

リカレント自己組織化マップを用いた Brain Computer Interface における脳信号解析

日大生産工 ○木野 裕麻 日大生産工 山内 ゆかり

1 まえがき

Brain Computer Interface (BCI)とは、使用者の身体を傷つけずに、人間が考える時の脳波を測定し、脳の思考情報を入力とし機械を制御するシステムで、身体障害者の生活支援、片麻痺患者を対象としたリハビリテーションなど医療分野への応用が注目されている。本研究では、頭皮上から非侵襲的に脳機能をマッピングする近赤外光(NIRS: Near infrared spectroscopy)を用いるBCIに着目した。NIRSは、体動制限が少なく、電氣的ノイズに強いため使用者への負担が少なく、電子機器からの影響も少ないからである。

NIRSを用いた研究として、柳沢らによる離散ウェーブレット変換による多重解像度解析及び、NIRS信号の微分値を用いた脳活動レベルの判別方法がある。この方法では、精度の高い判別ができ、想起課題での識別も可能だが、複数のチャンネルやタスク別の判定に対応することが難しくなってしまう[1]。

複数のチャンネルやタスク別の判定を可能にするため、ニューラルネットワークが用いられている。ニューラルネットワークは、時系列解析が可能で高い認識率を持つとしてBCIに使われることが多い[2][3][4]。ニューラルネットワークを使用することで、複数のチャンネルやタスク別の判定が可能になったが、タスク判断及び認識率は、実用化できるほど高くはない。

Recurrent-SOM (RSOM)は、自己組織化マップ(SOM: Self-Organizing-Map)を、時系列処理が可能となるように拡張したものである。早坂らが行った研究では、RSOMを用いた脳磁解析で高い認識率が得られている [5]。

そこで本研究は、RSOMを用いてNIRSデータのタスク別判断や認識率の向上をめざす。

2 RSOMの原理

SOMは、Kohonenによって提案されたニューラルネットワークの競合学習型モデルである[5]。また、多次元データの特徴ごとに二次元データに射影することができる為、多次元データの可視化に主に用いられる。SOMは入力層と競合層の2層で構成されている。以下にSOMのアルゴリズムを示す。

1. 全ての参照ベクトル m_i をランダムに決定
2. 入力ベクトル $x(t)$ を与える

3. $m(t)$ と参照ベクトルとのユークリッド距離を求め、最小となる参照ベクトル m_c を探す

$$|x - m_c| = \min |x - m_i| \quad i=1,2,\dots,M \quad (1)$$
4. 参照ベクトル m_c を持つニューロンを勝者ユニットにする
5. 勝者ユニット、近傍関数 h_{ci} を用いて近傍範囲内ある参照ベクトルを式2で更新する

$$m_i(t+1) = m_i(t) + h_{ci}(t)m_i[x(t) - m_i(t)] \quad (2)$$
6. 2~5を学習回数分繰り返す。

自己組織化を行うと学習後には、同じ特徴を持つ者同士でクラスタを形成する。

RSOMは、時系列信号のクラスタリングを可能にするようにSOMを拡張したものでMarkusらによって提案されたものである[6]。RSOMは、過去の入力ベクトルの情報をフィードバックすることで時系列信号のクラスタリングを可能にしている。図2にRSOMの概念図を記す。

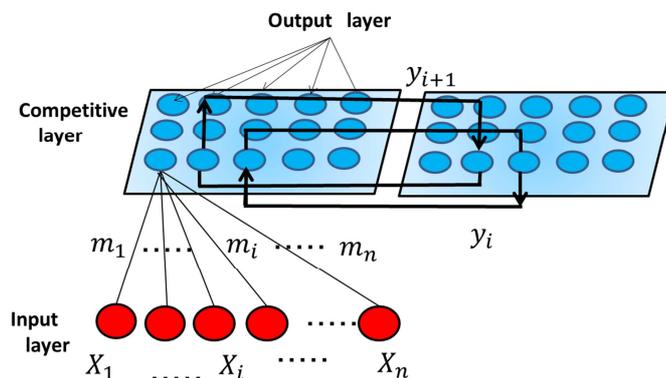


図2: RSOMの概念図

勝者ユニットは入力ベクトルと競合層のユニットの重み m_i との距離が近いものとし、式3に示す。

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

$\beta_0 \sim \beta_2$ は、リカレント係数を示している。勝者ユニットと近傍内にある参照ベクトルを式4で更新する。

$$m_i(t+1) = m_i(t) + \alpha(t) h_{ci}(t) y_i(t) \quad (4)$$

3 実験方法

本研究では、NIRSを用いて測定された実験参加者5人のグラッピング課題でのデータで信号分類を試みた。タスク[0]=休憩、タスク[1]=右手を握る、タスク[2]=左手を握る である。

また、本研究では個々のデータの前半を学習に使用し、後半を分類（認識）テストに用いた。実験の環境は下記の通りである。

- ・学習回数：10万回
- ・学習係数：0.5
- ・ノード数：16×16 = 256
- ・次元数：それぞれのデータのチャンネル数分
- ・リカレント係数： $\beta_0 = 0.7$ $\beta_1 = 0.3$ $\beta_2 = 0.2$

4 実験結果

NIRSのデータを入力ベクトルとし、SOMおよびRSOMで実験を行った。図3に最も良い認識率が得られた場合のRSOMの実験画面を示す。

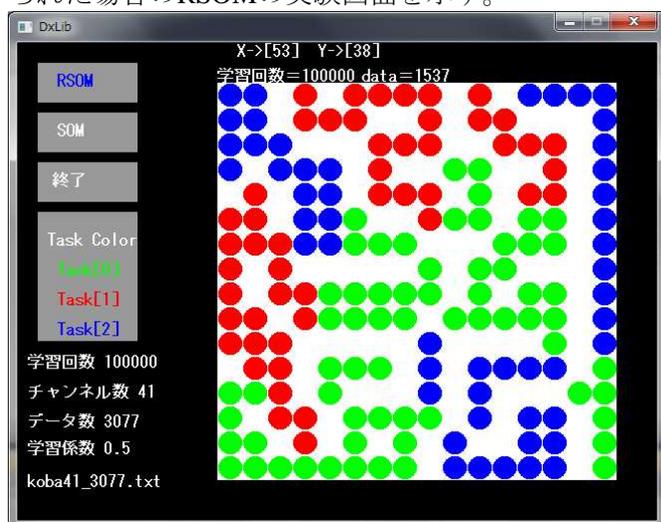


図3：RSOM実験画面

競合層をタスクの色で分類し、白は未分類とする。図3よりタスク毎にクラスタが形成され、領域分割がされていることが解る。下記に後半のデータの分類及び認識の判断基準を示す。

1. 勝者ベクトルのタスクと入力ベクトルのタスクが一致した場合、正しい認識と判断する
2. 勝者ベクトルのタスクと入力ベクトルのタスクが一致しない場合、誤認識と判断する
3. 勝者ベクトルのタスクが未分類の場合
 - A) 勝者ベクトルの上下左右で一番多いタスクと一致すれば正しく認識されたとする
 - B) 勝者ベクトルの上下左右で一番多いタスクと不一致の場合誤認識とする

実験協力者をアルファベットで表し、各10回行った際の認識率の平均をAve、最小値をMin、最大値をMaxとする。表1にSOMの認識率の平均、認識率の最小値と最大値を示す。表2には、RSOMでの認識率の平均、認識率の最小と最大を示す。

表1：SOMの認識率

	A	B	C	D	E	Ave
Ave	0.653	0.758	0.711	0.724	0.644	0.698
Min	0.626	0.667	0.666	0.687	0.610	0.651
Max	0.666	0.794	0.743	0.760	0.671	0.726

表2：RSOMの認識率

	A	B	C	D	E	Ave
Ave	0.661	0.780	0.711	0.718	0.675	0.709
Min	0.622	0.745	0.692	0.687	0.652	0.679
Max	0.687	0.806	0.770	0.747	0.695	0.741

表1と表2を比べると、RSOMで分類した方が、認識率が約1%上昇していることがわかる。また、認識率の最大値は約2%上昇した。

5 まとめ

本研究はリカレント自己組織化マップ(RSOM)を用いNIRSでの信号解析を行った。その結果、SOMで解析を行うよりも、認識率の向上が見られた。しかし、SOMに比べて認識率、タスク分類の性能は高いものの、BCIを実用化出来るほどの数値に足しておらず、改善する必要がある。

今後の課題として、アーチファクト運動によるノイズの除去や、ニューロフィードバックにより訓練された実験協力者のデータを用いて、RSOMでの認識率の向上を試みたいと考えている。

「参考文献」

- [1] 柳沢一機, 綱島均, 丸茂喜高, 広瀬悟, 清水俊行, 泰羅雅登, 土師知己, 機能的近赤外分光装置 (fNIRS) を用いた高次脳機能計測とその評価, ヒューマンインタフェース学会論文誌, Vol11 No.2, 2009, pp183~191
- [2] 斉藤宏哉, 中山謙二, 平野晃宏, NNを用いたBCIにおける自己組織化マップによる多チャンネル脳波の特徴抽出法の検討, 信号処理シンポジウム, 2010
- [3] 綿貫奨, 山内ゆかり, ブレインコンピュータインターフェース(BCI)に向けた脳信号解析, 第44回日本大学生産工学部学術講演会, 2011
- [4] Teuvo.Kohonen, (徳高平蔵 訳), 自己組織化マップ 改訂版, シュブリュガー・フェアラーク東京, 2005
- [5] 早坂侑一郎, 安達雅春, リカレントSOMと独立成分分析を用いた脳磁界解析, 電子情報通信学会技術研究報告, NLP, 非線形問題 107(400), pp41-46, 2007
- [6] Markus V arsta, Jukk Heikkonen, and Jose' del Ruiz Milla'n, A recurrent self-organizing map for temporal sequence process-ing, (In Proceedings of the ICNN'97), October 1997. ISBN3-540-63631-5