

鹿児島ブランド力向上を目的とした茶葉の葉期推定に関する研究

Research on estimation of leaf stage of tea
leaves to improve brand strength of Kagoshima tea

徳留 大輔*1, 福元 伸也*1, 鹿嶋 雅之*1, 渡邊 睦*1

Daisuke Tokudome*1, Shinya Fukumoto*1, Masayuki Kashima*1, Mutsumi Watanabe*1

1. はじめに

近年、少子高齢化に伴い農業の労働人口不足が問題となっています。農林水産省の調査[1]によると、お茶農家もこの問題に直面している。お茶の圃場調査ではお茶の葉期を目視で約 500 以上もの圃場を人間の力だけで判断する。実際に私も同行しましたが圃場がバラバラにあるので車で移動して各圃場を回るのにかなりの時間と労力を費やした。非常に大変な作業だと感じた。この葉期推定を AI ですることができれば農家さんの負担の軽減にもなり、作業効率を上げることができると考えた。またこれらの作業を AI に置き換えることで、高収益化にもつながることができると考えられる。

2. 関連研究

画像学習において VGG16 を用いることで学習の精度が上がる実験[2]や、ウメの成熟度合いを着色カテゴリーごとに分類している研究[3]、分光画像と機械学習を用いてトマトの収穫時期予測をしている研究[4]がある。mixup で二つのデータに対して線形補完を行い新たなデータを作成することで学習の性能を向上する研究[5]がある。また同じスマート農業の研究ではピーマンの成長度合いを 3 次元復元で行っている研究もある[6]。本研究では VGG16 と VGG19 を学習に使いモデル比較して茶葉の葉期推定に最適な学習を見つける。また mixup など学習精度を向上させる技術を用いて学習の精度を高めていく。本研究は鹿児島大学・堀口製茶レベル 3 自動化農機スマート農業実証コンソーシアムの共同研究であり、鹿児島大学工学部は画像解析・AI を担当する。図 1 にコンソーシアムの概要を示す。

コンソーシアム構成員	役割
関西ブロードバンド	ネットワーク構築
富士通	LSGおよびクラウド
日本計器鹿児島製作所	農機の制御
テラスマイル	農作業計画ICT化
堀口製茶	協力生産者
鹿児島大学農学部	農作物に関する知見
鹿児島大学工学部	画像解析・AI

図 1 鹿児島大学・堀口製茶レベル 3 自動化農機スマート農業実証コンソーシアム

3. 茶葉の概要

茶葉の成長度合いを開葉数といい、開葉とは芽の一枚目が開くことをいう。本研究で撮影した茶葉は萌芽期（芽が

半分以上見えた状態）から 7 日前後で開葉機に入る。1 枚目が開く時よりも 4~5 枚目が開く時は平均気温が上昇しているため、開葉日数は短くなる。図 2 は一番茶の開葉日数を示した図であり、本研究の茶葉はおおよそ 4~5 葉期の間に収穫を行っている。また、図 3 は葉数の数え方の資料であり、茶葉の葉数は下位の葉から順番に数える。ただし、包葉や不完全葉は数えない。包葉とは一番下に付いている小さい葉であり、不完全葉は歯の周りのギザギザが少なく葉脈もはっきりしていないものである。不完全葉は図 3 左の番号 2 の葉と比べて半分以下の大きさであれば不完全葉として葉数には数えない。




図 2：開葉日数（左）

図 3：葉数の数え方（右）

4. 提案手法

4.1 手法の概要

本研究では、図 4 のフローチャートに沿って研究を行っていく。




図 4：提案手法

最初に教師データとなる茶葉の撮影を行う。次に撮影してきた茶葉画像に対してデータセットの作成と前処理を行い学習に向けて準備を行う。そのあとに処理した画像に対してデータ拡張をして精度向上を図る。また、mixup や dropout を使用し、精度向上を行った。学習は VGG16 と

*1 鹿児島大学工学部
School of Engineering, Kagoshima University

VGG19 をモデルに進めて行っていく。またエッジ処理を行なった茶葉画像を入れて学習を行いエッジ処理は効果的になるかを検証した。最後に学習したデータをもとに茶葉の葉期推定を行う。

4.2 教師データ取得

茶葉画像の取得はスマートフォンによる収集アプリを用いて、堀口製茶の圃場にて撮影をした。この茶葉画像を取得するスマートフォンのアプリは独自開発のものであり学習用の茶葉画像として撮影し保存する専用のアプリとなっている。実際の葉期推定に用いられるアルミ枠を基準とし、アルミ枠を収集アプリの画面上にある赤い枠に合わせて撮影をした。図 5 はアプリを起動し、撮影する画面である。この赤い枠にアルミ枠を合わせて撮影した画像が図 6 である。生産者が実際に葉期推定を行っている目線に合わせてアプリを改善し撮影を行ってきた。また、茶葉の葉期に関しては、撮影する部分で茶葉の成長度合いが違うため、その圃場の平均を出すことでその圃場の葉期としている。




図 5 : 教師データ取得アプリ (左)

図 6 : アプリで撮影した茶葉画像 (右)

4.3 データセットの作成と前処理

データセット作成ではまず画僧サイズを 256×256 に統一し、画像を葉の枚数 (葉の開き具合) ごとにフォルダ分けを行いました。クラスは 0.9, 1.5, 1.7, 1.8, 1.9, 2.0, 2.1, 2.5, 3.4, 3.5, 3.8, 3.9, 4.0 までの 13 クラスに分けました。0.9 と言うのは 0.9 葉期であり、完全に 1 枚の葉が出る直前の状態である。また 4.0 葉期は完全に 4 枚出ている状態を示している。この葉期に関してはお茶農家が圃場調査で示した葉期をラベル付けてフォルダ分けを行っている。

4.4 データ拡張

データ拡張は 13 クラスそれぞれ、約 3000 枚から約 10000 枚に増やした。1 枚の画像を約 20 枚にし、左右反転・上下反転・ランダムに回転・ノイズの付与を行った。そのあとに、学習用・検証用・テスト用に分類した。実際にデータ拡張を行った茶葉画像は図 7 に示す。



図 7 : データ拡張後の画像

4.4.1 mixup

訓練サンプルのペアを混合して新たな訓練サンプルを作成するデータ拡張手法の 1 つである。データとラベルのペア $(X1, y1), (X2, y2)$ から下記の式により新たな訓練サンプル (X, y) を作成する技法である。

$$X = \lambda X1 + (1 - \lambda) X2$$

$$y = \lambda y1 + (1 - \lambda) y2$$

ここで、 $\lambda \in [0, 1]$ はベータ分布 $\text{Be}(\alpha, \alpha)$ からサンプリングにより取得し、 α はハイパーパラメータとなる。特徴的なのは、データ $X1, X2$ だけではなく、ラベル $y1, y2$ も混合してしまう点である。図 8 は実際に mixup を行った画像である。ぼんやり 2 枚の画像が合成されたような画像が出力される



図 8 : mixup した茶葉画像

4.4.2 dropout

dropout とは特定のレイヤーの出力を学習時にランダムで 0 に落とすことで、一部のデータが欠損していても正しく認識ができるようする技法である。dropout を用いることで過学習を抑えることができる。本研究でも過学習を抑えるために dropout を実装する。dropout は学習モデルの階層に入れて実装している。

4.4.3 エッジ処理

エッジ検出は画像内にある物体のエッジを見つけるために用いられる。エッジは輝度の不連続性から検出することができ、物体の輪郭や特徴抽出、画像のセグメンテーション (領域分割) 等の画像解析に使われる。本研究ではエッジ処理の中でも canny 法を用いた。弱いエッジも正確に検出できる強力なエッジ検出手法の一つで、他のエッジ検出と比較してノイズに対する誤検出も少ない手法である。特徴量を出すことで精度向上に役立つと考えた。図 9 に canny 法を行った茶葉画像を示す。



図 9 : canny 法後の茶葉画像

5. 評価実験

ネットワークモデルには VGG16 と VGG19 を用いて学習を進めた。学習層が違うモデルで比較してみた。そして、

過学習を抑えるために dropout を使用し、精度向上のために mixup を導入して学習を行った。また茶葉画像にエッジ処理の canny 法を使って画像処理を行い茶葉のエッジを強調させた画像を作成した。それを使い、エッジ処理を行った茶葉画像だけの学習と、エッジ処理と通常の茶葉画像を混ぜて学習を行い、VGG16・VGG19 やエッジ処理は葉期推定に効果があるのかを評価する。学習に関して活性化関数は softmax を用いた。モデルのコンパイルに関して、損失関数には多クラス分類交差エントロピーを用い、評価関数は正解率である accuracy を用いた。またエポック数は 100 とした。

6. 実験結果

6.1 VGG16 での学習結果

VGG16 で茶葉画像を学習した結果を図 10 に示す。VGG16 で学習を行なったところ、損失が 0.396 (右)、精度が 89.6% (左) となった。13 クラスかつ複雑な茶葉の葉期を分類して、精度が 89.6% になったのは高いと考えられる。この学習は mixup を使用して学習を行っている。




図 10 : vgg16 で学習した結果

6.2 VGG19 での学習結果

VGG19 で茶葉画像を学習した結果を図 11 に示す。VGG19 で学習を行なったところ、損失が 0.435 (右)、精度が 85.3% (左) となった。VGG16 に比べると少しではあるが VGG19 の方が低い精度になった。この学習も mixup を使用して学習を行っている。




図 11 : vgg19 での学習結果

6.3 mixup を含めない学習結果

茶葉画像の学習実験 6.1 と 6.2 では、mixup を使用して VGG16 と VGG19 に学習を行ったが、実際に mixup を使用していない学習だとどのくらいの精度になるかを比較する。

比較した表を表 1 に示す。比較した結果 mixup を使用して学習した結果の方が高い精度となった。

mixup	損失	精度
有り(VGG16)	0.396	89.6
無し(VGG16)	0.631	83.5
有り(VGG19)	0.435	85.3
無し(VGG19)	0.523	82.5

表 1 : mixup の学習比較

6.4 エッジ処理のみの学習結果

エッジ処理画像のみでの学習を行った結果を図 12 に示す。エッジ処理の学習モデルは VGG16 で学習している。学習した結果、損失が 2.56 (右)、精度が 4.8% (左) とかなり低い精度となった。




図 12 : エッジ処理のみの学習結果

6.5 エッジ処理と VGG16 での学習結果

エッジ処理画像と VGG16 で学習を行った時の画像を合わせて学習させた結果を図 13 に示す。結果としては損失が 1.4 (右)、精度が 70.7% (左) となった。エッジ処理画像だけの学習よりは精度が上がったが、エッジ処理を含めない学習の方が精度も高く損失も少なくなった。




図 13 : エッジ処理と vgg16 を混ぜた学習結果

7. 茶葉画像の葉期推定

vgg だけで学習した結果が良かったので VGG だけで学習したデータで推定と推定に関する信頼度を示した。VGG16 の結果を図 14, VGG19 の結果を図 15 で示した。推定は学習に用いていないテストデータ 100 枚をランダムで用いて行った。正解の推定を黒色、誤った推定を赤で示している。全般的に正解の推定を多く示すことができている。VGG16 を使って推定した時の正答の割合は 91/100 が正解と示された。また、VGG19 を使った時の正答の割合は 88/100 という結果が示された。ほぼ 9 割に近い正解率を出せたと考え

られる。しかし、正答に対する信頼度が高いのにも関わらず誤った推定をしているのもあった。



図 14 : vgg16 で行った推定と信頼度



図 15 : vgg19 で行った推定と信頼度

8. 考察

本手法による茶葉の葉期推定における VGG16 と VGG19 による学習が実際にラベル付けした値と推定値の予測精度が 85~90%であった。13クラス分類し茶葉の複雑な画像に対して高い精度で推定できたと考えられる。学習モデルの階層が増えると精度が高くなると思っていたが、実際に実装して学習させると、VGG16の方が高い精度を示すことができた。茶葉画像を学習させる上で一概にも学習モデルの階層を増やしても精度が上がるとは限らないと考えられる。mixup を使用していない際の結果の比較に関して、mixup が同じ画像でも違う画像として茶葉画像を増加して教師データを増やしたため精度が上がったと考えられる。またエッジ処理の canny 法を用いて学習を行ったが悪い精度になってしまった。エッジ処理の canny 法をかけたときに特徴となる部分である葉の枚数に対してエッジがかかっていたのが原因だと考えられる。葉が複数枚ある場合、エッジ処理を行うとかなり複雑になり、学習に影響が出てくると考える。エッジ処理だけでは推定できないと考えられる。推定の信頼度に関しては、高い正答率を示すことができた。しかし、茶葉画像の正答に対しての信頼度が 90%以上あるにも関わらず誤った判定をしているのもあった。特に 3.5 葉期以降に目立っており、これは 3.5 葉期以降の画像が他の茶葉画像に比べて少ないことや成長があまりにも変

わらないため推定が困難になっているのではないかと考える。しかし、茶葉という複雑な画像で 85%以上の精度と高い正答率で推定できたということが示せたと考える。今後の展望として、茶葉画像の葉期のクラス分けに関して、0~5 葉期までのクラス分類を想定しているため、現時点だとまだクラスが足りない茶葉画像がある。これに関しては茶葉画像を撮影しに行った際に成長してその葉期が撮影できなかったためである。また、クラス分類は 0.1 刻みでクラス分類しているため、今後クラスが増えていく予定である。これに対して高い精度を出すモデルや画像処理の技法を検討していく必要がある。今後は、学習モデルを VGG 以外での学習モデルでも試していき精度が高いモデルでの葉期推定のシステム確立に向けて研究を進めていく。

9. まとめ

本校では、VGG16 や VGG19 という学習モデルを用いた深層学習で茶葉の葉期推定の手法を提案した。評価実験では、本手法による VGG16 と VGG19 による学習が実際にラベル付けした値と推定値の予測精度が 85~90%であった。推定及び信頼度に関して、推定に対して高い正答率を示すことができた。茶葉の葉期推定のシステムが出来れば今後、お茶農家の非常に大変な作業である葉期推定を AI ことができ、負担の軽減にもなり、作業効率を上げることができる。また、高収益化にもつながることができると考えられる。これにより鹿児島ブランドであるお茶の生産性を向上できると考えられる。

謝辞

本研究は、農林水産省「スマート農業実証プロジェクト (ローカル 5G) (課題番号: 5GH03, 課題名: ローカル 5G に基づく超高速・超低遅延による自動運転および Drone/LPWA 等による圃場センシング・AI など営農・栽培データ解析による摘採計画の最適化体系及びシェアリングの実証)」(事業主体: 国立研究開発法人農業・食品産業技術総合研究機構) の支援により実施した

参考文献

- [1] 農林水産省, "2020 年農林業センサス 茶をめぐる情勢", pp8 令和 3 年 1 月
- [2] 中山英樹, "真相量み込みニューラルネットワークによる画像特徴抽出と転移学習", 東京大学 大学院情報理工学 研究科, 信学技報, pp1-6, (2012)
- [3] 建本 聡, 原田陽子, 今井健司, "深層学習を利用したウメ「露茜」の画像による熟度分類", 農業情報研究 28 (3), 2019. 108-114
- [4] 洞井晋一, 増田貴大, 坂川涼, 東田光裕, "分光画像と機械学習を用いたトマトの収穫時期予測に関する研究", マルチメディア, 分散, 協調とモバイル(DICOMO2017)シンポジウム, 2017
- [5] Hongyi Zhang, Moustapha Cisse, Yann N. Dauphin, David Lopez-Paz, "mixup: Beyond Empirical Risk Minimization", pp1-13, (2017)
- [6] 近藤烈司, 福元伸也, 鹿嶋雅之, 渡邊睦, 神田英司, 池澤和広 "スマート農業化に向けた 3 次元復元に基づく植物の成長推定に関する研究" 第 20 回 情報科学技術フォーラム (FIT2021), H-012 (2021.8)