

段階的畳み込み自己符号化器を用いたミツバチ画像分類手法の検証

和田拓也[†] 高橋伸弥[‡] 鶴田直之[‡] 藍浩之^{*}

福岡大学大学院工学研究科[†] 福岡大学工学部[‡] 福岡大学理学部^{*}

1. はじめに

近年、計算機の性能が格段に向上したことから、動物の行動観察を計算機プログラムにより自動化しようというComputational Ethologyと呼ばれる研究分野が世界的に注目されている^[1]。特にアリやミツバチのような社会性昆虫と呼ばれる、集団で生活をしているような昆虫の行動解析を人手で行うことには限界があるため、計算機により部分的にでも自動化が実現できれば、より多くの新たな知見が得られるものと期待されている。我々の研究室でも、ミツバチの巣内における帰巣個体の尻振りダンス行動とその周辺個体の行動とを画像処理により自動追跡し、採餌関連行動を観察することを目的として、複数個体の歩行軌跡を同時追跡するアルゴリズムを適用したシステムを開発している^[2]が、その更なる高精度化が課題として残っていた。

このような画像処理による行動観察では、ニューラルネットワークを用いた高精度な対象領域検出手法が広く用いられるようになっていることから、ミツバチ検出にも同様の手法を適用できれば課題の解決が期待できる。しかし、ニューラルネットワークを用いた手法では、正解ラベルをつけた大量の学習データで予め学習を行っておく必要があり、我々のプロジェクトにおいては大量のラベル無しデータは取得済みではあるものの、正解データの準備に多大な労力を要するため、容易には実現できないという問題があった。

この問題に対し、大量のラベル無しデータを対象に段階的畳み込み自己符号化器(図1)による教師なし学習を行って特徴抽出を行う手法を考案し、この特徴に基づいてクラスタリングすることでミツバチ画像进行分类することを検討

してきた^[3]。本稿ではこの手法に対し、次元数や学習エポック数、さらには損失関数を変更した際の性能評価を行って、提案手法の有効性を検証した。

2. 段階的畳み込み自己符号化器

自己符号化器は、入力と同一な出力がされるように中間層を学習するニューラルネットであり、入力データの次元より小さな次元で中間層を表現できれば、次元圧縮の効果を得ることができることから特徴抽出器として使用できる可能性がある。これを改良・拡張したものに、多層にした際の勾配消失への対策をした積層自己符号化器や、画像を対象とした積層畳み込み自己符号化器などがあるが、積層した自己符号化器では各層の事前学習で前層の出力を入力として使用するため局所解に陥る可能性があることから、事前学習において層を次第に深めていく段階的畳み込み自己符号化器が提案されている^[3]。これは、入力と出力間での誤差を損失関数とした事前学習処理により各層のパラメータを学習しておき、次の段で学習済みのパラメータに新たな層を加えたものの学習を行って層を増やしていく、最後に詳細学習で再学習を行うというものである。最終的に、ここで得られた特徴ベクトルを用いてクラスタリングを行うことで分類を可能とする。このときの特徴量の次元数やネットワーク全体の層の数、各層のノード数、




図1 段階的畳み込み自己符号化器 (SwCDAE) の構成

Validation of the classification method for honeybee image based on stepwise convolutional deep autoencoder

[†]Takuya WADA, Graduate School of Eng. Fukuoka Univ.

[‡]Shinya TAKAHASHI and Naoyuki TSURUTA, Faculty of Eng., Fukuoka Univ.

^{*}Hiroyuki AI, Faculty of Sci., Fukuoka Univ.

各事前学習および詳細学習の学習エポック数などは、最適な値を事前に決定することが難しいため、実験的に評価する。

3. 実験

ミツバチライフログモニタリングシステム^[1]で撮影した動画から切り出した画像(図2に例を示す)から、64×64のサイズで20画素ずつシフトさせて画像を切り出し、ガウシアンフィルタを用いて周辺にぼかしを入れた画像1万枚を用意し、学習用に約8000枚、検証用に約2000枚に分けて交差検証を行った。事前学習では、ノイズ付加処理、50%Dropout処理、バッチ正規化処理を行っており、中央の層のノード数すなわち特徴量の次元数は、先行研究^[3]では最初1000次元として最後の段で100次元としていたが、本稿では各段階ともに100次元に統一した。なおencoder部およびdecoder部の層の数は先行研究^[3]と同じく、それぞれ4層とした。

各層の事前学習および詳細学習を500, 1000, 2000エポックとし、その組み合わせに対して、それぞれ交差検証を行った。評価尺度は、クラスタ数を4に固定したWard法によるクラスタリングを行った際に、ミツバチとそれ以外とで正しく分類できたかを、再現率、適合率、F値として求めた。図3に、事前学習と詳細学習の回数の組み合わせに対する交差検証の結果を示す。各棒グラフはそれぞれ交差検証結果の再現率、適合率、F値の平均となっている。また上から、損失関数として平均二乗誤差(MSE)を用いた場合、SSIM^[4]を用いた場合、MSEとSSIMを組み合わせた場合(事前学習時にMSEを、詳細学習時にSSIMを損失関数としたもの)、従来手法である積層畳み込み自己符号化器(SCAE)を用いた場合となっている。F値が95%を超えたのはMSEの場合のみとなり、全体的にMSEが良い結果となった。また詳細学習よりも事前学習のエポック数を増やした方が比較的良好な値が得られている。中でも、MSE事前学習1000エポック、詳細学習500エポックでの学習結果が最良となった。

4. まとめ

本稿では、段階的畳み込み自己符号化器を用いた表現学習において特徴量次元数、学習エポック数、損失関数を変更した際の精度について検討した。結果、特徴量100次元、事前学習1000エポック、詳細学習500エポック、損失関数をMSEとした際に96.1%という精度でのミツバチの検出ができていることが示された。今後は層数を変化させた場合の性能変化を検証し、更なる高精度化を目指す予定である。

謝辞

本研究はJSPS科研費21K05624の助成を受けた。

参考文献

- [1] D. J. Anderson and P. Perona, "Toward a science of computational ethology," *Neuron*, Vol. 84, pp. 18–31, 2014.
- [2] 高橋他, "ミツバチコロニーの巣内行動観察システムの開発", *人工知能学会論文誌*, 32(4), pp. B-GC2_1–11, 2017.
- [3] 高橋他, "段階的畳み込み自己符号化器を用いたミツバチ画像分類手法の検討", *電気関係学会九州支部連合大会講演論文集*, pp. 527–528, 2019.
- [4] P. Bergmann, *et. al.*, "Improving Unsupervised Defect Segmentation by Applying Structural Similarity to Autoencoders," In *Proc. of the 14th Int. Joint Conf. VISAPP*, Vol. 5, pp. 372–380, 2019.



図2 学習に用いたミツバチ画像の例



図3 エポック数に対する交差検証の結果