

BCI の実用化に向けた高次元時系列データ解析

日大生産工 ○中山 佳奈 日大生産工 綱島 均
日大生産工 柳沢 一機 日大生産工 山内 ゆかり

1 まえがき

Brain Computer Interface(BCI)とは、脳信号を読み取ることによって、考えるだけで機械を動かすインターフェイスである。医療方面での応用が期待されており、BCIの実用化にはタスク判別と高い認識率が必要である。

木野らは、自己組織化マップ(Self-Organizing Map: SOM)を時系列処理ができるように拡張したリカレント自己組織化マップ(Recurrent Self-Organizing Map: RSOM)[1]を用いて認識率を向上したが、実用化に至るほどの認識率は得られなかった。

宍戸らは、追加学習可能なオンライン教師なし学習手法である自己増殖型ニューラルネットワーク(Self-Organizing Incremental Neural Network: SOINN)[2]に過去の状態を考慮する Recurrent 層を追加した Recurrent-SOINN[3]を提案した。Recurrent 構造による時系列データへの対応を取り入れたが、認識率の向上は見られなかった。

そこで、本研究では SOINN の学習法にオンライン学習を取り入れることで認識率の向上を目指す。

2 従来研究

SOINNは追加学習可能なオンライン教師なし学習手法である。

図1にSOINNのアルゴリズム[4]を示す。

宍戸らはSOINNが時系列データに対応できるように拡張したRecurrent-SOINNを提案した。Recurrent-SOINNは、上述のSOINNのアルゴリズムの勝者決めの手法をRSOMを参考にして、置き換えたものである。

SOINNでは式(1)、式(2)を用いて勝者を決めている。

$$c_1 = \arg\min_i |x(t) - m_i(t)| \quad (1)$$

$$c_2 = \arg\min_i |x(t) - m_i(t)| \quad i \neq c_1 \quad (2)$$




図1. SOINNアルゴリズム

一方、Recurrent-SOINNでは、式(1)、式(2)の代わりに式(3)、式(4)、式(5)と置き換えて勝者を決めている。このように式を置き換えることで時系列データに適した学習を可能にした。

$$y_i(t) = \beta_1 y_i(t-1) + \beta_2 y_i(t-2) + \beta_0 [x(t) - m_i(t)] \quad (3)$$

$$c_1 = \arg\min_i |y_i(t)| \quad (4)$$

$$c_2 = \arg\min_i |y_i(t)| \quad i \neq c_1 \quad (5)$$

3 提案手法

An Analysis of High-Dimensional Temporal Data for Practical BCI

Kana NAKAYAMA, Hitoshi TSUNASHIMA, Kazuki YANAGISAWA and Yukari YAMAUCHI

Recurrent-SOINN は、認識に使うデータは認識にのみ使う静的な学習だが、データに整合性が無いと認識率が低下する。

本研究では、SOINN にオンライン学習を取り入れ、データを追加学習しながら認識していくことで、認識率の向上を目指す。

4 実験環境

本実験で使用する脳信号データは、BCIを使用して測定したものである。ここでのタスクはグラッピングであり、1試行を前レスト10秒、タスクを30秒、後レスト10秒とし、これを5試行繰り返すことで得ている。

実験環境は以下の通りである。

agemaxとは事前閾値であり、エッジの年齢がこの数を超えたとき古いエッジを削除する。リカレント係数とは過去の学習情報をどれだけ加えるかを決めている係数であり、0から1までの定数である。

- ・学習データ数：586
- ・認識データ数：586
- ・チャンネル数：42
- ・学習回数：586
- ・リカレント係数： $\beta_1 = 0.6, \beta_2 = 0.3, \beta_0 = 0.1$
- ・agemax：73(=データ数/8)
- ・ノード更新周期 λ ：293(=データ数/2)

5 実験結果

図2は元データ、図3がSOINN、図4がRecurrent-SOINNによる競合層の状態を示している。赤で示されているノードはタスク状態、緑で示されているノードはレスト状態を表している。

SOINNは多くのノードを認識しているが、タスクに関してはRecurrent-SOINNのほうが正しく判別されている。このことから、認識率はSOINNの方が高く、タスク判定はRecurrent-SOINNの方が優れていると考えられる。




図2. 元データ




図3. SOINN結果




図4. Recurrent-SOINN結果

6 まとめ

本研究では、SOINNにオンライン学習を取り入れ、認識データを追加学習しながらデータを認識していくことで認識率を向上する手法を提案した。

今後は、認識率を数値で確認できるようプログラムを改良し、認識率が向上しているか確認する。SOINNはパラメータ依存であるため、パラメータの最適化も課題の1つである。

7 参考文献

- [1] 木野裕麻, 山内ゆかり, Recurrent Self-Organizing Mapによる脳信号解析, 電子情報通信学会技術研究報告, NC, ニューロコンピューティング 112-480(2013-3)
- [2] SOINN: Self-Organizing Incremental Neural Network | Hasegawa Lab, Imaging Science and Engineering Laboratory, Tokyo Institute of Technology <http://www.haselab.info/soinn.html> (最終アクセス日時 2015年10月19日14:38)
- [3] 穴戸勇斗, 山内ゆかり, Recurrent SOINNによる脳信号のタスク認識, 第5回 NU-Brainシンポジウム
- [4] 山崎和博, 巻渕有哉, 申富饒, 長谷川修, 自己増殖型ニューラルネットワークSOINNとその実践, 日本神経回路学会誌, Vol.17, No.4(2010), pp187-196