

ニューラルネットワークに基づく構造化データの分類

Classification of structured data based on neural network

発表者： LUO ZIJIE

指導教員：坪井 一洋

1 はじめに

近年、ニューラルネットワークは急速に発展している。ニューラルネットワークの発展は、主に次の三つの点に起因している。

- ・ビッグデータ時代の膨大なデータ量
- ・ハードウェア性能の向上
- ・新たなアルゴリズム

現在、画像認識、音声分類、自然言語処理などの分野では、ニューラルネットワークは他の機械学習の手法より優れていると示されているが、これらの研究分野ではいわゆる「非構造化データ」を使用している。

同時に、ニューラルネットワークでデータの分類問題やデータの予測を高精度にできるように、現在多くの研究を進められている。これがいわゆる「構造化データ」の機械学習問題である。

こうした背景からニューラルネットワークモデルとビッグデータを、さまざまな分野で結合させることで社会的に有益な情報を得ることが期待される。

本研究では日本の国民的スポーツであるベースボールへの機械学習の応用を考えた。構造化データである投球データを用いてベースボールの球種を判断するニューラルネットワークシステムを Python によって実現することを試みた。

2 ニューラルネットワークモデル

この実験で用いるニューラルネットワークを図 1 に示す。ニューラルネットワークは多数のパーセプトロンで構成され、入力 X から出力が得られる。層と層の接続は重み ω とパラメータ b である。 ω は層と層の間で、ニューロン同士のつながりの強さを示す。

活性化関数 σ は行列演算に非線形性を導入するために追加された関数である。一般的に 4 種類の関数を使用されるが今回の実験では ReLU 関数を使う。たとえば、 ω_{jk}^l を第 $(l-1)$ 層の第 k 番目のニューロンから第 l 層の第 j 番目のニューロンへの重みとし、 b_j^l を第 l 層の第 j 番目のバイアス、 a_j^l は第 l 層の第 j 番目のニューロンの出力とする。 a_k^0 の時には入力層 X である。このとき出力 a_j^l は以下のように書ける。

$$a_j^l = \sigma \left(\sum_k \omega_{jk}^l a_k^{l-1} + b_j^l \right) \quad (1)$$





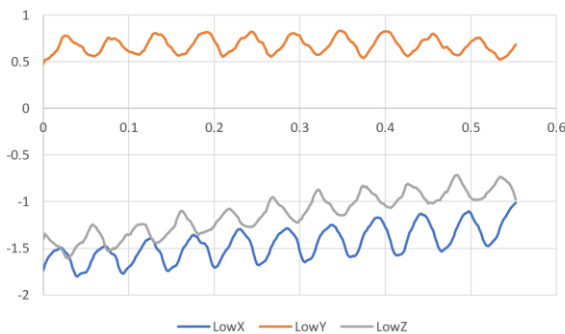
図 1 ニューラルネットワークの概要

3 加速度データの処理

今回使用するベースボールデータはボールに内蔵した加速度センサにより得られた時系列データである [1]。センサからは x, y, z の 3 軸方向の成分が出力される。全部で 22 ケースの投球データがある。センサからの出力波形の 1 例を図 2 に示す。同図 (a) はストレート球、(b) が非ストレート球 (カーブ) の出力例である。加速度のサンプリング間隔は 0.01 秒である。



(a) ストレート



(b) カーブ

図 2 加速度センサの出力例

ニューラルネットワークモデルは処理するデータのサイズを同じにする必要がある。加速度の時系列データのうちで最も短いデータは 0.47 秒までの 47 時刻分である。そこですべての加速度データに対して 0.47 秒までのデータを使用することにした。このとき、 x, y, z 軸の成分それぞれ 47 個のデータをもつので特徴量は全部で 141 (=47x3) である。

4 実験結果

実験は 2 回行なった。第 1 回の実験では 18 ケースの投球データを使う。ランダムに 14 ケースの加速度データをトレーニングデータとして、ニューラルネットワークモデルで学習させた。残りのストレート球と非ストレート球の各 2 ケースの加速度データをテストデータとして検証した。

その結果を図 3 に示すが、トレーニングデータとテストデータの正確率はともに 100% であった。

```

トレーニングの正確率
1.0
テストの正確率
1.0

```

図3 第1回実験の結果

第2回の実験ではこの18ケースのデータをトレーニングデータとして、ニューラルネットワークモデルで学習させた。そして、新たな4ケースのデータをテストデータとして、ニューラルネットワークモデルで球種を判別した。

その結果は図4に示す通り、トレーニングの正確率は100%であり、テストデータの正確率は50%であった。そして、ここで不正解となったデータは2ケースとも非ストレート球データであった。

このことからこの2ケースの非ストレート球データは実際にはストレート球であった可能性が予想できる。

```

Iteration 107, loss = 0.00622000
Iteration 109, loss = 0.00627451
Iteration 110, loss = 0.00623354
Iteration 111, loss = 0.00628694
Training loss did not improve more than tol=0.000100 for 10 consecutive epochs. Stopping.
トレーニングの正確率
1.0
テストの正確率
0.5

```


図4 第2回実験の結果

5 主成分分析(PCA)


今回使用した加速度データの特徴量は141であるため、直接可視化するのは難しい。そこでPCA法を使用し、141次元空間を3次元空間に変換し、可視化する[2][3]。そのため、PythonのSklearnというライブラリを使い、PCA法によって141次元から3次元に変換した。

その結果は141次元空間から3つの有用な情報を抜き出したものになっている。可視化した結果を図5に示す。紫色はストレート、緑色は非ストレートである。第2回実験でのニューラルネットワークモデルが判別を間違った2ケースの非ストレート球データはともに図5では赤の円内に表示している。この結果から、これらのデータはストレート球のグループの周辺にあることがわかった。


今回の結果に対しては2つの考え方ができる。1つは新たに使用した4ケースのデータがトレーニングデータの領域外にある可能性である。もう1つは新しい4ケースのデータのうち非ストレート球とラベルされたデータが実際にはストレート球であった可能性である。



(a) x,y軸の結果



(b) x,z軸の結果



(c) y,z軸の結果

図5 PCAの可視化結果

6 まとめ

本研究ではニューラルネットワークモデルを使って、野球の投球における球種を判別するシステムの開発を試みた。ボールが飛翔している状態で計測した加速度の時系列データから球種分類を行った。

ストレート球と非ストレート球の全18ケースの加速度データをニューラルネットワークモデルで学習させた結果、トレーニングデータとテストデータの正確率はともに100%となった。

次に、この18ケースのデータをトレーニングデータとして学習させ、これらに含まれない新しい加速度データ4ケース(ストレート球と非ストレート球各2ケース)をテストデータとして使ったところ、テストデータの正確率は50%となった。そして、誤ったデータはともに非ストレート球であった。

主成分分析(PCA)の次元削減による結果を視覚化することで、この新しい4ケースのデータのうち非ストレート球のデータはストレート球のグループの周辺にあることがわかった。

今後の課題としては、加速度の出力データ数を増やすことと今回用いた二つの非ストレート球にラベルされたデータの検証である。

参考文献

- [1] 長岡:『加速度センサを内蔵したボールの回転特性の実験的検証』, 茨城大学機械システム工学専攻修士論文, (2018)
- [2] Jonathon Shlens: "A Tutorial on Principal Component Analysis", arXiv:1404.1100, 2014
- [3] XiaoyuZhu, Hefeng Dong, Pierluigi Salvo Rossi, Martin Landrø: "Feature Selection based on Principal Component Analysis for Underwater Source Localization by Deep Learning", arXiv:2011.12754, 2020