

ニューラルネットワークを用いた風速グラフの画像分類 Image classification of wind speed graphs using neural network

○浅香光星¹, 成登大輔², 長谷部寛³*Kousei Asaka¹, Daisuke Narto², Hiroshi Hasebe³

Abstract: In the present study, we have developed an auto extraction system based on machine learning. It can extract peculiar wind fluctuation from a large amount of wind speed graphs obtained from observation. A simple two-layer neural network was constructed to understand the characteristics of the neural network. First, we trained the neural network on pseudo wind speed graphs as training data. Then, we classified pseudo wind speed graphs generated in the same way. It could be classified perfectly. When this neural network was used to classify actually observed wind speed graphs, although the graphs were classified, reproducibility was not high.

1. はじめに

本研究では、都市の風の微細な変動特性について知ることを目的とし、日本大学理工学部駿河台校舎の7号館にて超音波風速計を設置し、特異な風環境がいかんして起こりうるのかを知るために、常時風観測を行っている^[1]。

しかし、そのデータを10分間ごとのグラフにまとめても1日144枚となり、膨大なデータを人力で処理し、分析することは困難である。

そこで、多量の風速グラフから特異な風の状態を抽出するため、機械学習に基づいて風速グラフを自動分類することを試みた。風速グラフを画像として見なし、機械学習の画像分類手法を適用した。本報告では、その第一歩として単純なニューラルネットワークに基づいた画像分類アルゴリズムを構築するとともに、実際に観測された風速のグラフの分類を試みた。

2. ニューラルネットワークについて

本研究では、プログラミング言語 Python を用いてニューラルネットワークを構築した。今回は TensorFlow Core のチュートリアル「分類問題の初歩」のコード^[2]を参考にしながらプログラムを構築した。機械学習のフレームワークには Tensorflow2 の Keras を用いた。ニューラルネットワークは、その挙動の特性を把握するため、単純な2層フィードフォワードネットワークとした。構築したニューラルネットワークのイメージを figure 1 に示す。

このネットワークの最初の層は、風速グラフ画像(320×240ピクセル)を2次元配列から、320×240=76800ピクセルの、1次元配列に変換する。

次に中間層は全結合されたニューロンの層であり、128個のノードで構成される。

最後の出力層では合計が1になる5個の確率の配列を返す。つまり5つのカテゴリーに分類される。

この3つの層は figure 2 に記したコードで設定した。コンパイルについてはオプティマイザ、損失関数メトリクスをそれぞれ figure 3 の通りに設定した。

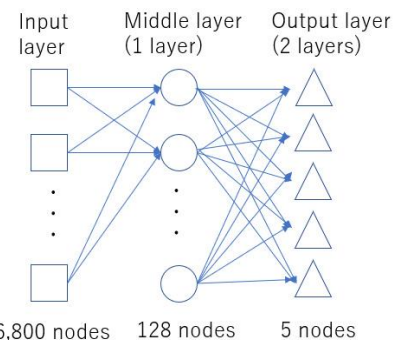


Figure 1. Overview of neural network

```
#層の設定
model = keras.Sequential([
    keras.layers.Flatten(input_shape=(320, 240)),
    keras.layers.Dense(128, activation='relu'),
    keras.layers.Dense(5, activation='softmax')
])
```

Figure 2. Neural network code

```
#モデルのコンパイル
model.compile(optimizer='adam',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
```

Figure 3. Model compilation code

3. 画像データの詳細

今回の画像分類モデルを学習させるため、用意したデータセットについて説明する。

風速の大きな変化を捉えられるように、figure 4 に示す5つのパターンのグラフを生成し、訓練データとした。なお、各パターン瞬時値が異なるグラフを生成するため、中央値は関数で与えると同時に、変

動成分を乱数で生成し、その和として瞬時値が若干異なるグラフを作成した。1 カテゴリー30枚を作成し、計150枚の画像を訓練データとした。

なおテストデータに関しては2通り用意した。1つ目のテストデータは訓練データから1 カテゴリー1枚ずつ用意し、2つ目のテストデータには figure 5 のように実際の風観測結果のグラフ画像を用意した。これらをそれぞれ「テストデータ 1」、「テストデータ 2」とした。

また訓練データにはあらかじめ正解となるラベルを与えておく必要がある。そこで figure 4 のような5つのグラフの形状のパターンに、0~4のラベル番号を与えた。




Figure 4. Generated wind speed graphs




Figure 5. Observed wind speed graph

4. グラフ判別結果と精度

先に挙げた設定で訓練データ150枚を学習させた際、30回学習するよう設定した。その結果、25回目あたりから正解率が100%に近くなっていった。

このモデルを用いてそれぞれ3回ずつ学習と分類させた結果を table 1, 2 にまとめた。

その結果、テストデータ1の場合は正しく分類され、なおかつ3回とも同じ結果となった。

テストデータ2の場合、正解率の評価と判別結果にばらつきが生じ、再現性に欠ける結果となった。

この要因は引き続き検討が必要である。

Table 1. Result of test data 1

| test data 1 | First time | Second time | Third time |
|-----------------------------------|------------|-------------|------------|
| Evaluation of correct answer rate | 0.20 | 0.20 | 0.20 |
| 1st image | 0 | 0 | 0 |
| 2nd image | 1 | 1 | 1 |
| 3rd image | 2 | 2 | 2 |
| 4th image | 3 | 3 | 3 |
| 5th image | 4 | 4 | 4 |

Table 2. Result of test data 2

| test data 2 | First time | Second time | Third time |
|-----------------------------------|------------|-------------|------------|
| Evaluation of correct answer rate | 0.20 | 0.00 | 0.60 |
| 1st image | 4 | 2 | 0 |
| 2nd image | 4 | 3 | 0 |
| 3rd image | 0 | 2 | 0 |
| 4th image | 4 | 1 | 4 |
| 5th image | 4 | 3 | 4 |

5. まとめ

本研究では都市の風の特異な変動特性を把握するため、風速グラフをニューラルネットワークを用いて自動的に分類し、特異な気象状態を自動検出できるシステムの構築を目指した。

今回は2層のニューラルネットワークを構築し疑似的なグラフの判別はできた。一方、風速グラフ判別の再現性に課題が残った。それらを改善しつつ精度を高めることが今後の課題として挙げられる。

参考文献

[1] 村上徳佳：「超音波風速計を用いた常時風観測システムの構築」, 平成26年度卒業論文

[2] TensorFlow：「はじめてのニューラルネットワーク：分類問題の初歩」

<https://www.tensorflow.org/tutorials/keras/classification?hl=ja>, (参照 2021-09-16)