

ヒナの摂食誘導システムにおける 個体検出精度向上のための訓練データ拡張

市原禄朗† 宅野亮†† 新村毅††† 辻愛里†††† 藤波香織††††

† 東京農工大学 工学部 情報工学科

†† 東京農工大学 大学院 生物システム応用科学府 生物機能システム科学専攻

††† 東京農工大学 大学院 農学研究院 生物生産科学部門

†††† 東京農工大学 大学院 工学研究院 先端情報科学部門

1 はじめに

養鶏場においてヒナの摂食状況の偏りによって、最悪の場合栄養不足で死んでしまう個体が発生することが問題となっている。これをヒナの摂食を誘導するシステムで解決を試みているが、システムで用いる物体（ヒナ）の検出精度が低いことが課題となっている。これは、ヒナの体が小さいことと、複数の環境の学習画像を収集するのが困難なため、汎用性が低いことが原因だと考えられた。そこで、本研究では物体検出の精度と汎用性向上を目的としたデータ拡張手法を提案する。

2 摂食誘導システム

図1にシステムの概要を示す。本システムでは、ヒナの画像を学習させた物体検出器で検出を行い、得られた位置情報から親鶏を模したロボットを操作する。ヒナのケージ内は上から Web カメラで撮影され、PC では、物体検出器の YOLO を用いて検出したヒナの位置情報を可視化し、スマートフォン側に送信する。スマートフォン側では得られた画像を元に、HTTP 通信を介して親鶏ロボットを操作する。親鶏ロボットはアプリからの信号に応じて床を叩き、それによってヒナの注意を引くことで摂食を誘導する。

3 データ拡張の実装

3.1 概要

データ拡張とは学習データを加工し、擬似的に新規の学習データを生成する手法である。拡張を行うことで、学習データを水増しし、精度や汎用性が向上することが知られているが、最適な方法は対象に依存する。また、物体検出においては様々なデータ拡張を併用することでより精度が向上する場合がある。しかし、ヒナの物体検出に有効なデータ拡張および併用による精度向上は未知であるため、本研究で明らかにする。

3.2 実装したデータ拡張

本研究で実装したデータ拡張は既存手法5つと独自に考案したデータ拡張1つである。既存手法は画像を




図1: システム概要図

ランダムに反転させる Random-flipping(RF) と画像をランダムに切り抜く Random-cropping(RC), また、近年考案された手法である物体の一部に遮蔽を生成する Random-erasing[1](RE) と画像に物体を合成する手法 [2](Synthesizing の意より S と呼称), 格子状の遮蔽を生成する FenceMask[3](FM) の5つである。そして、Error-Synthesizing(ES) と呼ぶ手法を新たに導入する。ES は、既存の画像から学習を行い作成したモデルで検出を行い、誤判定領域を画像に合成し、データを拡張する。学習段階で誤判定しやすい領域を画像に合成する事によって、学習中に誤判定を修正させ、精度の向上を図る。以上の6つのデータ拡張に関してすべての組み合わせで拡張を行い、精度を調査した。

4 精度評価と考察

4.1 実験概要

既存の学習データとは異なる新しい環境の画像をテストデータに加えて検証を行い、学習データが単一でも様々なデータ拡張を行うことで、新規環境における精度や汎用性を調査した。実験はヒナの画像を用いて行い、学習と学習中の検証には単一環境の画像を 501 枚と 167 枚をそれぞれ使用した (図2 上部)。また、精度評価に用いるテスト画像には学習と同環境の画像 40 枚と、図2 下部の新規環境画像を 20 枚ずつ、計 80 枚使用した。そして、検出器には YOLOv5 を用い、通常内部で行われるデータ拡張は無効にした。

4.2 データ拡張の方法

データ拡張はすべての学習画像に対して1回ずつ、つまり全体の枚数が2倍になるように拡張を行った。また、拡張は先述した6手法全ての組み合わせ、つまり合計63通りで行い、各組合せにおける拡張手法適用の順番はサンプルごとにランダムに決定した。

Data augmentation for improving accuracy of chick detection in a robotic feed guidance system

† Rokuro ICHIHARA†† Ryo TAKUNO††† Tsuyoshi SHIMMURA

†††† Airi TSUJI †††† Kaori FUJINAMI

† Department of Computer and Information Sciences, Tokyo University of Agriculture and Technology

†† Department of Bio-Functions and Systems Science, Tokyo University of Agriculture and Technology

††† Division of Science of Biological Production, Tokyo University of Agriculture and Technology

†††† Division of Advanced Information Technology and Computer Science, Tokyo University of Agriculture and Technology



図 2: 学習と検証に使用した画像例 (上) とテスト用に追加した画像例 (下 2 枚)

4.3 実験結果

精度評価の指標には、正解ラベルの領域と検出した領域から IoU(1) と呼ばれる指標を、検出成功の閾値として Precision(検出の正しさの数値) と Recall(検出率の数値) を計算し、精度を評価する値である AP を用いた。AP は縦軸に Precision, 横軸に Recall をプロットした曲線を積分した値である。これによって、検出の精度と全体の正解率を含んだ計算をすることができる。本実験では 0.5-0.95 の IoU に対して 0.05 間隔で 10 個の AP を求め、それを平均した値を精度評価値として用いた。また、比較対象として、拡張していない学習画像で作成したモデルを Default とした。図 3 に各データ拡張単体で拡張をし、学習したモデルの AP の比較を示す。また、表 1 に拡張をした画像で学習をし、AP の高かった上位 5 つの組み合わせを示す。

$$IoU = \frac{\text{(正解領域と検出領域の共通部分)}}{\text{(正解領域と検出領域の和集合)}} \quad (1)$$

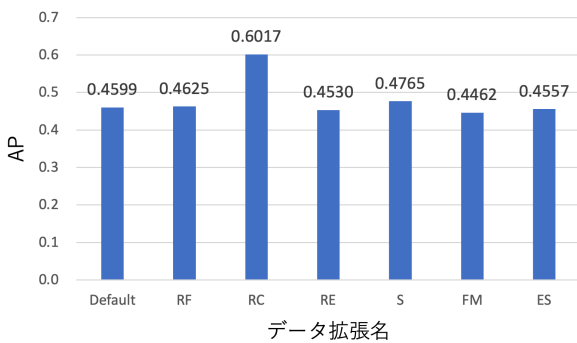


図 3: 各データ拡張の精度比較

(RF:Random-flipping,RC:Random-cropping,RE:Random-erasing, S:Synthesizing,FM:FenceMask,ES:Error-Synthesizing)

4.4 考察

4.4.1 各データ拡張について

図 3 より、単体でみると一番精度の向上するデータ拡張は RC であることがわかった。これは、ヒナが小さくピクセル数が少ないことから学習が難しいため、擬似的にピクセル数を上げることが精度向上に効果的であったためだと考えられる。また、1 つの新規環境では他に比べてヒナが大きく映っていたため、ヒナを大きくした画像で学習ができていたことも精度が向上した要因として考えられる。

Default と比べてわずかに精度が低下した 3 つの手法に関してはどれも遮蔽を生成するという共通点がある。すなわち、ES は誤判定領域として、ヒナではない背景

表 1: 実験結果

順位	RF	RC	RE	S	FM	ES	AP
Default							0.4599
1	○	○	○		○	○	0.6243
2		○	○	○	○	○	0.6166
3	○	○	○	○			0.6165
4		○	○		○	○	0.6156
5		○				○	0.6102

部分を合成し、残りの RE, FM は遮蔽を生成する。そのため、ヒナを余計に隠したことが少ないピクセル数を減らし、精度が低下したと考えられる。

4.4.2 データ拡張の併用について

表 1 より、個別では精度が低下した ES, RE, FM の 3 つの手法は RC と併用することによって精度の向上が見られた。これは RC によってヒナのピクセル数が増え、遮蔽の割合が減ったことが要因として考えられる。特に、ES に関しては、RC と組み合わせることで高い精度の向上が見られた。そのため、誤判定領域を合成する際に、物体部分を守る実装をすることで精度が向上することが見込まれる。

また、表 1 の 1 位の組み合わせより、S 以外を併用することで高い精度となることが確認できた。これより、データ拡張は併用することで基本的に精度が向上するということがいえる。S が含まれなかった理由としては、遮蔽を生成した後に物体を合成してしまい、不自然な画像が生成されるなどの問題が考えられる。

5 おわりに

本論文では、ヒナの物体検出に有効なデータ拡張手法を提案した。実験の結果より、単体では Random-cropping が一番有効であるとわかった。また、本実験で使用した 6 つのデータ拡張は、基本的に併用することによって精度と汎用性が向上し、新規の環境に対しても検出精度が向上することがわかった。そして、独自に考案したデータ拡張 (Error-Synthesizing) は、併用時に効果が上がることがわかった。今後は、各データ拡張のパラメータや拡張の割合などに着目して、調査を行う。

謝辞

本研究は東京農工大学融合研究支援制度 (TAMAGO) と JST A-STEP (JPMJTR21U8) の支援を受けた。

参考文献

- [1] Z.Zhong, et al. Random erasing data augmentation. In *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 34, pp. 13001–13008, 2020.
- [2] D.M.Montserrat, et al. Training object detection and recognition cnn models using data augmentation. *Electronic Imaging*, Vol. 2017, No. 10, pp. 27–36, 2017.
- [3] P.Li, et al. Fencemask: A data augmentation approach for pre-extracted image features. *arXiv preprint arXiv:2006.07877*, 2020.