

画像解析による植物の重さ推定の提案

福島 誠人† 竹長 慎太郎† 波部 斉† 井口 信和†

1. はじめに

近年、異常気象や自然災害の影響で2019年の農産物の被害額は2405億円にも及び[1]、農業人口も年々減少し食料自給率も低下傾向にある[2]。そのため、自然環境の影響を受けずに安全で安定した食料の供給が見込める植物工場が注目されている。

作物の栽培には養液栽培[3]を用いている。養液栽培とは土を使わずに、肥料を水に溶かした液（培養液）によって作物を栽培する栽培法である。大規模な栽培が可能であるが光の照射具合で作物の成長スピードが異なるため、作物を観察し出荷時期を判断する必要がある。出荷する際には規定の重量ごとに小分けにするが、規定の重量に達しない場合は別の株から足す必要があり、規定の重量を超過している場合は捨てることもある。作物の重さは収穫したあとでないと正確に測定できないが、収穫前の状態で重量を推定できれば、先述のような余分な作業が削減でき、全体的な作業効率化につながると期待される。そこで、本研究では、作物を撮影した画像を用いて、収穫前の重さ推定を行うことにする。

Murakamiらは畑で栽培されているレタスを空から撮影した画像を用いて重さの推定を行った[4]。この手法では、レタスの色の範囲を定めて2値化を行い、抽出された領域の面積を入力として単純な回帰分析により重さの推定を行っている。しかし、本研究で想定する作物の場合は図2のように葉の重なりが生じるため、葉に相当する画素の面積を用いるだけでは正確に重量を推定できないと考えられる。

そこで本研究では、深層学習の1つである畳み込みニューラルネットワーク (Convolutional Neural Network; CNN) [5]を用いて回帰分析を行い作物の重さを高精度に推定する手法を提案する。CNNを用いることで、[4]のように画像上の面積だけでなく、葉の茂り度合いなど、重さ推定に有用な情報を抽出でき、高い精度で重さを推定できるとが期待される。本研究では、CNNの中でも、様々なタスクで高い性能を持つことが知られている Residual Network (ResNet) [6]を用いた回帰分析と、葉に相当する画素の面積を用いた単純な線形回帰分析の2つを比較し、前者の優位性を示す。

2. 作物の重さ推定の流れ

本節では、データの取得方法と提案手法的流れについて述べる。

2.1 データの取得方法

本研究で使用する作物は、水耕栽培器 (Green Farm) を用いて2~3週間かけて栽培したレタス系のサラダボウルレッド (レタス) を使用する。栽培中の何回か、レタスを取り出してその重量を測定する。さらに、ターンテーブルの上にレタスを乗せ、ターンテーブルを回転させながら上と横の2方向からカメラを用いて20~30秒間撮影した(図1)。使用したカメラはGoPro Hero7であり解像度とフレームレートは2704×1504, 60fpsである。図2に取得したデータを示す。実験には、30フレームごとで切り取りとった画像を用いる。




図1 データ取得の環境



図2 取得したデータの例

2.2 提案手法

提案手法による重さ推定の実行の流れを図3に示す。ResNetを用いた回帰分析では撮影した2704×1504の解像度では学習を行うことができないため、0.2倍にリサイズする。Aydogduらが6層のCNN, ResNet-18, ResNet-34を使用した年齢推定の比較実験を行いResNet-18が高い精度で年齢推定を行えたことを報告している[7]。これから、一般的な画像認識タスクにおいてResNet-18が優れていると言えるので、本研究でもResNet-18を用いる。深層学習を使用するには大量のラベル付きデータが必要になるが、本研究では少ないラベル付きデータでも精度よく推定を行うために転移学習[8]を用いる。転移学習とはあらかじめImageNet[9]などの大規模なデータセットを用いて学習された学習済みモデルを用いて別のドメインに適合する技術である。学習済みモデルはImageNetの1000個のカテゴリに分類するためのモデルであり、このままでは回帰分析はできないため、モデルの終端をスカラー値を出力するように変更して回帰分析ができるようにした。また、少量のデータセットでも効率的に識別率の向上を手助けする技術としてData Augmentation[10]がある。Data Augmentationとは、画像に対して回転や移動、ノイズ付加など様々な人為的に処理を加えることによって学習データを増やすことである。少ない画像で学習を行うと過学習に陥る可能性が高

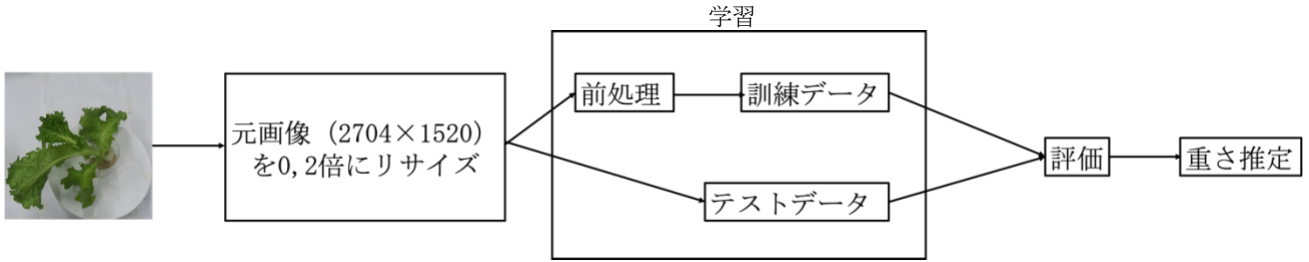


図3 ResNet-18を用いた回帰分析による重さ推定の流れ (提案手法)




図4 線形回帰分析を用いた重さ推定の流れ

くなるが, Data Augmentation を行うことで過学習を防ぎ識別精度を向上させることができる.

2.3 線形回帰による重量推定

実験では, 前節に述べた提案手法の比較対象として, 色情報に基づく2値化と, 2値化結果の面積を入力とした線形回帰を行う. この手法は1節で述べた[4]に近いものと言える.

まず, レタスの葉の領域を抽出するために, HSV色空間で, 色相Hが $30 \leq H \leq 90$, 彩度Sが $64 \leq S \leq 255$, 明度Vが $0 \leq V \leq 255$ の範囲が葉の領域に相当するとして, 該当する領域を抽出する.

次に, 抽出した領域の面積を入力とした単純な回帰分析を行う. 最小二乗誤差を用いた回帰直線の計算方法を次に示す. 回帰直線の傾き, 切片, 葉の面積, 重さをそれぞれ, a, b, x, y とすると, 誤差は(1)式で表される.

$$S(a, b) = \sum_{i=1}^n (y_i - ax_i - b)^2 \quad (1)$$

これが最小となる a, b を求めるため, それぞれに対して偏微分を行う. (2), (3)式は偏微分の結果である. 最後に(2), (3)式に関して連立方程式を解き, 回帰直線を求める.

$$a \sum_{i=1}^n x_i^2 + b \sum_{i=1}^n x_i = \sum_{i=1}^n x_i y_i \quad (2)$$

$$a \sum_{i=1}^n x_i + bn = \sum_{i=1}^n y_i \quad (3)$$

3. 実験

提案手法と線形回帰分析のデータセットの作成方法, 実験設定, 実験結果について述べる.

3.1 データセットの作成方法

2.1節で述べた方法で取得した画像枚数の分布を図5に示す. 横軸がレタスの重量, 縦軸がそれぞれの重量で収集した画像枚数である. クラスにより取得できた画像枚数が異なるため, 作成したデータセットにクラスの偏りが生じ

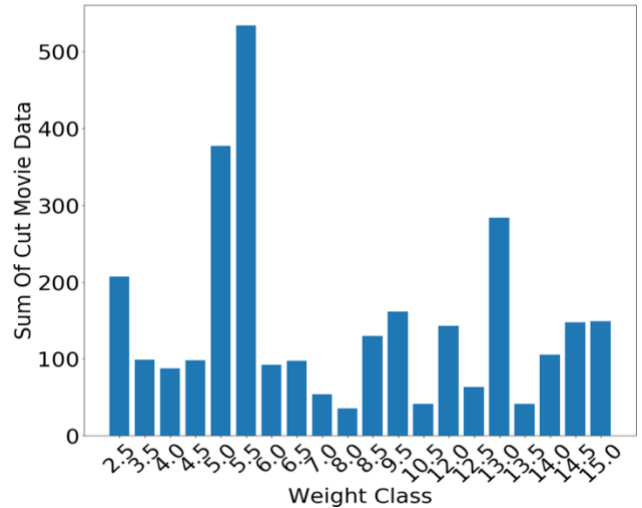


図5 取得したデータの分布

ないように次のように学習データ, テストデータ, 評価データを作成する.

評価データは各々の動画の最後の2秒間を選択し. 学習データとテストデータは, 30フレームごとに切り取ったデータを交互に選択したあと, (4), (5)の条件式によってそれぞれの重量におけるデータ数が大きく偏らないようにする. ここで, 学習データのある重さでの枚数を x_i , テストデータのある重さでの枚数を y_i , 交互で選択された段階で学習データの中のデータ数が最小の重量の枚数を min_{train} , 交互で選択された段階でテストデータの中のデータ数が最小の重量の枚数を min_{test} としている. (4)式と(5)式によって, 学習データでは枚数の最小値と最大値の差が50以下, テストデータでは20以下になる.

$$x_i = \begin{cases} x_i & (min_{train} + 50 \geq x_i) \\ min_{train} + 50 & (min_{train} + 50 < x_i) \end{cases} \quad (4)$$

$$y_i = \begin{cases} y_i & (min_{test} + 20 \geq y_i) \\ min_{test} + 20 & (min_{test} + 20 < y_i) \end{cases} \quad (5)$$

これらの方法で作成された上, 横, 上と横方向の3種類のデータセットを用いて比較実験を行う. 表1に3種類の

表1 各データセットにおける学習データ、テストデータ、評価データそれぞれの枚数

| | 上 | 横 | 上と横 |
|--------|-----|-----|-----|
| 学習データ | 490 | 653 | 957 |
| テストデータ | 416 | 547 | 783 |
| 評価データ | 129 | 156 | 285 |

データセットの学習データ、テストデータ、評価データのそれぞれの枚数を示す。

3.2 実験設定

実験で使用する Data Augmentation と学習モデルに設定するハイパパラメータについて述べる。

Data Augmentation は、左右反転と $\pm 3^\circ$ 回転する動作を行う。あらかじめ ImageNet で学習された ResNet-18 を用いて転移学習を行い、学習回数は 100 エポックとする。学習率、モメンタム、重み減衰、バッチサイズはそれぞれ 0.001, 0.9, 0.005, 8 とする。10 エポックごとに学習率の 0.2 倍を減衰させ学習を行う。

3.3 実験結果

提案手法である ResNet-18 を用いた回帰分析と、その比較手法である線形回帰分析による結果を図 6, 7 に示す。共に横軸は重量の正解値を示しており、縦軸は図 6 では平均誤差、図 7 では重さ推定結果を示している。赤点は線形回帰分析の結果を示し、青点は ResNet-18 を用いた回帰分析の結果を示している。

線形回帰分析では、図 6 よりレタスの重さが重い場合に平均誤差が大きくなっていることがわかる。レタスが成長し 1 方向のカメラ画像では葉が重なって見えるため正確に葉に相当する画素の面積を抽出できないからだと考えられる。また、図 7 より重さが重くなるにつれて結果が悪くなっていることがわかる。そのため、葉に相当する画素の面積に着目した単純な線形回帰分析では重さを推定することが困難であることがわかる。

ResNet-18 を用いた回帰分析では、図 6 より線形回帰分析より結果が良いことがわかる。レタスの葉に相当する画素の面積の特徴量だけではなく、表面の模様などを加味することで、重なり度合いが考慮できる効果があったものと考えられる。しかし、レタスの重さが軽い場合に平均誤差が大きくなっている傾向がある。これは、レタスが十分に成長しておらず画像から得られる特徴量が少ないからであると考えられる。学習データを上、横方向のそれぞれを用いて学習するよりも上と横の両方向の学習データを用いる方が精度よく重さを推定できている。上、横方向のそれぞれの学習よりも上と横の学習データの方が多いため、精度が良くなったと考えられる。

4. まとめ

本研究では、葉に相当する画素の面積に着目した線形回帰分析と ResNet-18 を用いた回帰分析による作物の重さ推定を行う手法を提案した。実験結果より、単純な線形回帰分析より ResNet-18 を用いた回帰分析の方が高い精度を示した。今回の実験では、1 方向から撮影した画像を学習させ重さ推定でも重さを推定することが出来ることがわかった。そのため、複数の方向から撮影した画像をペアにし学習させることでさらに高い精度で行うことが期待できる。

今後の課題としては、さらに精度を向上させるために 1 方向からだけではなく、複数の方向からの画像を用いた重さ推定の実現が挙げられる。また、ResNet-18 よりも高い性能を持つ Wide Residual Network[11]や Dense Net[12]を用いることでさらに高精度に重さを推定出来るのではないかと考えられる。

参考文献

- [1]影山. 吉田. "令和元年台風第 19 号等に係る被害情報". 農林水産省. 2020-04-10. <https://www.maff.go.jp/j/saigai/typhoon/191011/index.html>, (参照 2020-07-17)
- [2]農林業センサス統計第 1 班. "農業就業人口及び基幹的農業従事者数について". 農林水産省. 2017-03-25. <https://www.maff.go.jp/j/tokei/sihyo/data/12.html>, (参照 2020-07-17)
- [3]小田 雅行, 野中 正義, 星野 和生, "人工光下におけるリーフレタスの養液栽培 I. 養液の濃度, pH 及び温度が生育に及ぼす影響," 生物環境調節, vol. 24, no. 3/4, pp. 103-107, 1986.
- [4]T. Murakami and F. Idezawa, "Growth survey of crisp head lettuce (*Lactuca sativa* L.) in fertilizer trial by low-altitude small-balloon sensing," *Soil Science and Plant Nutrition*, vol. 59, no. 3, pp. 410-418, 2013.
- [5]Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.
- [6]K. He, X. Zhang, S. Ren and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [7]M. F. Aydogdu, V. Celik and M. F. Demirci, "Comparison of three different CNN architectures for age classification," in *2017 IEEE 11th international conference on semantic computing (ICSC)*. IEEE, 2017, pp. 372-377.
- [8]P. Natrajan, S. Rajmohan, S. Sundaram, S. Natarajan and R. Hebbar, "A Transfer Learning based CNN approach for Classification of Horticulture plantations using Hyperspectral Images," *2018 IEEE 8th International Advance Computing Conference (IACC)*, 2018, pp. 279-283.
- [9]J. Deng, W. Dong, R. Socher, L. Li, Kai Li and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database," *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp. 248-255.
- [10]矢野 正基, 大賀 隆裕, 大西 正輝, "深層学習を用いた画像識別タスクの精度向上テクニック," *電子情報通信学会論文誌 D*, vol. 102, no. 2, pp. 34-52, 2019.
- [11]S. Zagoruyko and N. Komodakis, "Wide residual networks," in *Proceedings of the British Machine Vision Conference (BMVC)*, E. R. H. Richard C. Wilson and W. A. P. Smith, Eds. BMVA Press, September 2016, pp. 87. 1-87. 12. [Online]. Available: <https://dx.doi.org/10.5244/C.30.87>.
- [12]G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely Connected Convolutional Networks," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 2261-2269.



図6 上の平均誤差（左），横の平均誤差（中心），上・横の平均誤差（右）




図7 上の予測結果（左），横の予測結果（中心），上・横の予測結果（右）