

転移学習による海苔の品質判定における Data Augmentation の有効性 Effectiveness of Data Augmentation in Judging Dried Seaweed Quality Using Transfer Learning

○阿部舜耶¹, 平石秀史²
*Toshiya Abe¹, Hidefumi Hiraishi²

Abstract: In this research, we tackled automation of grading seaweeds by machine learning. Seaweed being a seasonal product, our task faces the typical obstacle in machine learning: scarcity of dataset. To overcome this hurdle, we exploited transfer learning combined with data augmentation. We experimentally showed that it would boost the precision of classifier to exploit domain-specific features of seaweed images for data augmentation.

1. はじめに

海苔の等級とは海苔の品質の階級を示す[1]. 海苔の等級の判定は、熟練した検査員の目視により実施されている。しかし、検査員の高齢化により、後継者不足が深刻な問題となっている。そのため、海苔の等級判定の自動化が要望されている。既存研究として、安部他[2]は、カラーリーダーを用いた海苔の品質評価に取り組んでいる。本研究では、海苔の等級判定の自動化を深層学習の画像認識により試みる。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要である。しかし、海苔は季節性の海産物であり、大量にサンプルを入手することが困難である。そのため、本研究の目的は、写真撮影した少ない海苔の画像データから、深層学習を用いて高い正解率を持つ判定器を作ることである。また、画像枚数が少ない場合には、転移学習[3]が有効である事が知られており、本研究では転移元として Xception [3] モデルを使用している。また、転移学習ではモデルの制約から、学習データを拡大・縮小が必要となる場合がある。そのため、学習や判定に必要な情報の欠落が懸念される。Xception モデルの制約は、「入力画像のサイズが 299*299 pixel」である。我々の海苔の画像は 3250*3400 pixel であり、そのまま入力すると縮小が起き、情報が欠落する。さらに画像の枚数は 1class あたり約 45 枚であり、転移学習を利用するのに十分な枚数でない。これらの問題に対し、鈴木、栗野[4]は、海苔の画像を水平垂直に 299*299pixel に分割した。これにより、1class あたりのデータ数は約 450 枚に増加し、入力の際の縮小処理は不要になった。しかし、海苔は 1 枚の海苔でも部分によって品質の善し悪しがある。検査員は海苔 1 枚全体を俯瞰して等級を判定しており、水平垂直に分割された海苔の画像を学習させると、ある等級の海苔の画像の学習で、実際は

品質の異なる海苔の画像を学習させている場合がある。これは、判定器の精度を低くする。また、画像数は分割により増加したものの、まだ枚数は少ない。そこで、我々は Data Augmentation (以下 DA と略す) として海苔画像にトリミング・縮小・回転の画像処理を行うことで、画像枚数を増加させ、海苔 1 枚を俯瞰した画像を用いた学習を行う事により、精度を高める事にした。

2. 実験手法

2.1 オリジナル画像

用いた画像は 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。各画像はサイズ 3400 * 3250 pixel, RGB フルカラー, jpeg 形式で、等級をラベルとした学習データを作成した。

2.2 Data Augmentation

2.2.1 トリミング, 縮小, 回転の概要と効果

1 枚の画像を次の順に加工し、画像数を増加させる。

(1) トリミング

オリジナル画像を 2691*2691 の正方形に左端から 100pixel ずつ切り取り、画像を 8 枚生成する。

(2) 縮小

(1)で生成した画像を 9*9pixel を 1pixel に縮小することで 299*299 の画像を生成する。今回は縮小前の 9*9pixel の RGB 値それぞれの値から平均値, 中央値, 最大値, 最小値をとることで, (1)で作成した画像 1 枚から 4 通りの画像を生成する。

(3) 回転

(2)の画像を回転, 反転させて画像数を増加させる。回転は 0°, 90°, 180°, 270°, 反転は回転させた画像に対してそれぞれ行う。これより, 1 枚の(2)の画像から 8 枚の画像が生成できる。このように画像を加工することで 1 枚の元画像から $8*4*8=256$ 枚の画像が生成できる。

1: 日大理工・院(前)・数学 2: 日大理工・教員・数学

表 1 : Percentage of correct labels predicted by AI

セット	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	計
正解枚数	15/15	15/15	13/15	15/15	15/15	15/15	15/15	15/15	15/15	15/15	15/15	15/15	15/15	15/15	14/14	222/224
正解率	1.00	1.00	0.87	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	0.99

2.2.2 トリミング, 縮小, 回転の根拠

(1) トリミング

本手法のトリミングで生成される画像のサイズの割合は、画像全体の大きさに対して十分に大きく、海苔1枚を俯瞰するのに十分であると考えられる。また、切り取った画像はすべて異なる画像である。

(2) 縮小

各 pixel には0~255のRGB値を表す三要素のベクトルが割り当てられており、縮小後のRGB値をどのようにきめるかという点に任意性がある。縮小処理が転移学習モデル側で行われた際に、画像が不自然なものになる場合があり、縮小処理をあらかじめ行っておくことで、この問題を回避できる。

(3) 回転

検査員は等級の判定時に海苔を手に取り、左右上下に回転させ判定している。そのため画像の加工の方法として自然といえる。反転についても同様である。

2.2.3 AIの精度の評価方法

2.2で加工した画像は、元の海苔画像は同じであってもAIの等級ラベルの予測が異なる可能性がある。そこで、元の1枚のオリジナル画像から生成されるすべての画像に対して予測ラベルの多数決をとることでこの問題に対処する。1枚のオリジナル画像から256枚の拡張データが生成される。それらに対しAIは256の予測ラベルを出力する。これらのラベルに対して最頻値を取り、それをオリジナルの画像に対する最終的な予測ラベルとする。これは「海苔1枚に対する等級判定」という観点で検査員の評価と同等の指標である。

2.3 実験

2.3.1 学習データ

2.2による画像処理によりDAした画像を学習に用いる。枚数は、1等級11520枚、2等級11520枚、3等級11520枚、4等級11264枚、5等級11776枚の計57600枚である。サイズは299x299pixelで、RGB3チャンネルをもつjpeg画像である。

2.3.2 実験環境

“各等級”のDA前のオリジナル画像から3枚の画像をtestデータとした。残りのオリジナル画像をtrain, validationデータに8:2の割合でランダムに配置した。

その後、配置したすべてのオリジナル画像をDAし枚数を増加させた。このデータセットで学習からテストまでを実施し、AIの予測の正解率を求める。これを1セットとし、15セットを繰り返す。なお、どのセットについても他のデータセットのtestデータと重複はないため、すべてのオリジナル画像に対し、ちょうど1回のテストが行われる。

3. 結果と結論

15セット分の正解率を表1に示す。これより十分な学習ができていることがわかる。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する場合は、入力画像の解像度を落さずに学習データを増やす本手法のデータ拡張が有効である事がわかった。DA画像の予測ラベルの多数決の詳細を見ると、圧倒的多数で正解しているものがほとんどであった。これより、「海苔の等級は全体を俯瞰して判断する」ことは合理的といえる。したがって、画像を水平垂直に分割する画像数増加よりも本手法は海苔の等級分類に適している。一方、不正解だったものは多数決が他の等級ラベルと拮抗していた。今後は、多数決の詳細をレーティング形式で明確化するべきだと考える。また、自然な画像の縮小の方法は多くあり、海苔の画像に学習に適した縮小をさらに行って画像数を増やし、精度を向上させる。

参考文献

[1] 海苔産業情報センター, 海苔ジャーナルエクспレス <http://www.j-nori.com/talk3.html>
 [2] 安保康治[他], カラーリーダーによる板海苔の品質評価, 久留米信愛女学院短期大学研究紀要. 32, 2009
 [3] François Chollet, Xception: Deep learning with depth-wise separable convolutions. In Proc. of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.1800–1807, 2017.
 [4] 鈴木大智, 栗野俊一, 深層学習による海苔の品質判定のデータ分割の有効性, 令和3年度日本大学理工学部学術講演会予稿集, P-1, pp. 831-832, 2021