

H-014

転移可能なディープニューラルネットワークに基づくゴミ分類 Transferable Deep Neural Network for Trash classification

劉学[‡] 小嶋和徳[‡] 伊藤慶明[‡]
LIU XUE KOJIMA Kazunori ITOH Yoshiaki

1. はじめに

留学生 30 万人計画の実施に伴い、来日の留学生は増加している。令和元年外国人留学生在籍状況調査結果によると、令和元年五月までの留学生数は 312,214 人に至った。日本はゴミ分別に厳しい国だが大多数の在日留学生にとってゴミ分別は難しい。そのため留学生がゴミの分別を間違えることはよくある。その場合、環境を汚染するだけでなく、資源を無駄にしている。そこで本研究では、留学生の生活を応援するために生活ゴミ分別手法を検討する。既存のゴミ分類方法があるが本研究では転移学習に基づくゴミ分類方法を検討した。本研究で転移可能なディープニューラルネットワークを使用したゴミ分類の結果について説明し、より良い結果を得るためにデータを拡張した。データのバランスが転移学習の結果に一定の影響を与えることがわかった。

2. 先行研究

Rahmi らの研究[3]では、生活ゴミ分類に使用できる一連のディープラーニングモデルを比較検討した。例えば、Densenet121, DenseNet169, InceptionResnetV2, MobileNet, Xception などである。これらのモデルを使用してゴミ分類に関する比較実験を行った。また、より良い実験結果を得るために、深層学習モデルをファインチューニングし、精度の高いモデルを構築した。これらの実験結果はわずかなデータ拡張に基づいているものである。これらのモデルはゴミ分類には効果的だが、ネットワークが深いため大容量のメモリが必要となる。

3. データ

3.1 データの収集

岩手県盛岡市に住む 30 名の留学生を対象に、家庭ごみの分別調査を行った。留学生たちはガラス製品とプラスチック製品に関するごみを間違えやすいことが分かった。盛岡地域の生活ゴミ出しルールに基づいて日常生活の中でガラス製品とプラスチック製品を対象として 4 種類ゴミがあるデータを作成した。図 1 はデータの具体的内容である。




図 1 収集したゴミ画像データの数

図 2 はゴミ画像のサンプルである。ペットボトル、ビン、資源ゴミ、不燃ゴミの 4 つの категорияが含まれている。



図 2 ゴミ画像のサンプル

3.2 データ拡張

実験データにはペットボトル、ビン、資源ゴミ、不燃ゴミの 4 つの categoriaが含まれている。実験データを均等化するために回転、水平・垂直方向に平行移動、左右反転、拡大・縮小、シアー変換、色調変更の 6 種類の拡張手法を用いて毎種類画像数を 1,500 枚程度まで拡張した。図 3 は拡張方法を用いた画像の例である。左から順に原画像、水平に平行移動、左右反転、拡大、シアー変換、色調変更である。



図 3 拡張方法を用いた画像の例

4. 検討手法

転移学習[2]とは、機械学習手法の一つで、あるタスクに対して訓練されたモデルをそれと関連したタスクに応用する手法のことである。既に学習された知識を他の課題へ転移するというイメージから知識転移とも呼ばれている。転移学習はデータ不足を解決するために特別に設計されてい

る。多くのコンピュータビジョンや自然言語処理タスクで広く使用されている。ファインチューニングは転移学習の一般的な実現方法である。先行研究では、最適化関数を使ってモデルのファインチューニングを行った。本研究では、ImageNet のデータセットをソースデータとしてニューラルネットワークモデルを事前訓練する。そして、学習済みモデルの重みの一部を凍結する方法を通じてファインチューニングされた学習済みモデルを作成したデータ(ターゲットデータ)に転移して分類タスクを行う。図 4 は転移学習の構造図である。




図 4 転移学習の構造図

本研究では、ターゲットデータは少ない、ソースデータと類似度が低いため、学習済みモデルの重みの一部を凍結する方法を通じて学習済みモデルのファインチューニングを行った。先行研究と違うデータ拡張方法を使ってターゲットデータ拡張して実験に転用した。

5. 実験

本研究では学習済み Resnet34[1]をベースモデルとして 4 種類のゴミを含むデータに分類タスクを行う。Resnet34 を選んだ理由は他の深層ネットワークと比較してパラメータが少なく、必要なメモリが少なく、モバイルデバイスへの移植が可能であるためである。実験では先行研究でのデータセット上で事前に学習された Resnet34 のパラメータを使用して、ファインチューニングを行った。また、ファインチューニングされたネットワークを用いて、データ拡張前と拡張後のデータセットに対して別々の分類タスクを実行した。より良い比較のために、事前学習パラメータのないネットワークを使用して、バランスをとる前後のデータセットで同じ実験を行った。学習回数 100 回、バッチ数 10、学習率 0.0001 を実験条件とした。図 5 は拡張されたデータセットである。




図 5 拡張されたデータセット

データ準備段階では、前述したデータ拡張方法を使ってデータ拡張を行い、入力画像サイズを 224*224 ピクセルにリサイズした。次に、9:1 の比率に従って、データセットをトレーニング部分とテスト部分に分割した。まず、ファインチューニングされたニューラルネットワークを元データセットに適用する。結果を表 1 に示す。

表 1 元データセットに基づいての結果 (TF は転移学習の略)

	epoch	batch	Test Accuracy (%)	time
With TF	100	16	0.91	0.71h
Without TF	100	16	0.78	0.70h

このように、特定データに基づいて転移学習の性能は、ベースモデルの性能をはるかに上回っている。バランスのとれた拡張データ上では、ファインチューニングされたニューラルネットワークを使用している。転移学習はバランスのとれたデータでより良いパフォーマンスを実現した。先行研究での 95%精度にわずかに及ばないが浅いネットワークの中でいい結果を得た。結果を表 2 に示す。

表 2 データバランス前後の実験結果の比較

	epoch	batch	Test Accuracy (%)	Time (H)
Imbalanced(元データ)	100	16	0.91	0.71h
Balanced(拡張されたデータ)	100	16	0.94	1.56h

6. 終わりに

本研究では、留学生が間違えやすいいくつかの種類のゴミについてデータを収集し、これらのデータをもとに転移学習を利用して自動識別の実験を行った。実験結果から、転移学習がゴミ分類に対して良い性能を持っていることが分かった。また、移行学習の方がデータのバランスをとるのに優れた性能を持っていることも分かった。今後は、間違えやすいゴミの種類を増やし、より良い分別方法を検討する。

参考文献

- [1] Kaiming, Xiangyu Zhang, Shaoqing Ren, Jian Sun "Deep Residual Learning for Image Recognition", 2016 IEEE, DOI=10.1109/CVPR (2016).
- [2] Ali Suryaperdana Ageos, Zhencheng Hu, Nobutomo Matsunaga "Fine Tuning Based SqueezeNet for Vehicle Classification", ACM, 14-18 (2017).
- [3] Rahmi Arda Aral, Seref Recep Keskin, Mahmut Kaya, Murat Haciomeroglu "Classification of TrashNet Dataset Based on Deep Learning Models", 2018 IEEE Big Data, 2058-2062 (2018).