚(全1055区画で区画ごとに4枚)を用いる。実験に際し、予測日として2018年の11月17日、2019年の6月10日、10月18日、11月29日、2020年6月5日の計62区画分を設定し、この5日を除いたデータのうち、10%を評価用データ、残るデータを学習用データとした。

学習モデルはResNet50を用い、1次元の実数値を出力する。重みの初期値はランダムとし、損失関数は平均絶対誤差(MAE)、最適化手法はAdamを



図1 学習用にリサイズしたきゅうりの画像例

用いた。学習時、それぞれの画像はResNet50の入力サイズである 224×224 にリサイズし、画素値を $1/255$ 倍した。ミニバッチのサイズは32、学習エポック数は200とした。

2.2 収量データの一様手法

与えられている収量データを一様分布に近づけるためには、収量の度数分布から見られるデータ分布に対し、それぞれの階級に含まれるデータを新たに生成または削除するというアプローチが考えられる。分類タスクではクラスごとのデータサイズが均一でなく、それによって問題が発生する不均衡データ問題があり、解決手法の一つとしてリサンプリングがある。このリサンプリングを、回帰における収量度数分布の階級と分類におけるクラスを同一視することで適用する。本研究での度数分布の階級数は10とした。

・操作1

まず、収量度数分布において度数の小さい階級のデータサイズを大きくする。データが画像であることから、画像の回転・反転によるデータ拡張手法を用いた。[4]ではCNNの分類タスクにおける画像回転の有効性を示している。90°ごとの回転と反転(図2)を表1のルールに従って適用し、データサイズを大きくする。この手法を用いるのは、操作後に元データをなるべく残すためである。

・操作2

次に、度数の多い階級のデータサイズを小さくすることを考える。[3]のランダムアンダーサンプリング(RUS)を用いて、収量の、最小度数をもつ階級に他階級のデータサイズを合わせる。この2つの操作による学習データの収量度数分布のヒストグラムは図3のようになる。

2.3 学習の条件

以上の前提条件と2つの操作から学習条件を

[†] Shunsuke TOMITA, Kazuyuki NAKAMURA, Meiji University

[‡] Makoto NAKAUNE, Toru YAMADA, Kazunori TSUKAZAWA, Saitama Agricultural Technology Research Center

表1 データサイズ増加時の操作ルール

最大度数に対する度数比	追加する画像
1/2倍以上 1倍以下	追加なし
1/4倍以上 1/2倍未満	反転
1/6倍以上 1/4倍未満	反転, 90°回転
1/8倍以上 1/6倍未満	反転, 90°, 180°回転
1/8倍未満	反転, 90°, 180°, 270°回転




図2 画像の回転(左から0°, 90°, 180°, 270°)と反転(上:正図, 下:反転図)




図3 行う操作に対するヒストグラム

定める. 操作なしを model A, 操作1のみを行ったものを model B, さらに操作2を行ったものを model C とし,これらのモデルを比較する.

3. 結果と考察

3.1 全体の予測精度

model A, B, C によるテスト結果は表2である. 評価には平均絶対誤差(MAE)を使用した. MAEは操作1, 2を行った model Cが542.45となり, 操作を行わない model Aの567.54より25.09ポイント小さくなった. これにより, 収量予測で学習データの収量を一様化することの有効性が見られる. しかし, 操作1のみを行った model Bは663.75と, model Aより96.21ポイント大きくなった. 図2で見られるように, 回転・反転操作のみでも階級間の度数差を小さくし, 操作なしに比べて一様化しているといえるが, 予測精度は低くなったため, 必ずしも収量を一様化することで予測精度が高くなるとはいえない.

3.2 局所の予測精度

model A, B, C による区画ごとの予測結果は図4である. model Cを model Aと比較すると, 特に右4つの区画で予測値が正解値に近くなった. また, model Bを model Aと比較すると, 特に左4つの, 2番目を除く区画で予測値が正解値から遠くなった. model Bは全体的に予測値が大きくなり, 正解値に近い区画もあるが, 元々正解値に近かった

表2 テスト結果

	model A	model B	model C
MAE	567.54	663.75	542.45




図4 区画ごとの正解値と予測値の比較

区画も予測値が大きくなった. model Cは, 正解値に近い予測値はほとんどそのまま, 他の区画の大部分で予測値が正解値に近付いていた. つまり, model Bは過適合により予測精度が低くなっているのに対し, 度数の大きいデータが削除された model Cは過適合せずに model A で予測できなかった部分をカバーできていた.

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. その際に学習データの収量を, 度数分布から画像の回転・反転を用いたデータの生成とRUSによるデータの削除というリサンプリング手法を用いて一様分布に近づけた. 学習の結果から, 画像データを入力とする学習でこれら2つの操作による収量分布の一様化の有効性が見られた.

回帰問題として, 今回の手法は一様化の一つに過ぎないため, 度数分布の階級数や操作法によってさらなる精度向上が期待できる. 一方で, 手法によっては過適合が進み, 精度が悪化するケースも十分考えられるため, データの分布に対する操作に注意を払う必要がある. きゅうりの収量予測としては, 画像だけでなく, 気温や湿度といった数値データも特徴量を捉えるために重要である. 数値データを併用した場合, 今回の操作1では数値はそのまま複製するほかなく, 過適合に陥る恐れがあるため, 数値データを踏まえたアプローチも課題の一つである.

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] 下村真生, 中村和幸: 農作物収量予測に向けた可視化手法の適用分析事例, 一般社団法人 人工知能学会 第34回全国大会, 2020
- [3] Haibo He, Edwardo A. Garcia: Learning from Imbalanced Data, IEEE Transactions on Knowledge and Data Engineering Volume: 21, pp.1263-1284, 2009
- [4] Spyros Gidaris, Praveer Singh, Nikos Komodakis: Unsupervised Representation Learning by Predicting Image Rotations, a conference paper at ICLR, 2018