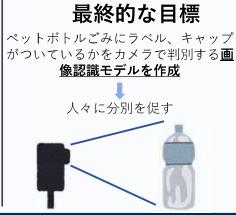


自作の画像データを用いたCNNによるペットボトルごみの識別

逗子開成高等学校 高校1年 白井千裕 鈴木翔天

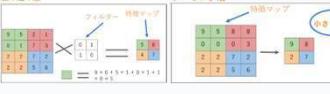


研究背景・目標



CNNとは

CNN(Convolutional Neural Network)は「畳み込みニューラルネットワーク」で主に画像認識の分野で力を發揮し、「畳み込み層」、「ブーリング層」、「全結合層」の3つの層で構成されている。



「畳み込み層」は入力データをフィルターを使い、画像から特徴の抽出を行う。抽出したものを特徴マップという。

「ブーリング層」は抽出された特徴の空間サイズを小さくする。これにより特徴マップが平行移動しても影響を受けることがないようにしたり、データ量を減らすことができる。

「全結合層」は特徴マップを結合し一次元の数値にすることで元のデータがどういう画像なのかを確率で示す。

環境開発



データ拡張

<引数一覧>

| 引数 | 説明 |
|---------------------|-------------------|
| rotation_range | ランダムに回転する回転範囲 |
| width_shift_range | ランダムに水平移動する範囲 |
| height_shift_range | ランダムに垂直移動する範囲 |
| shear_range | せん断の度合 |
| zoom_range | ランダムに縮尺する範囲 |
| channel_shift_range | ランダムにRGBを足し引きする範囲 |
| horizontal_flip | 水平方向に入力をランダムに反転 |
| vertical_flip | 垂直方向に入力をランダムに反転 |

画像認識の機械学習には大量の画像データが必要になるが、大量の画像を集めることは難しい。そのような場合、データを増やす方法として「データ拡張」がある。これは画像の水増しされるが、単にデータをコピーするのではなく、画像を反転させたり、ずらしたりして画像データを増やすのである。

データ拡張の際、TensorFlowに含まれるImageDataGeneratorという機能を使う。この機能で引数を指定することで様々な方法で画像を増やすことができる。(左の表)

本研究ではテスト用データを拡張した上で、トレーニング用データを拡張したもの、していないものを、この後の「学習及び評価」のところで学習し、比較する。

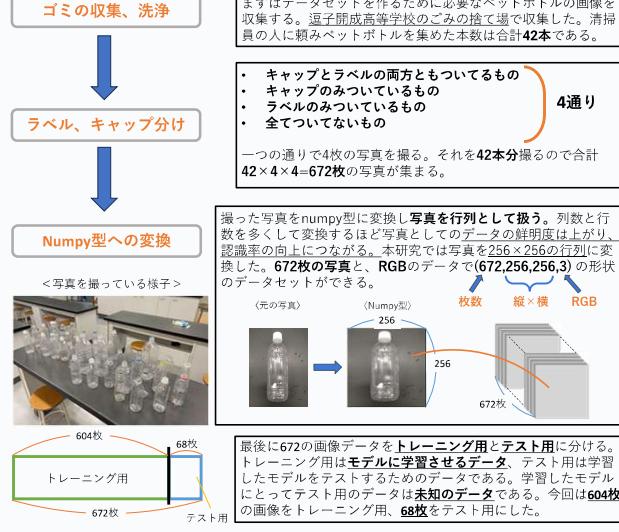
一枚の写真データを拡張した様子

(左の表の赤い線の部分は実際に使用した引数)



データセットの作成

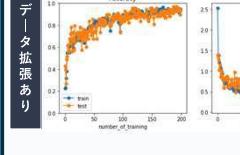
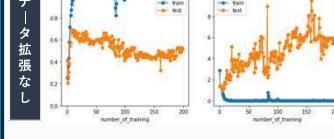
画像認識モデルには学習するためのデータセットが必要となる。一般的にデータはネットなどから収集したり、そもそも最初からデータセットが提供されていることがある。しかし、ペットボトルごみ(ラベルやキャップがない状態)の画像はあまりないため、自分たちで画像を収集し、データセットを作成する必要がある。



モデルの作成



学習及び評価



学習

左のグラフの「Accuracy」は正解率、「Loss」は誤差。 「number of training」は学習回数(エポック数)を表す。

正解率は上がるほどよく、逆に誤差は下がるほどよい。

| 拡張なし | 拡張あり |
|---|--------------|
| Accuracy トレーニング用は最初から急上昇し、その後一定。 テスト用は上昇しません。 | 共に徐々に上昇していく。 |
| Loss トレーニング用は収束。 テスト用は収束せず。 | 共に徐々に収束していく。 |

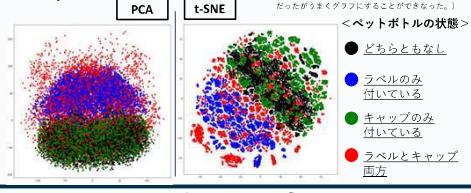
評価

評価はモデルの実際の性能を計る。ここで用いるデータは拡張されたものである。計測すると、拡張なしは45%と低いが、一方で拡張ありは97%と高い認識率である。黄色の線で示した数値が正解率を表している。



PCA, t-SNEによる分類

本研究ではCNNによる画像の識別を行ったが、ここではPCA及びt-SNEを用いて分類し、CNNと比較する。2つのグラフでは4種類のまつりはある程度できているが、かなり重なっているため、PCA及びt-SNEではCNNのような97%の精度の識別は難しいと言える。また、黒のデータは数値的に近いことがわかる。



カメラ環境への応用

カメラを用いてペットボトルをリアルタイムで判別するモデルを作成する。カメラの画像をpythonで扱うにはcv2というライブラリを用いる。

判別番号(円で囲った数字)

| | ペットボトルの状態 |
|---|-------------|
| 0 | どちらともなし |
| 1 | ラベルのみ付いている |
| 2 | キャップのみ付いている |
| 3 | ラベルとキャップ両方 |

推論

推論とはトレーニング用のデータで学習したモデルが新たなデータを推測することである。左の画像は20枚を推論した結果である。画像の下の数字は判別番号を表している。※次のスライド

モデルの推測が正しい場合
- 正しい判別番号だけ書きれる。

モデルの推測が間違っている場合
- 推測した判別番号... [正しい判別番号]

左の画像を見ると、20枚の推論ではすべて正確に認識できたことがわかる。

ここでは20枚しか推測しなかったが、データすべて(68枚)で推論を行うと間違いは一つしか見つからなかった。確率は約98%である。

推論はAIの推測という重要な指標であるため、この9割以上の正解率はAIとしては性能が少なからずあると言える。

考察

学習において、「学習及び評価」のグラフから下の表にまとめたことが言える。本研究のCNNのモデルはPCAやt-SNEによる分類よりも正確に判別することができる。データ拡張により影や少し傾いた写真にも対応できるようになった。

「PCA, t-SNEによる分類」や「カメラ環境への応用」からキャップが認識しづらい事がわかる。

カメラを用いると認識率が下がる理由として、影や背景の色、明るさなど、周囲の環境に合わせた学習を十分にすることはできず、環境に適応できなかったことが考えられる。

| 拡張なし | 拡張あり |
|--|---------------------------------|
| トレーニング 里詮なデータのみで学習するので正解率が急上昇する。 | 徐々に正解率が上昇する。 |
| テスト 未加工データで学習するので対応できず、推論したデータで学習したので未加工の複雑なデータでも対応できる。 | 未加工データで学習したので未加工の複雑なデータでも対応できる。 |
| 例えるなら 簡単な単純集のみ | 応用問題集 |

今後の展望

- より様々な(大きさや色)データを集める。
- CNNなど人工知能のアルゴリズムをさらに理解、研究し、最適なパラメータを探索する。
- カメラで社会に応用する際に影や手が映るといった、実際の環境に適応できるよう学習させる。

参考文献

自作のデータで画像認識モデルをつくって遊ぼう!
[初心者] データの階層を調べてみた
https://www.tensorflow.org/tutorials/structured_data/datasets/#load_a_local_tfrecord_file

ImageDataGeneratorを使ってみた
<https://qiita.com/okamoto/items/1485215d1225749ed0f>

機械学習のためのエンドツースタートのプラットフォーム
<https://www.tensorflow.org/tutorials/>

PCA, Kernel PCA, t-SNE, CNNによる可視化のための次元削減法の比較
https://www.tensorflow.org/tutorials/visualize_data/comparison_of_dimensionality_reduction_techniques/

nvidiaのGPUをDockerのTensorFlowで動かす
<https://www.andrewmselby.com/nvidia-gpu-docker-tutorial/>

石川 聰郎 桐林社 2018

「Pythonで動かして学ぶ!あらわしい深層学習の教科書 機械学習の基本から深層学習まで」

・「AlphaZero 深層学習・強化学習・探索・人工知能プログラミング実践入門」
・「留川英一・ボーンデジタル 2019

・「TensorFlowによる深層学習入門OpenAI Gym・PyBulletによるシミュレーション」
牧野 浩二・西崎 雄光・オーム社 2021