

深層学習による海苔の品質判定のデータ分割の有効性 Effectiveness of data division for quality judgment of seaweed by Deep Learning

○ 鈴木 大智¹, 栗野 俊一²
*Suzuki Daichi¹, Kurino Shun-ichi²

Abstract: The purpose of this study is to define the quality of seaweed by deep learning image recognition. Generally, a large amount of learning data are required for deep learning. Since the number of data is small in this case, by transfer learning and image division, we were able to improve the learning efficiency and obtain the desired judgment accuracy.

1. はじめに

海苔の市場価格は、等級によって決定されるため、生産者にとって重要な関心事である。等級判定は漁業組合において、有資格者による目視によって実施される。

しかし、この有資格者の高齢化による後継者不足が深刻となっており、海苔の等級判定の自動化が要望されている。

そこで本研究では、海苔の等級判定を深層学習の画像認識により自動で行う事を試みる。

2. 背景と目的

深層学習を有効に活用するためには大量の学習データが必須であるが、対象の領域によっては大量の学習データが得られない場合も少なくない。

本研究の目的は、海苔の等級判定を写真撮影した少ない画像データから、深層学習を用いて、高い正解率を持つ判定器を実現することである。画像認識の分野では、このような場合、転移学習 [1] が有効である事が知られているが、それでも不十分な場合もあり、今回の海苔の等級判定でも、十分な学習効果が得られなかった。

そこで、我々は認識の対象となる海苔画像が輪郭をもたないという特性を生かし、入力画像を分割したデータ (図 2) を作成し学習を行う事により、精度を高める事にした。

3. 海苔画像の学習

3.1 採取した海苔画像データ

予め専門家の手によって、5つの等級に分けられた225枚の乾海苔を入手し、それらを写真撮影した。1枚の画像サイズは3300 x 3400ピクセルのjpeg形式で、画像データ1枚に1つの等級を付与し学習データを作成した。

3.2 転移学習の利用

本研究では、少ない学習データでも高い学習効果が得られる事が知られている「転移学習 [1]」を用いる。今回、転移元として利用するのは、Xception[2]モデルである。

転移学習では、利用するモデルの制約から学習、判定対象の画像をリサイズする必要があるが、学習や判定に必要な情報の欠落が懸念された。

4. 画像の分割

4.1 輪郭をもたない認識対象

海苔の画像データには次のような、輪郭をもたない認識対象としての性質があると考えられる。

1. 海苔は輪郭に品質を表すような特徴をもたない。海苔の等級は輪郭にはよらず、表面の色と光の反射具合によって決まる。
2. 海苔は1枚であっても、位置や部分によって、品質が異なることがありうるが、海苔の等級は、1枚の表面全体の品質を総合することにより決まる。

4.2 データの分割の根拠

我々はAIの学習のための入力画像を分割をすることにした。画像を分割するメリットとデメリット、その対策について述べる。

1. 海苔は輪郭に品質を表すような特徴を持たないため、画像による品質分類を行うにあたっては、学習に用いる画像を分割しても、失われる情報量が少ない。
2. 分割を行うことで、学習データを増加させた時と同様の効果が期待できる。分割をしない場合と、した場合では、分割をした方がデータの件数が多く、海苔は一部切り取っても再び海苔であるため、画像を分割することにより、データが増えることを擬似的に再現できる。
3. 画像の圧縮による情報量の喪失を回避できる。転移学習を用いているため、入力サイズは転移元のモデルに依存する。オリジナルの画像はモデルの入力サイズより大きいため、入力時に圧縮が行われ、情報量が失われる恐れがある。画像分割を行い、モデルの入力サイズと入力画像のサイズを同じ大きさにすれば、圧縮の必要がないため情報量が失われずに済む。
4. 部分により等級が異なる可能性については、分割前は同じ画像であったものの予測を総合して、1つの海苔の等級の評価とすることとした (図 1)。

表 1: 分割の場合と、非分割の場合の 1~5 等級の等級判定テストの正解率 (小数点以下第 3 位で四捨五入)

	1 回目	2 回目	3 回目	4 回目	5 回目	6 回目	7 回目	8 回目	9 回目	10 回目	平均
分割	1.0	1.0	1.0	1.0	0.95	1.0	1.0	0.95	1.0	1.0	0.99
非分割	0.85	0.85	0.85	0.85	0.70	0.85	0.90	0.90	0.95	0.95	0.865

海苔は同じ 1 枚であっても、表面の部分により等級が異なる可能性があるため、分割を行うと分散が増加する可能性があるが、元の 1 枚に関して評価を総合することでこの問題に対処した。




図 1: 分割した海苔画像から予測を決定する

以上から我々は「分割しなかった場合よりも、分割し予測を総合した方が精度が高いモデルができる」と予想した。

5. 実験

実験では、同じ学習データ、同じモデルを利用し、入力画像を分割した場合と分割しない場合のそれぞれの結果を求め、比較する。

5.1 学習データ

学習に用いるデータは、1 等級 45 枚、2 等級 45 枚、3 等級 45 枚、4 等級 44 枚、5 等級 46 枚の計 225 枚である。

分割前のデータのサイズは 3300x3400 ピクセルで RGB 3 チャンネルをもつ画像であり、分割するときは、299x299 ピクセルで RGB 3 チャンネルの画像を敷き詰めるようにして、1 枚あたり 110 枚に分割した。

データセットの全件数は分割をしない場合で 225 枚、分割をした場合で 24750 枚である。

5.2 実験環境

AI の学習について述べる。1 ~ 5 等級の海苔を撮影し、海苔以外の背景部分を取り除く。これらの画像データを train, validation, test 用に、等級ごとに 8:1:1 に乱数を用いて仕分け、学習からテストまでを実施し、テストの正解率を求める。これを 1 セットとし、画像を分割した場合としない場合に対し、各 10 回ずつ学習実験を行う。

5.3 精度の評価方法

分割をした場合としない場合の精度の評価方法について述べる。分割をしなかった場合は、学習後のモデルを用いて、テストデータ 1 件ずつに対して判定を行い、それら




図 2: 海苔画像を分割するイメージ

と正解ラベルとの一致率をモデルの精度とする。分割をした場合では、分割後の各テストデータに対して学習後のモデルによる評価を行い、分割前に 1 枚であった 110 個の部分の評価を集め、最頻値をとる。この最頻値を分割前のテストデータに付与された正解ラベルと比較し、同じであれば正解、異なっていれば誤りとする。これらにより、分割した場合としない場合のモデルの予測精度を比較する。これらは「海苔 1 枚に対する等級判定」という観点で同等の指標である。

6. 結果

分割をした場合としない場合の予測精度を表 1 に示す。1~10 のデータセットは、それぞれ学習とテストに用いるデータの選び方を変えて複数作成したものである。結果として「分割しなかった場合よりも、分割して学習し予測を総合した方が正解率が高い」ことがわかる。

7. 結論

この事から、海苔の様に輪郭をもたない対象物の画像認識を転移学習を用いて学習を行う場合は、入力画像の解像度を落さず、学習データを増やす、画像の分割手法が有効である事がわかった。

8. 参考文献

[1] 中山英樹. 深層畳み込みニューラルネットによる画像特徴抽出と転移学習. 信学技報, Vol. 115, No. 146, pp. 55-59, 2015.

[2] François Chollet. Xception: Deep learning with depth-wise separable convolutions. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1800-1807, 2017.