

Recurrent-SOINN を用いた BCI における脳信号解析

日大生産工 ○宍戸 勇斗 日大生産工 山内 ゆかり

1 まえがき

Brain Computer Interface(BCI)とは、脳信号を測定して機械を制御するシステムのこと、主に医療関係で注目をされている。近年脳信号の測定には、体動制限が少なく、多次元で即応性のある信号が得られるNIRS (Near infrared spectroscopy)が多く用いられている。

脳信号の解析は、2状態の判別であればサポートベクターマシンが有効であるとされているが、複数の状態や複雑なタスクの判定にはニューラルネットワークのアルゴリズムが用いられている。Markusらが提案したRecurrent Self-Organizing Map: RSOM[1]はリカレント構造により、時系列データの解析に優れていることが知られている。木野らはRSOMによる脳信号解析が従来のSOMに比べ高い認識率が得られることを確認した[2]。しかし、脳信号のデータは再現性が低く、実用に向けて更なる認識手法の改善が求められている。

自己増殖型ニューラルネットワーク (Self-Organizing Incremental Neural Network: SOINN) は山崎らによって提案されたクラスタリング手法で、ネットワークの構造を事前に決定することなく、高いノイズ耐性とクラスタリング性能を持つとされている[3]。脳信号は動的に変動し、ノイズも多い為、SOINNによる解析が有効であると考えられる。

本研究では、自己増殖型ニューラルネットワークにRecurrent構造を付加し、時系列データに適した処理が行えるように拡張したRecurrent-SOINNを提案し、これを用いて脳信号解析を行うことで認識率の向上を試みる。

2 従来研究

2-1 RSOMによる脳信号解析

木野らはMarkusらが提案したRSOM[1]を脳信号解析に用いることにより、従来の通常SOMに比べ、全体的に認識率の向上を確認することができた。これにより、Recurrent構造は脳信号の時系列データの解析に適していると考えられる。

2-2 自己増殖型ニューラルネットワーク SOINNのアルゴリズムを図2に示す。




図2.SOINNのアルゴリズム

3 提案手法

本研究では、図2で示したアルゴリズムに時系列データに適したRecurrent構造を取り入れたRecurrent-SOINNを提案する。

時系列データからSOINNに与える入力ベクトルを構成する際に、規準となる時刻 t と、その1時刻前 ($t-1$) のデータ、2時刻前 ($t-2$) のデータを一定の割合で複合的に考慮する。具体的には式(1)を用いて入力ベクトル x_t を決定する。

$$x_t = \beta_1 x_{(t)} + \beta_2 x_{(t-1)} + \beta_3 x_{(t-2)} \quad (1)$$

ここで、 $\beta_1 \sim \beta_3$ はリカレント係数である。

4 実験環境

実験に使うデータは、日本大学生産工学部機械工学科綱島研究室で、2012年6月1日から2013年5月10日の期間に実験協力者21人に対して実施したNIRSによる脳信号測定実験で測定された実データを用いる。

快・不快画像を見せ、脳信号を測定し、学習することにより、未知の測定データから、快画

像を見ているのか、不快画像を見ているのかを認識したい。

測定データは脳内のヘモグロビン(Hb)の増減や酸素交換情報(oxy-Hb:酸素化Hb)で脳信号を測定している。

本研究では測定値をRecurrent-SOINNを用いて実験をする。Recurrent-SOINNで学習ステージのデータを使い学習をして、識別ステージのデータを使い認識実験を行った。またrecurrentアルゴリズムによる性能向上が見られるかを確認するため同じ環境下のSOINNでの学習、認識実験結果と比較した。

実験の環境は以下の通りである。

- ・データ数：586
- ・次元数：脳信号データのチャンネル数
- ・学習回数：データ数×20
- ・ λ ：データ数/2
- ・agemax：25,50,75
- ・リカレント係数： $\beta_1=0.6$, $\beta_2=0.3$, $\beta_3=0.1$

SOINNの特性上、 λ とagemaxの2つのパラメータに学習性能が依存している。本実験ではagemaxは3通りで実験を行った。

5 実験結果及び検討

Recurrent-SOINNとSOINNの学習・認識実験結果のagemax別の20回平均を表1に示す。

表1.実験結果 (agemax別)

25					
SOINN			Recurrent-SOINN		
平均	最大	最少	平均	最大	最少
55.66	66.76	44.1	54.79	64.43	44.13
50					
SOINN			Recurrent-SOINN		
平均	最大	最少	平均	最大	最少
55.42	68.37	43.34	55.01	65.89	41.09
75					
SOINN			Recurrent-SOINN		
平均	最大	最少	平均	最大	最少
58.03	67.96	41.78	55.37	67.54	41.7

agemaxが75で全体的に認識率が高くなっている。また、Recurrent-SOINNとSOINNの認識率を比べると全体的に1%～2%ほど下がっている。

表2には認識率が一番高かった、agemaxが75の実験協力者毎の20回平均、最大、最少を示している。

認識率が個人によりばらつきがあるのは学習ステージと識別ステージで人により大きく差が出てしまうためだと考えられる。

表2. 実験結果 (実験協力者別)

実験協力者	SOINN			Recurrent-SOINN		
	平均	最大	最少	平均	最大	最少
A	70.73	82.08	50	69.79	82.42	57
B	50.44	60.92	36.18	46.6	51.71	35.84
C	51.23	70.65	31.74	47.06	70.99	31.91
D	69.54	78.5	55.8	67.45	78.5	52.22
E	40.02	61.43	20.99	36.85	59.39	23.38
F	90.34	97.95	54.95	88.63	95.22	65.36
G	63.41	71.5	32.76	62.22	69.45	55.97
H	46.72	56.66	37.88	43.51	63.48	19.28
I	54.54	65.53	38.91	50.21	65.7	35.67
J	64.59	69.62	40.1	62.88	69.97	54.44
K	50.16	69.28	41.64	46.02	62.46	34.47
L	77.03	82.42	64.33	73.31	84.47	55.29
M	62.72	73.38	41.81	59.42	75.43	41.3
N	55.59	60.58	45.22	54.07	68.09	44.2
O	39.29	46.08	33.45	37.9	47.1	32.76
P	50.23	58.36	31.4	51.06	65.53	42.49
Q	37.34	61.77	29.35	35.14	50.51	18.26
R	66.77	76.79	50.34	65.27	76.62	40.61
S	59.8	62.46	50.34	55.96	62.12	50.34
T	66.85	66.21	51.19	62.24	65.53	48.81
U	51.27	54.95	39.08	47.22	53.58	36.01
平均	58.03	67.96	41.78	55.37	67.54	41.7

実験結果から今回はrecurrentアルゴリズムの優位性を示すことはできなかった。

6 まとめ

本研究では、SOINNにrecurrentのアルゴリズムを加えたRecurrent-SOINNを提案し、学習・認識実験及びSOINNとの比較を行うことによりrecurrentアルゴリズムの有効性を検討した。実験結果から、recurrent構造を用いることによる認識率の上昇が見られなかった。

本研究では、入力ベクトルに過去のデータを加味することで、リカレント概念を取り入れているが、1時刻まえのSOINN空間の出力を入力ベクトルに加味する方が、より累積した情報を扱える。それらの改善を行うことで認識率の向上につながると考えられる。

「参考文献」

- [1] Markus Varsta, Jukka Heikkonen, and José del R. Millán, A recurrent self-organizing map for temporal sequence processing, (In Proceedings of the ICNN'97), October 1997, ISBN3-540-63631-5
- [2] 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] 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 .The Brain & neural networks 17-4(2010)