

脳波データを用いた精神状態の推定および分類について

森田 尚亨、柳瀬 香南

On the Estimation and Classification of Human Mental States using the EEG Data

Naoyuki MORITA, Kana YANASE

Abstract

We present a method to realize the goal of estimating and classifying human mental states by applying the self-organizing (feature) map : SOM to the data which uses the alpha wave and beta wave component of EEG. The data are constructed by two quantities which reflect the difference of brain activation and the level of brain activity.

We performed a preliminary experiment in which five different mental states were estimated to examine the usefulness of this technique we present.

As a result, SOM properly classified the state of brain activities originating in the difference in human mental states. It is also suggested that when we know which unit on the map the given EEG data belonged to, it is possible that we could estimate in what mental state we got the data.

1. はじめに

以前、我々は「在学生の脳と心を調べる」という拙稿の中で、発見科学と脳波という視点から、デジタル脳波計を用いて在学生の精神状態を調べる試みを紹介した¹⁾。その後、衛生技術科在学生の協力により preliminary な実験を行い、いくつかの精神状態における脳波データを収集してきた。また、脳波波形の α 波成分 (8 ~ 13Hz) および β 波成分 (14 ~ 30Hz) に注目し、脳の活動状態の違いおよび活動レベルの違いをそれぞれ反映している 2 つの量を新たに導入した。そして、これら 2 つの量を用いて表された脳波データに自己組織化マップというクラスタリングアルゴリズムを適用することで、脳波データから精神状態の分類および推定を試みてきた。本稿では、我々が現在得ている知見などを提示する。以下、2 章では脳波と精神状態の関係について、3 章では脳波データについて、4 章では我々が行った脳波データの処理方法について、5 章では我々が行った実験について述べ、6 章以下、実験結果、考察、そしてまとめと続く。

2. 脳波と精神状態の関係

脳は、脳神経細胞が電気的活動を行うことによって感覚の知覚・判断、運動・制御などさまざまなことを行っている²⁾。いわゆる脳波 brain wave とは、この電気的活動の時間変化を巨視的(大

脳皮質のかなりの範囲から発生する電気的活動を距離的に離れた位置から総体的に見ていると言う意味で)に捉えたものである³⁾。通常、脳波を扱う場合には、これら電気的活動の時間的変化を頭皮上の電位変化として捉えた時系列波形、すなわち EEG ; electroencephalogram を脳波として利用している⁴⁾。また国際脳波学会によって、脳波は周波数帯域ごとに、以下のように分類および名称が定められている。① δ 波：0.5～3 Hz、② θ 波：4～7 Hz、③ α 波：8～13Hz、④ β 波：14～30Hz、⑤ γ 波：30Hz以上⁴⁾。

臨床医学分野における EEG の有用性は古くから知られており、臨床脳波では正常脳波と異常脳波の鑑別および病態診断、また睡眠脳波による睡眠障害の診断などが脳波検査として、日常広く行われている。一方、人間工学分野においても安静度、ストレス度または快適性の推定、さらには脳波によるマン・マシンインターフェースなど、さまざまな分野に EEG は利用されている⁵⁻¹³⁾。なお、「人間工学」と「脳波」をキーワードに Yahoo のネット検索を行うと、キーワードに一致する 58200 件ものホームページが存在することがわかった。このように、人間工学と脳波の関わりは決して薄くない。現在、我々が取り組んでいる試みも人間工学分野に関連があるものである。

人間工学では、ヒトの①リラックスの程度、②緊張度、ストレス、③快／不快、④集中度、⑤眠気、⑥睡眠の程度と質、などを知ることが目的としている¹⁴⁾。そして脳波は α 波や β 波さらには θ 波の出現状況によって、安静度、ストレス、そして快適性などの判定に最もよく使われている¹⁴⁾。具体的には、以下のようである¹⁴⁾。リラックスの程度(①)を知るためには α 波を指標に評価する。緊張度、ストレス(②)を知るためには β/α (または α/β)を指標にする。快／不快(③)を知るためには①と②の相対差によって推測する。集中度(④)を知るためには α 波の増減、および正中前頭部付近から出現する Fm θ 波を指標にする。眠気(⑤)を知るためには α 波および θ 波の出現率を指標にする。また、注意しなければならない重要事項としては、我々が人間工学分野において対象としている脳波は正常脳波であるということ、そして、それは背景脳波と言われる「定常的脳波」であり、その波形に現れるのは大脳皮質の神経細胞網における情報処理過程の「定常的程度」であって、思考の過程やその内容が反映されているわけではない¹⁴⁾ということがある。つまり、背景脳波でわかる基本的なことは脳の活動の活発性の程度である。

成人の正常脳波について、以下に概略する^{4,14)}。正常脳波は、主に α 波と β 波から構成され、 θ 波は少量散在するのみであり、明らかな θ 波や δ 波は存在しない。特に δ 波はない。 α 波は、安静・閉眼・覚醒時に、後頭～頭頂部で優位に出現する。また漸増漸減 waxing and waning 現象があり、ほぼ左右脳半球で対称的に出現する。 α 波は、開眼や知覚刺激、精神活動など、脳が働く状況で抑制または消失する。 β 波は α 波と共に出現するが、通常 α 波に比べて振幅が小さく、 α 波の振幅によって目立たない存在となっている。また β 波も α 波同様、脳が活性化すると減少するが、その程度が α 波に比べて遙かに少ないため、結果として残存しているように見える。つまり、 β 波とは開眼や精神活動、緊張、ストレスなどで α 波が抑制された際に、 α 波よりも減衰の程度が少ないために残存して見える波形である。このため、見かけ上、 α 波が消失して β 波が出現したように見える。しかし、 α 波に替わって出現するわけではない。すなわち、脳の活動レベルが高くない場合には α 波および β 波の振幅は大きい、 α 波の振幅が β 波のそれよりも大きいので、 α 波が目立って出現している脳波となる。一方、活動レベルが高いほど2つの波の振幅は小さくなり、すなわち脳波の振幅は小さくなり、 α 波は抑制または消失し、 β 波が見えてくるようになる。また、Fm θ 波は前頭中心部に優位に出る1秒以上持続する θ 波であり、精神的に集中して作業しているときに出現する。その作業にある程度なれた人や、その人にとって適度な集中度が要求される作業で出やすい傾向がある。

3. 脳波データ

一般的な脳波収集では、国際脳波学会連合標準電極配置法 ten-twenty electrode system (図 1) によって頭皮に配置された電極によって EEG を収集している。また正常脳波の場合、通常 EEG の波形は個人差が大きく、すなわち α 波の大きく出る人とそうでない人の差が大きく、その波形のみを見て精神状態を直接推定することは難しい。このため、人間工学分野では、頭皮に装着された各電極から収集される EEG の波形を高速フーリエ変換して得られる α 波成分、 β 波成分など周波数成分 (パワースペクトル) の二次元的な分布を色分け表示する、 EEG トポグラフィと言われるマッピングの手法がしばしば使われる (図 2) 。




図 1 ten-twenty electrode system の原理 (臨床脳波学第 5 版 : 医学書院より引用)

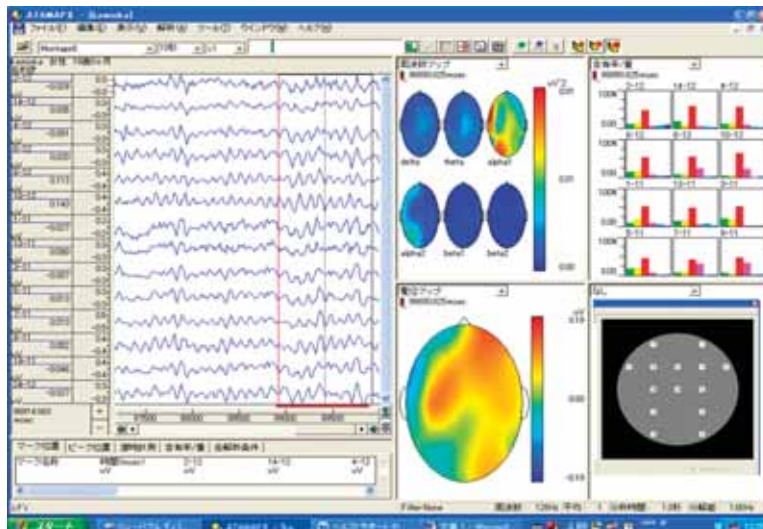


図 2 ボランティア学生 (19 歳女性) の安静閉眼時の EEG およびトポグラフィ : KISSEI COMTEC 製 ATAMAP-II により作成 (周波数マップ上、後頭部優位に α 波が出現している) 。

このマッピングを用いると、複雑な波形の脳波では元波形からは理解しにくい、周波数成分とその量を把握でき、また頭皮上の各周波数成分の分布を直感的に把握できる。我々もこのようなパワースペクトルに変換された脳波データを用いている。

人間工学分野における EEG の周波数成分を用いた従来の研究では、 δ 波帯域、 θ 波帯域、 α 波帯域、 β 波帯域さらには γ 波帯域というように複数帯域のデータを利用しているものが多い^{10,11)}。しかし 2 章で述べたように、睡眠脳波や異常脳波などを対象とする臨床医学分野に対して、人間工学分野では成人の正常脳波を対象とすることになる。そして、成人の覚醒時の正常脳波は主に α 波と β 波から構成され、明らかな θ 波や δ 波は存在しない。また、人間工学分野において脳波を利用する場合は、リラックス度やストレス度また快適性を、主として着目している時間帯における α 波および β 波の出現率またはそれらの振幅の増減を指標として評価することが多い。このため、我々は α 波帯域 (8~13Hz) および β 波帯域 (14Hz~30Hz) から得られる 2 つの周波数成分 (パワースペクトル) のみを用いて、精神状態の推定・分類を試みることにした。

4. データ処理法と自己組織化マップ

4.1 データ処理法

以前、拙稿において記述したように¹⁰⁾、近年、大規模なデータから隠れた知識や予期せぬパターン、新しい規則などを発見、抽出する情報処理技術、すなわちデータマイニングが急速に発展してきている¹⁵⁾。そして発見科学という学際的分野が登場してきた¹⁶⁾。データが存在するところにデータマイニングが発生し、また研究対象が個人で違えばデータマイニングの対象も違うため、その適用範囲は非常に広汎である。また、データマイニングにおいて使われる手法も、注目している対象に応じて、統計的手法をはじめ、人工知能、人の脳神経細胞網が行っている並列処理を真似たニューラルネットワークなどさまざまなものが使われており、広汎である^{16,17)}。

ヒトは赤ちゃんから成長していく過程において、時には失敗を繰り返して物事を学習し、そして理解・記憶していくが、これはすべてヒトの脳が学習し、理解・記憶していることに他ならない。そしてその過程においてヒトの脳は特定の神経回路網を新たに構築することによってそれらのことを達成している。このようなヒトの脳を真似た人工的な神経回路網を構築することで、特定の処理を行うことができるようになるパラダイムが人工ニューラルネットワーク (一般にはニューラルネットワークと呼ばれている) である。そしてこのネットワークはハード的、およびソフト的 (つまりはプログラム) に構築され利用されている。

今回、我々が、EEG データに適用した自己組織化 (特徴) マップ self-organizing (feature) map : SOM というクラスタリングアルゴリズムは、T. Kohonen によって発案されたパラダイムである¹⁸⁾。いま、対象が多くの情報を持つ場合、例えば EEG の場合では電極ごとに EEG 波形が収集されるため、同時刻に電極数分のデータが収集される。また波形の周波数成分を扱うと、扱う周波数帯域の数を電極数に乗じた数のデータが発生する。このような場合、ある時刻において数十個のデータが発生することになるが、この数十個のデータを各次元とする多次元ベクトルでその時刻のデータを一くくりして表し、取り扱うことになる。このような多次元情報を直接扱う方法としては多変量解析が有名である。一方、SOM は多次元情報を 2 次元マップへ射影することにより、多次元情報を可視化する 2 層構造を持つニューラルネットワークである (図 3)。

ニューラルネットワークでは特定の処理を行うために、学習および記憶という要素が不可欠である。あらかじめ答えが判っている信号を与えて、正しく答えが出せるようにニューラルネットワークを学習させていく教師有り学習。一方、とにかく信号を与えその信号を元にネットワーク




図3 Kohonen 特徴地図の基本構造 (多次元入力ベクトルから2次元競合層内の単一ユニット (参照ベクトル) との結合の様子) (自己組織化マップの応用: 海文堂より引用)

が自ら学習し結果を出していく教師無し学習。ニューラルネットワークを学習させる方法はこれら2つに大別される。SOMは教師無し学習アルゴリズムを用いている。

4.2 自己組織化マップ (SOM)¹⁹⁾

SOMの2層とは入力層と出力(競合)層である。入力層は4.1節で述べた多次元ベクトルを入力ベクトルとする層である。また出力(競合)層はネットワークからの出力を視覚的に見るため通常2次元に配列されている。つまり、出力(競合)層が2次元マップを構成していることになる。また出力(競合)層の各配列要素はニューロンまたはユニットなどと呼ばれ、ユニット同士を識別するためにラベル i ($i = 1 \sim N$; N はユニットの総数)を付けておく。また出力(競合)層の各ユニット i には参照ベクトル $m_i(t)$ が割り振られ、このベクトルは入力層の次元に合わせて n 個の要素を持っている。ここで t はネットワークの学習回数を表す。

このネットワークにおける情報の処理の仕方は以下のような式でまとめられている。

$$m_i(t+1) = m_i(t) + h_{ci}(t) [x(t) - m_i(t)] \quad (1)$$

この式の意味は次のようなものである。ニューロン i が時刻 t で処理している情報処理能力を $m_i(t)$ とすると、外部から入力信号 $x(t)$ が入るとする。ニューロンはこの入力信号を学習して次の時刻には $x(t)$ により近い情報処理能力 $m_i(t+1)$ を持つようになる。このとき、 $x(t)$ が n 次元の入力ベクトルであれば、参照ベクトルとも呼ばれる $m_i(t)$ は同じ n 次元の要素を持つ。また $h_{ci}(t)$ は学習効率係数を含めた近傍関数と言われるもので、学習時間の経過とともに通常、単調に減少させていく。

SOMにおける多次元情報を2次元マップに可視化するアルゴリズムは以下のようなものである。

- (1) はじめに参照ベクトル $m_i(0)$ ($i = 1, 2, \dots, k$) をランダムに初期化する。
- (2) 入力ベクトル x と最も良く一致する参照ベクトル $m_c(t)$ を持つ競合層のユニット C (勝者ユニット)を探す。そして、 x にそのユニットのラベルを付ける。

$$x \in C \quad \text{if} \quad \|x - m_c(t)\| = \min_i \{ \|x - m_i(t)\| \} \quad (2)$$

ここで、 $\|\cdot\|$ は適当な距離 (たとえばユークリッド距離) である。

(3) 勝者ユニットの近傍の参照ベクトルを更新する。

$$m_i(t+1) = \begin{cases} m_i(t) + \alpha(t) [x - m_i(t)], & i \in N_c \\ m_i(t), & i \notin N_c \end{cases} \quad (3)$$

ここで、 N_c は勝者ユニットの近傍を表す。

また、

$$\alpha(t) = \alpha_0 (1 - t/T), \quad (4)$$

および、

$$N_c = N_0 (1 - t/T) \quad (5)$$

ここで、 α は $0 < \alpha < 1$ の値をとる学習率係数で、その値は訓練が進むにつれて 0 へと

減少していく。また t は現在の学習回数であり、 T は行われるべき学習の回数である。

近傍 N_c も α と同様にサイズを減らしていく。

学習を繰り返していくと、特定の入力に対する勝者ユニットは徐々に固定化されていく。そして、ほぼ固定されるまで学習が進んだ段階でアルゴリズムを停止する。以上の結果、出力 (競合) 層の各ユニットそれぞれに、類似した入力ベクトルが集まってきてクラスタを作ることになる。実際には、互いに類似した入力ベクトルは出力 (競合) 層の同じユニットにラベル付けされることになる。そして、そのラベル付けを元に特徴マップと呼ばれる 2 次元マップが作成される。このような教師無し学習によって入力ベクトルが自動的に分類されることを通称、クラスタリングと呼んでいる。この入力信号間の類似性を反映している特徴マップを分析・解釈することで、多次元情報である入力信号に関するさまざまな知識を得ることが可能になる。我々は、EEG データを SOM に入力して作成された特徴マップのどのユニットにその EEG データがクラスタリングされるかにより、精神状態の推定を行うことを試みた。

4.3 EEG データへの SOM の適用

今回、我々は α 波帯域および β 波帯域のパワースペクトルを元に、以下のような量を作成し、精神状態の推定および分類に利用した。① α 波帯域および β 波帯域のパワースペクトルの比: P_α/P_β 、② α 波帯域および β 波帯域のパワースペクトルの 2 乗和の平方根: $\sqrt{P_\alpha^2 + P_\beta^2}$ 。すなわち、電極ごとに $(P_\alpha/P_\beta, \sqrt{P_\alpha^2 + P_\beta^2})$ の対データが得られることになり、この対データを電極数並べたものを入力ベクトルとして SOM を適用する。

ところで、 P_α/P_β は、両周波数帯域のパワーの変化、すなわち α 帯域と β 帯域の相対的増減に対応する。これには、EEG における α 波および β 波の振幅の増減およびそれら周波数成分の増減によるパワースペクトルの変化が反映されている。この P_α/P_β は α 波および β 波の変化率が異なるとき、その様子を捉えることができる。しかし、 α 波および β 波が同率で変化するとき P_α/P_β はその変化を反映しない。また、 $\sqrt{P_\alpha^2 + P_\beta^2}$ は α 波および β 波両周波数帯域のパワースペクトルの合計の変化 (両周波数帯域パワーの絶対量の増減) に対応する。これには EEG における α 波および β 波の振幅の増減およびそれら周波数成分の増減によるパワースペクトルの変化が反映されている。そして $\sqrt{P_\alpha^2 + P_\beta^2}$ は、 α 波および β 波両周波数帯域のパワースペクトル

が同じように変化する、すなわち、2つのスペクトルが共に増加または減少する様子を反映する。しかし、 $\sqrt{P_\alpha^2 + P_\beta^2}$ は α 波が減少して β 波が増加したとき、またはその反対のときに、これらの増減分が相殺されると変化しない。したがって、そのような変化は P_α/P_β で捉える方が有効である。

結局、2章で述べた精神状態と α 波成分および β 波成分の関連性から、以下のようなことが言える。① P_α/P_β は、安静時や精神的緊張時など脳の活動状態の違い、あるいは活動性の有無を反映している。活動性であれば小さくなる。② $\sqrt{P_\alpha^2 + P_\beta^2}$ は、脳の活動レベルを反映している。より活発に活動していると小さくなる。

しかし、3章で述べたように、正常人でも、 α 波の出現率の高い者もいれば、ほとんど見られない者もいる。また α 波の振幅の大きい場合や小さい場合もある。さらに β 波の多寡にも差があって、全体的な EEG は生理的範囲内であれば、かなりの個体差を示す。このため、通常、正常な EEG ではこの人の EEG が万人の基準となるべき EEG であるというようなことは言えない。ある人の精神活動状態に対する EEG の変動は、その人においてのみ意味を持つ。そこで、上述の①および②の量に関して、被験者ごとに安静閉眼時におけるそれらの値の平均値を基準値として、基準値と特定の精神状態における値との比をとった。このように被験者ごとに正規化することにより、EEG における個人差の低減をはかった。

結局、基準値に対する相対値として正規化された ($P_\alpha/P_\beta, \sqrt{P_\alpha^2 + P_\beta^2}$) の対データを用いる。なお、実際の SOM の操作では、正規後の P_α/P_β または $\sqrt{P_\alpha^2 + P_\beta^2}$ のデータの中で最大値をとるデータによって再度正規化し、SOM の入力ベクトルの各要素値が 0 ~ 1 の範囲になるようにしている。

5. 実験

5.1 EEG データの収集

EEG は 10-20 法 ten-twenty electrode system および Aav 法 (左右の基準電極の平均電位を基準にする方法) を採用して、NIHON KOHDEN 製 EEG-1714 により収集した。なお、瞬目や眼球運動の影響を避けるため、図 4 に示すような前額部の電極 Fp_1, Fp_2 を除外した $F_3, F_4, F_7, F_8, C_3, C_4, T_3, T_4, P_3, P_4, O_1, O_2, F_z, C_z$ の 14 電極のデータを採用した。さらに、電極ごとに得られた EEG 波形に対して EEG マッピングソフト KISSEI COMTEC 製 ATAMAP-II による周波数解析を適用し、 α 波帯域 (8-13Hz) および β 波帯域 (13-30Hz) のパワースペクトルを取り出した。こうして、4.3 で述べた正規化された ($P_\alpha/P_\beta, \sqrt{P_\alpha^2 + P_\beta^2}$) の対データが 14 電極分得られる。したがって、SOM への入力データ (入力ベクトル) は 28 個の要素を持つことになる。解析条件はサンプリング周波数 128Hz、FFT 区間 1 秒、窓関数矩形に設定した。また EEG 波形上で FFT 区間がオーバーラップするように 0.25 秒ずつシフトさせてデータ数を稼いでいる (図 4)。

5.2 実験した精神状態と被験者

(1) 評価した精神状態は以下のようなものである。

- A) 安静閉眼時: rest and closed eyes → 精神状態のリファレンスとする。
- B) 好みの音楽を聴く: listen the favorite music (精神的快適状態)
- C) その音楽の中でもお気に入りの箇所: listen the favorite parts in the music
- D) 暗算時: mental arithmetic (精神的負荷・緊張状態)

① $1 + 1 = 2, 2 + 2 = 4, 4 + 3 = 7, 7 + 4 = 11, 11 + 5 = 16, \dots$ という様に、

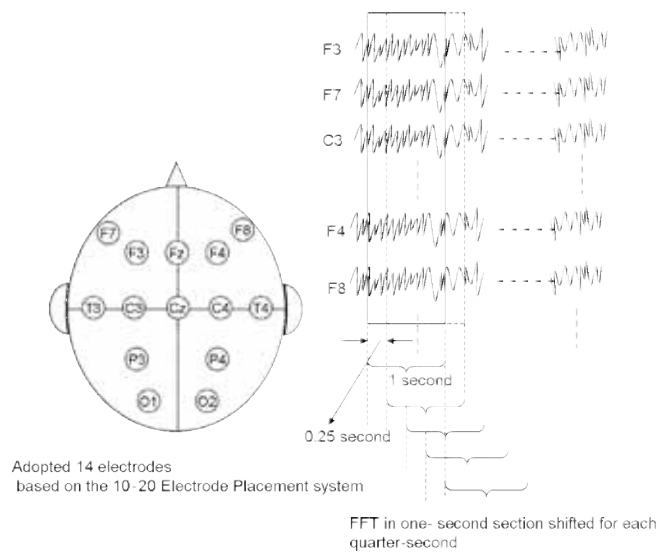


図4 採用した14電極と得られる EEG に対する高速フーリエ変換 (FFT) 区間の設定

逐次的に足し算を行う。

E) 12色の思い出し：remember 12 colors (精神的負荷・緊張状態)

① 7×10の正方形のマス目に12色をランダムに配置した画像を15秒程度見せた後、12色の色を思い出してもらおう作業。

(2) なお、開眼状態ではα波が抑制され、また眼球運動および瞬目の影響が著しく、そのままでは解析が困難な場合が多いため、安静時以外のタスクもすべて閉眼状態で行った。

(3) 実験に参加したボランティア学生数は15名を超えたが、α波の出現状態が良く、データ処理のやりやすい被験者は半数以下であり、脳波における個人差の大きさを実感した。また衛生技術科の学生構成の特性から、利用するデータの構成は結果的に女子学生の割合が多くなった。本稿では、比較的α波の出現状態が良かった7名分(男子学生2名、女子学生5名；年齢分布19～20歳)のデータを使った結果を示す。

(4) 実験で使用した被験者ごとおよび精神状態ごとの EEG データの内訳を表1に示す。

表1 SOMに入力する各精神状態における EEG データ(学習用およびテスト用)

Mental states	Subjects	Data for learning					Data for testing	
		S1	S2	S3	S4	S5	T1	T2
Rest and closed eyes		137	103	124	115	63	272	430
Listen the music		141	171	101	33	91	390	619
Listen the favorite		74	193	49	77	50	395	348
Remember 12 colors		9	15	26	8	20	65	148
Mental arithmetic		14	9	7	26	74	249	157
Total of data		375	491	307	259	298	1371	1702

学習用データにおいて、“12色の思い出シタスク”および“暗算タスク”におけるデータ数がその他の精神状態と比べると少ない理由は、これらはいわゆるストレス状態下でのデータであるため、EEG 波形に瞬目の影響などの雑音が混入し、その他の精神状態の EEG 波形と比べると波形が変形している場合が少なくなかったからである。このような、変形している波形などを除外していった結果、使用できるデータ数が少なくなってしまった。なお、表中では自己組織化マップ (SOM) に対する学習用データおよびテスト用データを区別して示している。また、被験者はそれぞれ学習用 S 1~S 5、テスト用 T 1~T 2 とラベルしている。なお、学習用およびテスト用それぞれに男子学生を 1 名ずつ割り当てている。

5.3 SOM による処理

我々は、まずユニットサイズ 3×3 の SOM を用いて学習用データのクラスタリングを行い、精神状態の分類性能を調べた。そして、クラスタリングによって生成された 2 次元マップを用いてテスト用データのクラスタリングを行い、生成されたマップの有用性を評価した。次に、ユニットサイズ 7×7 の SOM を用いて学習用データのクラスタリングを再度行い、ユニットサイズ 3×3 の各ユニットのデータが、ユニットサイズを拡大することで、より細分化される様子を探った (図 5)。

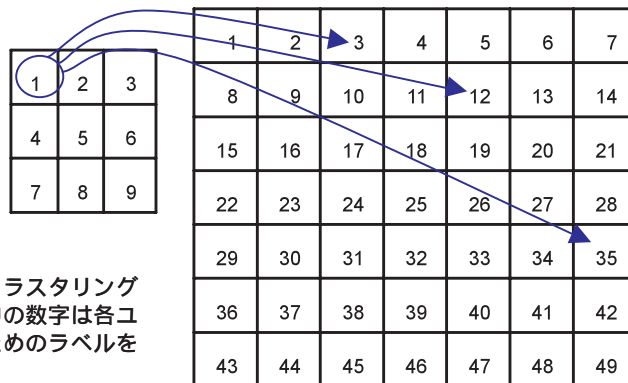


図 5 ユニットサイズとクラスタリングの変化：ユニット中の数字は各ユニットを識別するためのラベルを表す。

6. 実験結果 1

表 1 のデータに SOM を適用した結果をデータ数のクラスタリング分布状態として表 2 に示す。なお、 3×3 のマップにおけるユニットは図 5 で表しているようにラベルしている。図 6、7 に各ユニットにクラスタリングされた EEG データの P_α/P_β と $\sqrt{P_\alpha^2 + P_\beta^2}$ の相対値の電極分布を示す。横軸は図中心を境に左側を P_α/P_β 、また右側を $\sqrt{P_\alpha^2 + P_\beta^2}$ として、それぞれ左右の

表 2 表 1 のデータに対する SOM のクラスタリング結果：各ユニットのデータ数分布 (学習用データ)

11	282	228
4	523	64
171	366	81

Total 1730

(テスト用データ)

11	258	287
0	1460	47
286	621	103

Total 3073

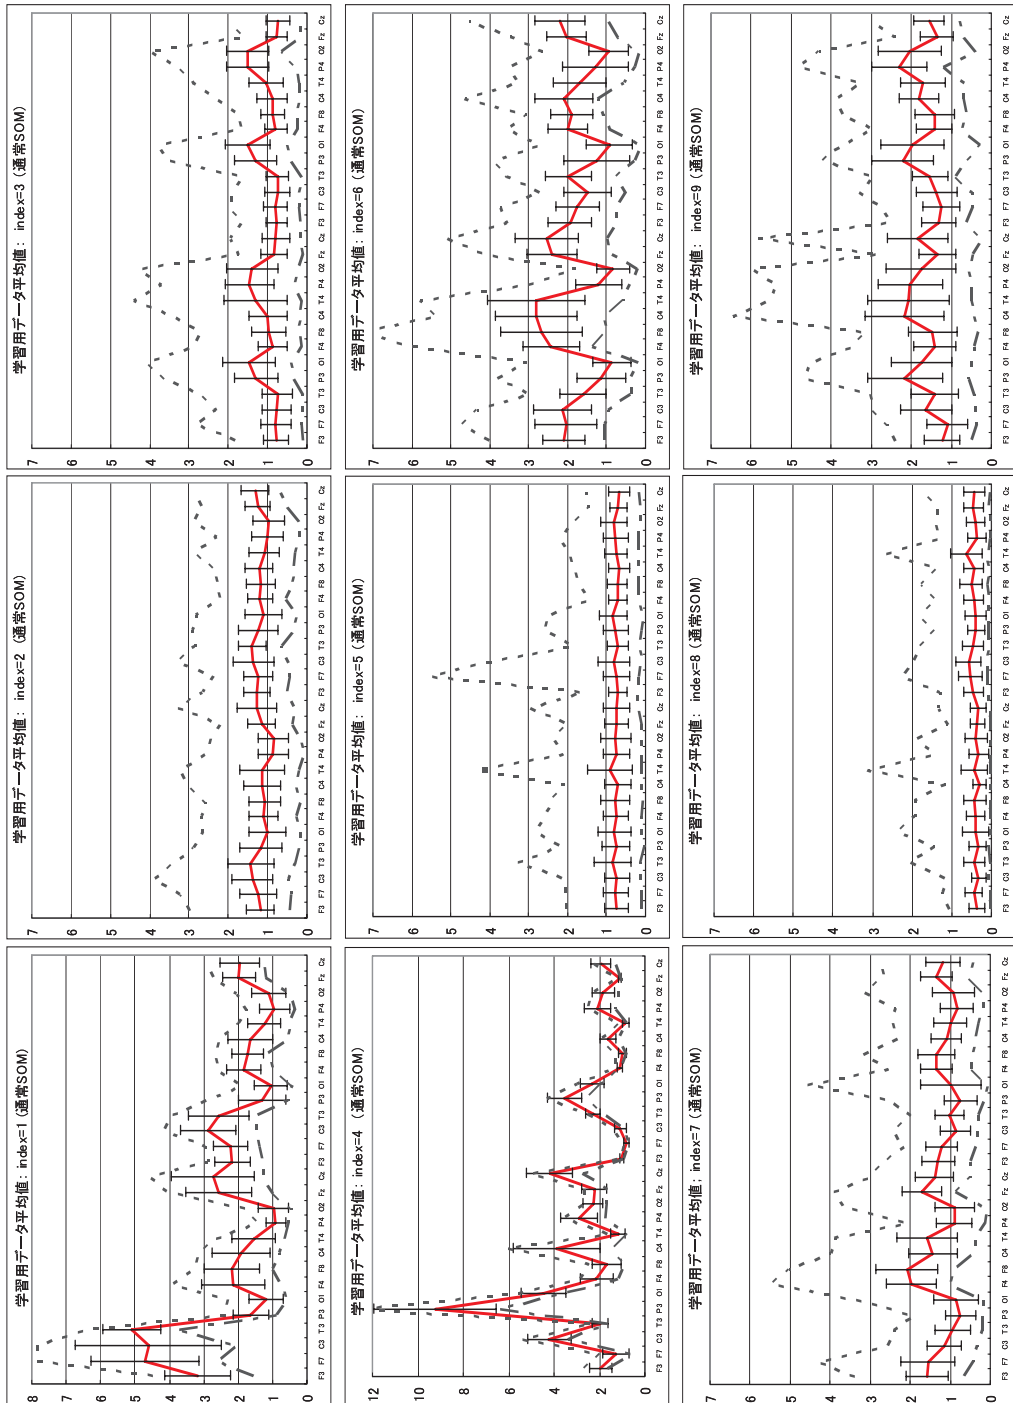


図6 学習用データに対する SOM(3×3) の出力結果: 各グラフにおいて、横軸はデータ収集電極を表し、グラフ中心を境にして左側が P_{α}/P_{β} 、右側が $\sqrt{P_{\alpha}^2 + P_{\beta}^2}$ に対応する。

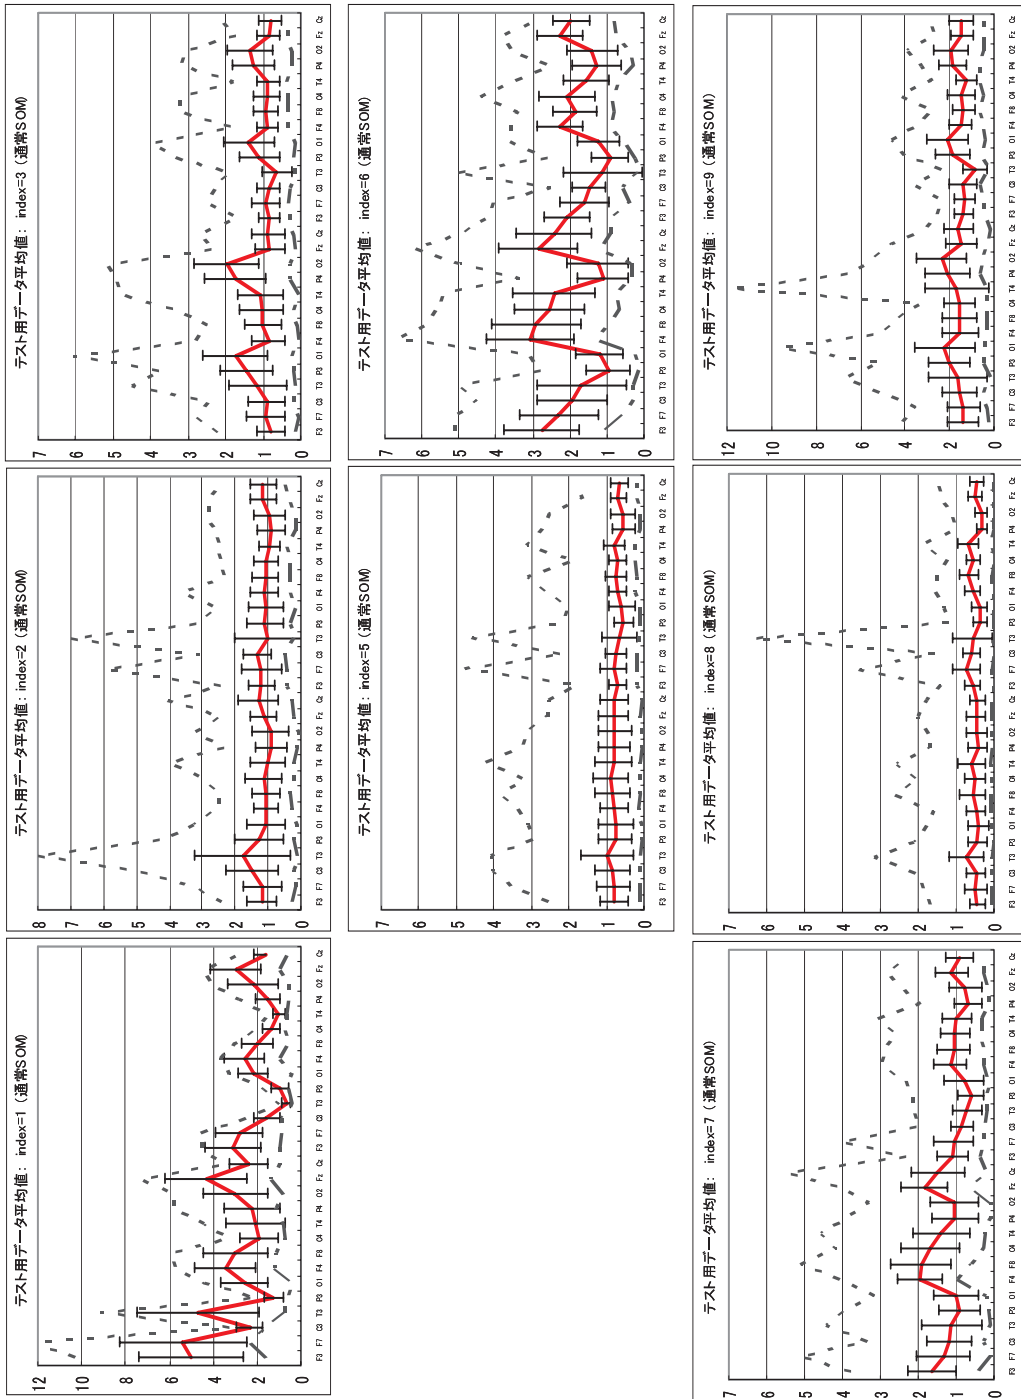


図7 テスト用データに対する SOM (3×3) の出力結果：各グラフにおいて、横軸はデータ収集電極を表し、グラフ中心を境にして左側が P_α/P_β 、右側が $\sqrt{P_\alpha^2 + P_\beta^2}$ に対応する。

電極ごとにまとめて、F₃、F₇、C₃、T₃、P₃、O₁、F₄、F₈、C₄、T₄、P₄、O₂、F₂、C₂で表示している。縦軸は、安静閉眼時の平均値を1としたそれぞれの値の相対値を表している。実線は平均値の分布、破線は最大値の分布、また一点破線は最小値の分布を表す。縦の誤差範囲は標準偏差を示す。

学習用データに対する、SOMの出力結果である図6に示される、各ユニットの P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の相対値の電極分布における平均と標準偏差を計算すると表3のようになった。またこれらの平均値と標準偏差を元に、各ユニット間の電極分布の統計的有意差をZ検定により検定した。ただし他と比べてデータ数が極端に少なくかつ特異な分布を示したユニット1と4は検定から除いた。その結果 P_α/P_β ではすべてのユニット間に有意差が認められ、 $\sqrt{P_\alpha^2+P_\beta^2}$ ではユニット6と9では有意差がなかったがそれら以外では有意差が認められた。

次に、テスト用データに対するSOMの出力結果である図7に示される各ユニットの P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の相対値の電極分布における平均と標準偏差を計算すると表4のようになった。また、学習用データと同様にこれらの平均値と標準偏差を元に各ユニット間の電極分布の統計的有意差をZ検定により検定した。ただし学習用データと同様、他と比べてデータ数が極端に少ないユニット1は検定から除いた。その結果、 P_α/P_β ではユニット2と3では有意差がなかったがそれら以外では有意差が認められ、 $\sqrt{P_\alpha^2+P_\beta^2}$ ではすべてのユニット間に有意差が認められた。また、図6（学習用データ）と図7（テスト用データ）の間で、同じユニットラベルにおける電極分布の統計的有意差を同様に検定した。今度は同じユニットラベル同士の検定を行うため、テスト用データのSOMの出力が存在しないユニット4以外はユニット1も含めて検定した。その結果、 P_α/P_β ではユニット9では有意差がなかったがそれ以外では有意差が認められ、また $\sqrt{P_\alpha^2+P_\beta^2}$ では、ユニット1と6では有意差がなかったがそれら以外では有意差が認められた。

表3 図6の各ユニットの P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の電極分布における平均(M)と標準偏差

M=2.526, SD=1.659	M=1.140, SD=0.488	M=1.035, SD=0.568	M=1.755, SD=0.794	M=1.202, SD=0.411	M=1.000, SD=0.497
M=3.109, SD=2.245	M=0.772, SD=0.380	M=1.969, SD=1.030	M=1.614, SD=0.820	M=0.741, SD=0.303	M=1.679, SD=0.750
M=1.341, SD=0.699	M=0.376, SD=0.249	M=1.666, SD=0.803	M=1.085, SD=0.487	M=0.462, SD=0.281	M=1.660, SD=0.655

(P_α/P_β)

($\sqrt{P_\alpha^2+P_\beta^2}$)

表4 図7の各ユニットの P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の電極分布における平均(M)と標準偏差

M=3.110, SD=1.999	M=1.170, SD=0.699	M=1.169, SD=0.722	M=1.884, SD=1.072	M=1.091, SD=0.526	M=0.972, SD=0.584
	M=0.821, SD=0.463	M=2.104, SD=1.206		M=0.672, SD=0.309	M=1.652, SD=0.772
M=1.393, SD=0.755	M=0.491, SD=0.299	M=1.723, SD=1.008	M=0.912, SD=0.447	M=0.516, SD=0.279	M=1.506, SD=0.677

(P_α/P_β)

($\sqrt{P_\alpha^2+P_\beta^2}$)

ところで、表 2 より判ることであるが、学習用データおよびテスト用データともに、ユニット 1 およびユニット 4 にクラスタリングされたデータはその他のユニットと比べると非常に少数である。また図 6 および図 7 の電極分布より、それらはその他のユニットにクラスタリングされた電極分布と比べると P_{α}/P_{β} の相対値にかなり大きく、また左電極の値が右電極よりも大きいものが多く、総体的に大脳の左半球が右半球よりも活動していない分布パターンを示していることが伺える(図 8)。さらに、テスト用データではユニット 4 にクラスタリングされたデータがなく、ユニット 4 は今回の実験では、かなり特異なデータ群であると思われる。




図 8 データ数の少ないユニットの特異な電極分布：学習用データおよびテスト用データ

表5 表2の各ユニットにおける精神状態の占有状況

RCE : 5	RCE : 127	RCE : 89	RCE : 1	RCE : 116	RCE : 95
Musc : 1	Musc : 84	Musc : 70	Musc : 3	Musc : 66	Musc : 93
Favrt : 5	Favrt : 67	Favrt : 69	Favrt : 3	Favrt : 35	Favrt : 42
12c :	12c :	12c :	12c : 0	12c : 8	12c : 20
MeArth :	MeArth : 4	MeArth :	MeArth : 4	MeArth : 33	MeArth : 37
RCE : 1	RCE : 195	RCE : 18	RCE :	RCE : 279	RCE : 23
Musc : 3	Musc : 202	Musc : 12	Musc :	Musc : 505	Musc : 8
Favrt :	Favrt : 112	Favrt : 34	Favrt :	Favrt : 409	Favrt : 4
12c :	12c : 4	12c :	12c :	12c : 91	12c : 2
MeArth :	MeArth : 10	MeArth :	MeArth :	MeArth : 176	MeArth : 10
RCE : 47	RCE : 43	RCE : 17	RCE : 57	RCE : 71	RCE : 60
Musc : 70	Musc : 69	Musc : 26	Musc : 67	Musc : 242	Musc : 26
Favrt : 54	Favrt : 64	Favrt : 38	Favrt : 59	Favrt : 186	Favrt : 5
12c :	12c : 74	12c :	12c : 24	12c : 68	12c : 0
MeArth :	MeArth : 116	MeArth :	MeArth : 79	MeArth : 54	MeArth : 12

(学習用データ)

(テスト用データ)

- RCE : Rest and closed eyes (安静閉眼時)
 Musc : Listen the music (音楽を聴いている時)
 Favrt : Listen the favorite (お気に入り箇所を聴いている時)
 12c : Remember 12 colors (12色を思い出している時)
 MeArth : Mental arithmetic (暗算をしている時)

表5には表2の各ユニットにおける各精神状態の占有状況を提示している。表5中、RCEは安静閉眼時を、Muscは音楽を聴いている状態を、Favrtはお気に入りの箇所を聴いている状態を、12cは12種類の色を思い出している状態を、そしてMeArthは暗算をしている状態を示している。図6、7および図8に示される特異な分布を持つユニット1とユニット4にクラスタリングされた被験者データの内訳は、学習用データのユニット1では、被験者S1のRCE状態が5個、Musc状態が1個、およびFavrt状態が3個と被験者S2のFavrt状態が2個であり、またユニット4では、被験者S5のRCE状態が1個とMusc状態が3個である。またテスト用データのユニット1では、被験者T1のMeArth状態が4個と被験者T2のRCE状態が1個、Musc状態が3およびFavrt状態が3個である。右半球に比べて左半球の活動レベルが低い特異な分布となった精神状態は、音楽を聴いている状態に多いことが判る。

7. 考察1

図6と表3およびマップの各ユニット間の有意差検定の結果から、学習用データに関しては異なった電極分布は異なったユニットにほぼ正確にクラスタリングされていることが予想される。このことは言い換えれば、異なった脳の活動レベルは異なったユニットにほぼ正確にクラスタリングされているとも言える。そうは言うものの、平均値と標準偏差の値からユニット2と3は同じようなレベルでの脳の活動状態であり、ユニット6の活動レベルに最も近いものはユニット9の活動レベルであると推察される。そしてこれら2つのユニットはマップ上、互いに隣接してお

り、SOMの特徴である類似しているものは近傍にクラスタリングされる、という特性が現れている。

同様に、テスト用データに関しても、図7と表4および作成されたマップの各ユニット間の有意差検定の結果から、異なった電極分布は異なったユニットにほぼ正確にクラスタリングされていることが予想される。また、ユニット2と3およびユニット6と9それぞれの関係も学習用データに関する関係と同様な傾向が見られる。

学習用データとテスト用データの間の有意差検定の結果では、統計的には有意差があり母集団として同じでないユニットが多いが、表3と表4における平均値と標準偏差のユニット間の変化を見ると、学習用データとテスト用データともに、 P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ とも同じ傾向にある。すなわち、ユニット4を除けば、ユニット1が基準値（安静閉眼時の平均値）に対する相対値が最も高い。ユニット6はユニット1に次いで高値であり、基準値よりはかなり高く、ユニット9がユニット6に続く。一方、ユニット8の相対値は最も低く、そして2番目に相対値が低いのはユニット5であり、これは2つのユニットは基準値よりも低値である。ユニット2とユニット3は共に基準値近傍であるが、ユニット2がやや高値である。ユニット7も基準値近傍といえるが、ユニット2および3よりは、 P_α/P_β がやや高値である。図6と図7における P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の相対値の電極分布の形を見ても、学習用データとテスト用データの各ユニットで、ほぼ同じような傾向が見られる。以上のことから、SOMによるクラスタリングは、14電極分の P_α/P_β との $\sqrt{P_\alpha^2+P_\beta^2}$ データ、すなわち、28個の要素を持つ入力ベクトルをその要素の統計的性質と2次元における分布状態の違いをうまく分類していることが予想され、今回導入したEEGデータに関する2つの量を用いたSOMは、精神状態の違いに由来する脳活動状態の違いを正しく分類し、またSOMが出力するマップ上のどのユニットに属したかが判れば、与えられたEEGデータがどのような精神状態で得られたものであるかを推定できる可能性が見い出されたと考える。

次に、表5の精神状態の占有状況を図6および表3と表5と対比してみる。表5より、学習用データでは、12cおよびMeArth状態がユニット8に集中している。これら2つの精神状態は、一般的にその他の精神状態と比べて、脳の活動状態はより活発であり、その結果、 P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の相対値は低くなってしまふ。これらの状態は、ある程度の無理強いをさせられていると言えるので、ある種のストレス状態であると言える。このことは、図6と表3にも反映されている。また、ユニット5の内訳ではMusc状態が最も多い。音楽を聴いている状態では、当然聴覚が機能しており、脳はある程度活性状態であると思われる。このことは同様に、図6と表3にも反映されている。このように、ユニットにおける精神状態の構成比率と、 P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の相対値は関連性があるように見える。すなわち表5より、ユニット6と9ではFavrt状態が最も多くRCE状態は少ないが、これらのユニットでは、図6および表3における P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の相対値は、基準値よりもかなり高くなっている。これらユニットにクラスタリングされた状態は、脳の活性状態が低いストレス状態とは逆の状態、つまりはゆったりとしたリラックス状態（俗に言う α 波が多く出ている状態）が多いと言える。またユニット2と3ではRCE状態が最も多く、次いでMusc状態が多いが、それらの P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の相対値は図6および表3から、基準値よりは高いがユニット6と9よりは低くなっている。これらの状態は敢えて言えば、ストレス状態でもリラックス状態でもない、ニュートラルな状態が多いと考えられる。以上のことから、今回用いた学習用データのような構成に関しては、SOMから出力されたマップを利用して、リラックス状態とストレス状態およびニュートラルな状態の分類・推定が可能であると考えられる。

一方、テスト用データでは、前述のように表4および図7において、それぞれ表3および図6と同様なユニット間の分布傾向があるにも関わらず、表5の精神状態の占有状況は学習用データとは異なっている。すなわち、RCE、MuscおよびFavrt状態のユニット間の分布傾向と比べて、いわゆるストレス状態と思われる12c状態とMeArth状態は学習用データと違ってユニット8に集中しておらず、その他のユニットにも分散している。また、ユニット6と9における精神状態の構成も学習用データとは異なっている、などである。

このような学習用データとテスト用データの違いはなぜ生じたのか？その理由の1つは学習用データ群とテスト用データ群のデータ数の差、特に12c状態とMeArth状態における学習用データ数とテスト用データ数の差が大きいことがあると思われる。すなわち、テスト用データでは、特定の精神状態として採用したデータ数が多いため、特定の精神状態の中に、さらにある程度の状態差（真剣に与えられたタスクを行っているか、そうでないかなど）が存在している可能性がある。その状態差がSOMによるクラスタリングに反映され、ストレス状態と思われる2つの状態の複数ユニットへの分散を導いたと考えられる。

以上の予想は、後日、被験者T1とT2に聴取した結果からもある程度裏付けられた。すなわち、全くの偶然であるが、被験者T1はそろばんの有段者であり、暗算が好きで、得意であった。さらに被験者T2も児童期に足し算などの暗算の訓練を受けていたことが判明した。またそうであるから、結果的に、学習用データの被験者群と比べて、より多くのデータが収集できたことも納得できる。このような被験者たちにとっては、通常、かなりなストレス状態と思われるタスクでも、負担が軽いため、脳の活動状態が活発でない。言い換えれば、実験で得られた結果は、ヒトは自分にとって得意なタスクや慣れたタスクを行うときには、あまり脳を使っていないという知見をもたらしている予想される。

今回の実験では5種類の精神状態のラベル付けを行っているが、SOMのクラスタリング結果は、ヒトの精神状態は常に変動し、安静閉眼時といっても、その中にはさまざまな状態が存在することを暗示している。ヒトの精神状態は常に変動しているということは、考えてみれば当たり前であるが、このような知見はEEGの波形やトポグラフィから得られる情報では判然としないものであり、SOMによるクラスタリングの有用性を強調すると思われる。なお、 α 波は本来、漸増漸減を行うので、その漸増期と漸減期の違いがクラスタリングに影響していることも排除できない。この点については、脳波波形から時間的に追跡していく必要があり、今後調査すべき課題である。

また、図6と図7の電極分布の形に着目するとユニット2、5およびユニット8と比べてユニット3、6、7およびユニット9は分布の変動がより激しいように見える。その理由は、表2から明らかなように、それらのユニットにクラスタリングされたデータ数が大きく違うことにある。すなわち、データ数が大きいものは、その変動が平均化されて目立たなくなるからである。そうは言っても、テスト用データのユニット3のデータ数はユニット2とほぼ同数であるにもかかわらず、より変動の激しい分布を示している。このことは、ユニット3の精神状態はユニット2とは異なる状態であることを暗示している。ユニット3では、左右のPとO電極、すなわち頭頂から後頭部の電極における P_{α}/P_{β} と $\sqrt{P_{\alpha}^2+P_{\beta}^2}$ の相対値がその他の電極に比べて、より高値となっている。このことは、これらの電極部位に相当する脳の領野がその他の領野と比べてより働いていないことを示している。このような視点からユニット6を眺めると、ユニット3とは逆に左右のPとO電極部位が、より働いていることが判る。このような電極ごとの違いを元にしたより細かい知見は、データ数が多く変動の少ないユニット3、6、7からは得られない。

そこで、より細かい知見を得るために、マップサイズを大きくした 7×7 のSOMを実施した。

8. 実験結果 2

表1の学習用データに 7×7 のSOMを適用した結果を、各ユニットのデータ数の分布として表6に示す。表6から、マップサイズを2倍以上に大きくしても、なお多くのデータ数がクラスタリングされるユニットが存在することが判る。いま学習用データの総数が1730個であり、 $7 \times 7 = 49$ であるので、単純平均では35.3個/ユニットとなる。類似した入力データは互いに同じユニットにクラスタリングされるか、または互いに近傍であるユニットにクラスタリングされるというSOMの特性がある。このため、平均の2倍程度よりも多いユニットにクラスタリングされたデータ同士は、類似度が高いデータが多数集まっていると思われる。このようなユニットを数えるとデータ数68個以上のものが、8個存在する。それら8個のユニットにおける精神状態の内訳を表7に示し、図9a、図9bにはそれらの P_α/P_β および $\sqrt{P_\alpha^2 + P_\beta^2}$ の相対値の電極分布を

表6 表1の学習用データに対するマップサイズ 7×7 のSOMのクラスタリング結果：各ユニットのデータ数分布

24	7	22	25	7	7	3
98	23	34	149	12	16	3
76	52	13	81	30	15	9
73	42	30	34	21	5	15
57	25	28	59	108	129	6
42	68	37	6	29	7	16
42	15	48	36	13	11	22

表7 データ数が多いユニットにおける精神状態の内訳（マップサイズ 7×7 のSOM）

	Unit 8	Unit 11	Unit 15	Unit 18	Unit 22	Unit 33	Unit 34	Unit 37
RCE:	1	14	46	46	16	33	53	18
Musc:	3	34	7	21	43	46	43	40
Favrt:	17	31	23	14	13	21	28	7
12c:	45	25				1	2	3
MeArth:	32	45			1	7	3	

a. 各ユニットにおける各精神状態のデータ数

	Unit 8	Unit 11	Unit 15	Unit 18	Unit 22	Unit 33	Unit 34	Unit 37
RCE:	1.0%	9.4%	60.5%	56.8%	21.9%	30.6%	41.1%	26.5%
Musc:	3.1%	22.8%	9.2%	25.9%	58.9%	42.6%	33.3%	58.8%
Favrt:	17.3%	20.8%	30.3%	17.3%	17.8%	19.4%	21.7%	10.3%
12c:	45.9%	16.8%				0.9%	1.6%	4.4%
MeArth:	32.7%	30.2%			1.4%	6.5%	2.3%	

b. 各ユニットにおける各精神状態の占有率

示す。また、マップサイズ 3×3 の SOM の結果である表 2 の各ユニットにクラスタリングされたデータが、マップサイズ 7×7 の SOM ではどのようにクラスタリングされたかを追跡した結果を表 8 に示す。さらに表 3 のような各ユニットの P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の電極分布における相対値の平均値と標準偏差を表 9 に示す。

9. 考察 2

まず、マップサイズを 2 倍以上に大きくしても、なお多くのデータ数がクラスタリングされた 8 つのユニットについて考察する。図 9 a および表 9 の結果から、ユニット 8 とユニット 11 には、その他のユニットと比べてより脳の活動状態が活発である精神状態がクラスタリングされていることが判る。そして、表 7 の結果から、このことは裏付けられている。さらに表 8 よりこれら 2 つのユニットにクラスタリングされたデータ群は、ほぼすべてマップサイズ 3×3 の SOM ではユニット 8 にクラスタリングされており、いわゆるストレス状態と見なされたデータ群である。ユニット 8 とユニット 11 の結果は、マップサイズを大きくするとデータ群をさらに 2 段階に詳しく分類でき、脳の活動状態のレベルの違いをより正確に知ることができることを示している。ユニット 15 のデータ群は表 8 より、大部分をマップサイズ 3×3 のユニット 2 から引き継ぎ (76 個中 71 個)、残りはユニット 3 とユニット 5 というユニット 2 の近傍から引き継いでいることが判る。そのため、図 9 b の電極分布の形も図 6 のユニット 2 の形と類似し、また表 9 における平均値も表 3 のそれらとほぼ同等である。このことから、ユニット 15 は 3×3 のユニットの本質的な特徴を多く引き継いでいると言える。ユニット 18 のデータ群は表 8 より、81 個中 56 個を 3×3 のユニット 5、21 個をユニット 2 から、残り 4 個をユニット 3 から引き継いでいることが判る。ユニット 15 に比べて 3×3 のユニット 5 の割合が多くユニット 2 の割合が少ないため、図 9 b および表 9 に示されるようにユニット 18 はユニット 15 よりは若干低値である。ユニット 22 のデータ群は表 8 より、ほぼすべて (73 個中 71 個) を 3×3 のユニット 5 から引き継いでおり、その点ユニット 18 と似ているが、表 9 では P_α/P_β の平均値がユニット 18 より低値であり、その点は図 9 b にも伺える。ユニット 18 とユニット 22 のこの違いの原因は、表 7 より各ユニットの精神状態の構成

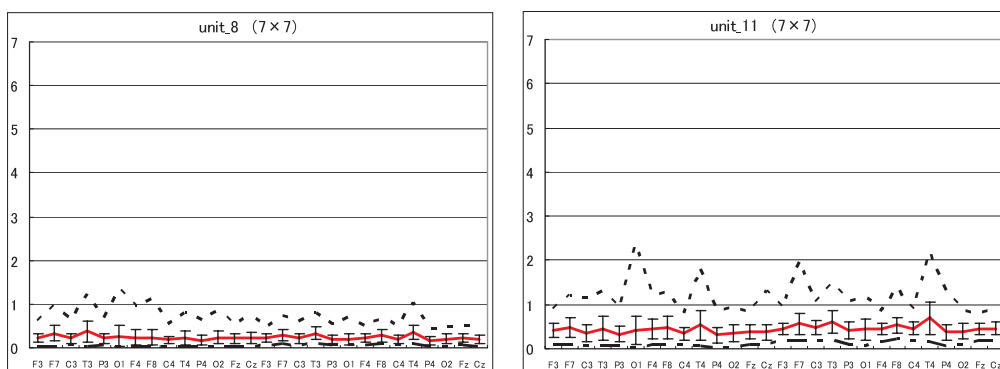


図 9 a SOM (7×7) の出力結果 (Unit 8、11) : 各グラフにおいて、横軸はデータ収集電極を表し、グラフ中心を境にして左側が P_α/P_β 、右側が $\sqrt{P_\alpha^2+P_\beta^2}$ に対応する。電極はそれぞれ左右の電極ごとにまとめて、F₃、F₇、C₃、T₃、P₃、O₁、F₄、F₈、C₄、T₄、P₄、O₂、F_z、C_z で表示している。縦軸は、安静閉眼時の平均値を 1 としたそれぞれの値の相対値を表している。実線は平均値の分布、破線は最大値の分布、また一点破線は最小値の分布を表す。縦の誤差範囲は標準偏差を示す。

の違いにあると類推できる。ユニット33のデータ群は表 8 より、108個中97個を 3×3 のユニット 5 から、残り11個をユニット 8 から引き継いでいることが判る。表 9 に示されるように、ユニット22と比べて P_α/P_β の平均値は若干高値だが、 $\sqrt{P_\alpha^2 + P_\beta^2}$ の平均値は 8 割以下と低値である。この結果は、表 7 においてユニット22と比べて MeArth 状態が多いことから裏付けられ、図 9 b でも伺える。ユニット34のデータ群は表 8 より、129個中75個を 3×3 のユニット 5、54個をユニット 8 から引き継いでいることが判る。ユニット34は、 3×3 のユニット 5 から多くのデー

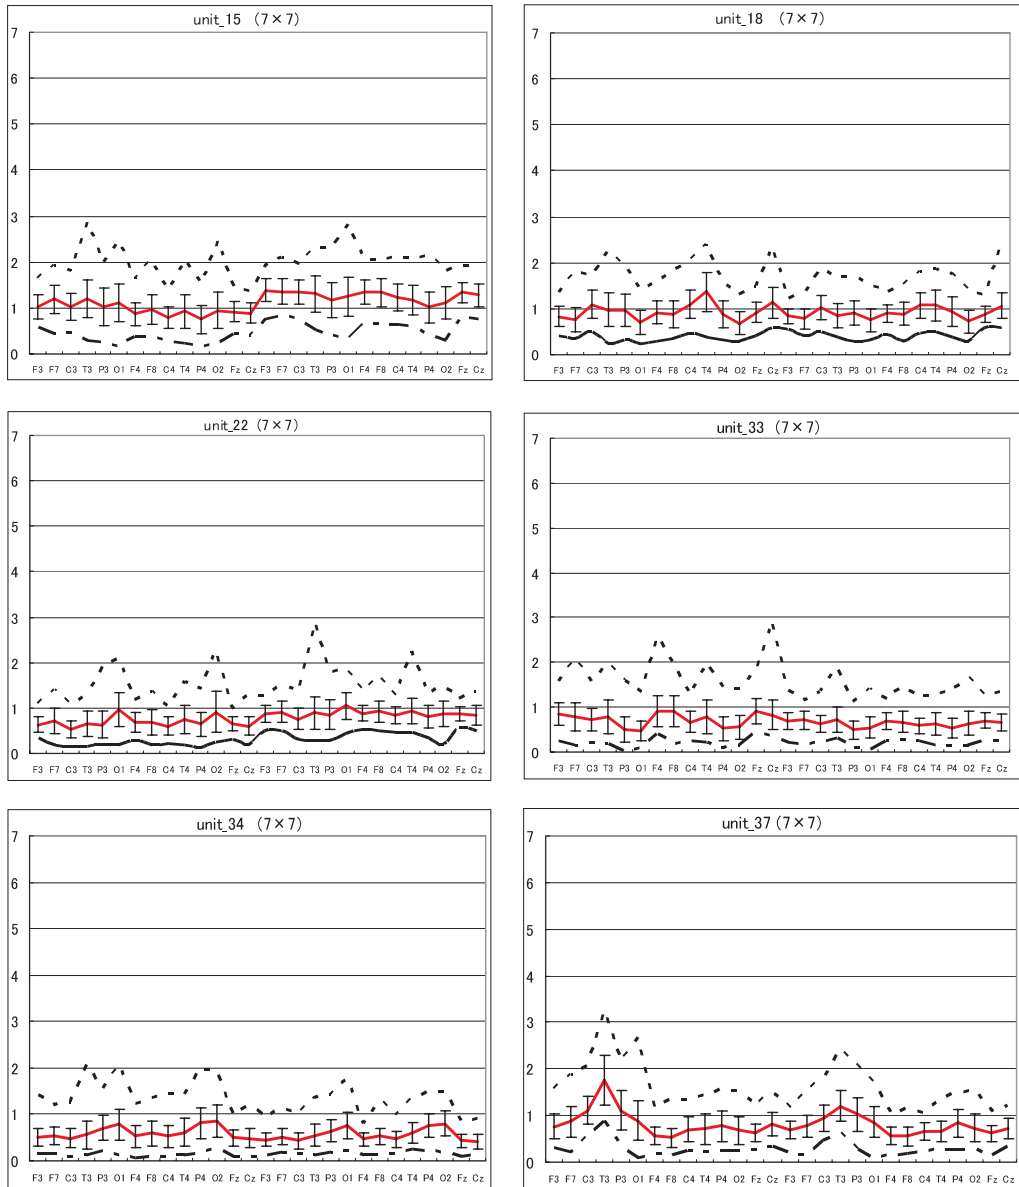


図 9 b SOM(7×7)の出力結果 (Unit 15、18、22、33、34、37) : 各グラフ横軸と縦軸は図 9 a と同様である。実線は平均値の分布、破線は最大値の分布、また一点破線は最小値の分布を表す。縦の誤差範囲は標準偏差を示す。

表8 マップサイズの変更に伴うクラスタリングされるデータ数の変化：表中の数字は7×7におけるユニットラベルを示し、括弧内の数字は7×7のユニットラベルにおけるデータ数を示す(70個程度以上のデータ数がクラスタリングされた箇所は網掛けをしている)

Unit 1	Unit 2	Unit 3	Unit 4	Unit 5	Unit 6	Unit 7	Unit 8	Unit 9	
3 (1)	3 (7)	10 (24)	6 (1)	1 (2)	2 (6)	1 (22)	8 (98)	5 (7)	
12 (4)	4 (8)	13 (11)	7 (3)		9 (2)	2 (1)	11 (148)	6 (6)	
35 (6)	10 (5)	15 (3)		4 (17)	12 (5)	3 (14)	19 (2)	10 (4)	
	12 (3)	16 (31)		11 (1)	17 (1)	9 (21)	32 (53)	13 (5)	
	15 (71)	18 (4)		15 (2)	21 (8)	10 (1)	33 (11)	14 (3)	
	18 (21)	19 (1)		16 (21)	26 (1)	17 (12)	34 (54)	20 (7)	
	20 (1)	20 (4)		18 (56)	27 (1)	20 (3)		21 (1)	
	24 (24)	22 (2)		19 (27)	38 (4)	24 (6)		25 (7)	
	25 (6)	23 (30)		22 (71)	41 (6)	26 (20)		28 (12)	
	29 (14)	25 (21)		23 (12)	42 (16)	27 (4)		38 (1)	
	30 (25)	28 (3)		29 (27)	47 (7)	29 (15)		47 (4)	
	36 (36)	29 (1)		31 (1)	48 (7)	38 (12)		48 (3)	
	37 (8)	31 (27)		32 (6)		39 (4)		49 (21)	
	38 (20)	36 (6)		33 (97)		40 (19)			
	40 (4)	37 (5)		34 (75)		44 (4)			
	41 (1)	40 (1)		37 (55)		46 (12)			
	43 (1)	43 (35)		39 (2)		48 (1)			
	46 (24)	44 (9)		40 (5)					
	47 (2)	45 (10)		43 (6)					
	49 (1)			44 (2)					
				45 (38)					
合計	(11)	(282)	(228)	(4)	(523)	(64)	(171)	(366)	(81)

タを引き継いでいるユニット18、22、33と比べると表9における平均値がより低値である。このことは図9bにも伺える。この結果は、3×3のSOMにおいてストレス状態が多くクラスタリングされたユニット8のデータ群を比較的多く引き継いでいるためであろうと類推される。ただし、表7の精神状態の構成を見ると、ユニット34ではいわゆるストレス状態の比率は非常に少なく、音楽を聴いている状態の比率が高い、すなわち、3×3のユニット8から引き継いだデータ群の中に、いわゆるストレス状態と見なしたデータが少なかったということを示している。このことは、マップサイズを大きくすることで、ストレス状態とそうでない状態のデータが分離されたことを意味する。最後のユニット37のデータ群は表8より、68個中55を3×3のユニット5から、残りをユニット2(8個)とユニット3(5個)から引き継いでいることが判る。このユニットは表9の結果からはあまり特徴的なものはないが、図9bからは左のC₃およびT₃電極の P_{α}/P_{β} および $\sqrt{P_{\alpha}^2+P_{\beta}^2}$ の相対値がその他の電極よりも高いという、特徴的な形をしている。また表7より、精神状態の構成ではMusc状態が多く、音楽を聴いている状態の中でこのような特定の左の脳領域の活動状態がその他の領域に比べて活性でなくなるという状態が、マップサイズを大きくすることで見出された。

表9 表6の各ユニットに対応した P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ の電極分布における相対値の平均値(上段)と標準偏差(下段)

1.115	1.484	1.341	0.578	1.985	2.065	3.354
0.568	0.577	0.740	0.335	0.945	1.044	2.359
0.238	1.416	1.257	0.404	1.767	1.407	2.176
0.165	0.841	0.683	0.230	0.964	0.893	1.419
0.975	0.882	1.611	0.942	0.873	1.596	2.479
0.346	0.368	0.881	0.350	0.575	0.734	1.085
0.690	0.792	1.333	1.231	1.542	1.987	1.220
0.294	0.473	0.489	0.533	0.743	1.246	0.579
1.116	1.286	0.866	0.358	0.731	0.607	3.031
0.398	0.617	0.453	0.200	0.335	0.289	1.789
1.310	0.849	1.340	1.269	1.227	1.545	2.176
0.493	0.441	0.496	0.657	0.569	0.750	1.222
1.082	1.232	0.777	1.005	1.797	1.984	1.623
0.522	0.694	0.469	0.457	0.801	1.025	0.594

(P_α/P_β)

1.078	1.806	1.093	1.097	1.788	1.860	1.718
0.456	0.745	0.487	0.555	0.902	0.793	0.886
0.234	1.131	1.135	0.486	1.804	1.266	1.344
0.130	0.523	0.436	0.217	0.657	0.648	0.498
1.263	0.922	1.208	0.906	0.641	1.331	2.231
0.329	0.419	0.487	0.277	0.264	0.427	0.696
0.878	0.787	1.123	1.216	1.132	1.539	1.910
0.256	0.448	0.333	0.446	0.459	0.888	0.727
0.849	1.137	1.185	0.784	0.637	0.558	1.750
0.249	0.482	0.638	0.342	0.225	0.244	0.747
1.242	0.776	1.588	0.597	0.803	2.288	1.396
0.406	0.311	0.428	0.216	0.292	0.843	0.733
0.844	0.731	0.688	1.101	1.327	1.426	1.754
0.315	0.308	0.361	0.390	0.412	0.550	0.547

$(\sqrt{P_\alpha^2+P_\beta^2})$

このようにマップサイズを大きくすることの有用性は高いことが明らかになった。3×3のSOMではいわゆるストレス状態の大部分がクラスタリングされたユニット8は、表8の結果を見ると7×7ではデータ数から大きく5つの精神状態(ユニット8、11、32、33、34)に細分類されることが伺える。また3×3のユニット5もデータ数から大きく5つの精神状態(ユニット18、22、33、34、37)に細分類されそうである。そして、精神的に無理強いをさせられている、すなわち本当にストレスを感じているような状態、もしくは脳が一生懸命に活動している状態はユニット8と11にありそうである。

一見、最初から大きいマップサイズでSOMをやれば、手間が省けそうであるが、今回行ったように小さいサイズでまずSOMを行い、次に大きなサイズでSOMを行うようにすると、大きなサイズのSOMのみでは判らない各ユニット間の関連性のようなものが見えてくる(図10)。すなわち、まず小さなサイズSOMを行うことで脳の活動状態の大まかな分類ができる。次に、大きなサイズのSOMの結果各ユニットにクラスタリングされたデータ群が、小さなサイズのSOMのどのユニットにクラスタリングされていたかをトレースすることにより、2つのSOMの結果を結び付けることができる。こうすることで、大まかな脳の活動状態を細分化することができる。今回、かなり特異なデータ群であったマップサイズ3×3のユニット1のデータ群は、7×7では、ユニット3、12、35にクラスタリングされた。この結果から、特異なデータ群もさらにその脳活動のレベルによって細分類されることにより、より詳しい知見が得られることが予想される。ただし、図10に示されるように、3×3においては特異なデータ群とは違って分類されたデータ群が、7×7では同じデータ群に分類されているケースもある。こうなると、クラスタリング結果に関して、どちらのマップサイズの結果が正しいのか判断しなければならない事態となり、マップサイズの拡大のその有用性の判断は単純にはいかないことが示唆された。

(7×7)	(3×3)
ユニット8	← ユニット8 (98)
ユニット11	← ユニット8 (149)、ユニット5 (1)
ユニット15	← ユニット2 (71)、ユニット3 (3)、ユニット (2)
ユニット18	← ユニット2 (21)、ユニット3 (4)、ユニット5 (56)
ユニット22	← ユニット3 (2)、ユニット5 (71)
ユニット33	← ユニット5 (97)、ユニット8 (11)
ユニット34	← ユニット5 (75)、ユニット8 (54)
ユニット37	← ユニット2 (8)、ユニット3 (5)、ユニット5 (55)
<hr/>	
ユニット32	← ユニット8 (53)、ユニット5 (6)
ユニット3	← <u>ユニット1 (1)</u> 、ユニット2 (7)、ユニット7 (14)
ユニット12	← <u>ユニット1 (4)</u> 、ユニット2 (3)、ユニット6 (5)
ユニット35	← <u>ユニット1 (6)</u>

図10 マップサイズ間のユニットの関係(7×7対3×3)

10. まとめ

今回、我々は、脳波データから精神状態を推定・分類するという目標を実現するために、EEGの α 波成分と β 波成分を用いたデータに自己組織化マップ self-organizing (feature) map : SOM を適用する手法を提案した。そして、この手法の有用性を検討するため preliminary な実験を行った。実験において推定すべき5種類の精神状態(安静閉眼状態、聴曲状態、お気に入りの箇所を聴いている状態、12種類の色を思い出している状態、暗算状態)を設定した。EEGは、ボランティア学生を被験者(19~20歳)として、国際脳波学会連合標準電極配置法 ten-twenty electrode system により、前額部の電極 Fp₁、Fp₂を除外した F₃、F₄、F₇、F₈、C₃、C₄、T₃、T₄、P₃、P₄、O₁、O₂、F_z、C_zの14電極から収集した。収集したEEGにEEGマッピングソフト KISSEI COMTEC 製 ATAMAP-II による周波数解析を適用し、 α 波帯域(8-13Hz)および β 波帯域(13-30Hz)のパワースペクトルを取り出した。これらのパワースペクトルを元に、 α 波帯域および β 波帯域のパワースペクトルの比： P_α/P_β および α 波帯域、および β 波帯域のパワースペクトルの2乗和の平方根： $\sqrt{P_\alpha^2+P_\beta^2}$ の対データが14電極分得られる。このとき、 P_α/P_β および $\sqrt{P_\alpha^2+P_\beta^2}$ は安静閉眼時の平均値を基準値に正規化された相対値を用いた。このような対データから、SOMに対して28次元のベクトルを入力した。ただし、SOMへの入力ベクトルの要素は、0~1の範囲に正規化されている必要があるので、SOMの稼働に際しては、入力ベクトルの再正規化を行っている。結局、SOMは入力ベクトルごとの電極分布の違いをクラスタリングしているのであり、その結果として、マップサイズに対応することになるさまざまな精神状態に由来する脳の活性状態が出現することになる。なお、SOMのクラスタリングに際しては、SOMの学習用として5人の被験者データを、またテスト用として2人の被験者データを使用した。さらに、SOMのマップサイズとして3×3および7×7を設定し、マップサイズの違いによるクラスタリング状況の変遷を追跡した。

実験の結果、マップサイズ3×3において、今回導入したEEGデータに関する2つの量を用いたSOMは、精神状態の違いに由来する脳活動状態の違いを正しく分類し、またSOMが出力するマップ上のどのユニットに属したかが判れば、与えられたEEGデータがどのような精神状態で得られたものであるかを推定できる可能性が見い出された。また、マップサイズ7×7のSOMのクラスタリング結果より、マップサイズを大きくすることの有用性が明示された。すなわち、まず小さなサイズSOMを行うことで脳の活動状態の大まかな分類ができる。次に、大きなサイズのSOMの結果各ユニットにクラスタリングされたデータ群が、小さなサイズのSOMのどのユニットにクラスタリングされていたかをトレースすることにより、2つのSOMの結果を結び付けることができる。こうすることで、大まかな脳の活動状態を細分化することができる。ただし、その有用性の判断は単純にはいかないことも示唆された。

また、マップサイズを大きくすることで、多くの精神状態に由来する脳の活動状態を分類・推定できることが判ったが、SOM自身は単に入力されるさまざまな精神状態下のデータを機械的にクラスタリングだけである。このため、クラスタリングされた個々の精神状態を説明する作業が残っている。今回のように、5種類の精神状態であるとの情報しか持ち合わせていない条件では、大きなマップサイズにおいて得られた個々のユニットの電極分布の形を元にすべての精神状態を分類・推定していくことは、不可能である。したがって、このような実験を行う場合には、実験対象として因果律を明確にできるものが望ましい。そのためには、対象とする精神状態を精選し、厳密に精神状態の情報を把握して実験できる、より精密な実験モデルの適用が不可欠である。またSOMへ入力使用するデータ数を精神状態間で均等化することも重要と思われる(今回使用したデータ数は、精神状態ごとに大きく異なり、このデータ数の違いがクラスタリング結果

へ影響している可能性もある)。

今回、行った実験はマップサイズ 7×7 におけるテスト用データの結果に対する検討が欠落しており、未だ不十分である。直ちに検討を行う予定である。さらに今回、我々はSOM稼働に際して α 波成分と β 波成分を用いた2つの量を用いた28次元ベクトルを使用したが、単純に θ 波成分、 α 波成分、 β 波成分のパワースペクトルを安静閉眼時に対して相対化した量を用いた $3 \times 14 = 42$ 次元ベクトルを使用した場合との比較はどうかなど、まだまだ検討すべき課題は多い。

また、紙面の都合上、マップサイズ 7×7 のSOMにクラスタリングされた電極分布のすべてを提示していないが、このマップサイズの各ユニットにおける電極分布は、当然ながらそれぞれ異なった形をしている。このことは、14電極それぞれにおける異なった活動状態が分類されたことを意味しており、今後、この活動状態について、時系列的により精密な追跡などを行うことにより、近年話題になっている脳の高次機能に関する研究分野²⁾へ、EEGデータからのアプローチを試みることもできるかもしれないと考えている。今後の課題である。

謝辞：授業や実習など忙しい日課にもかかわらず、我々の研究に快く協力していただいたボランティア学生諸君に心より感謝いたします。

参考文献

- 1) 森田尚亨、柳瀬香南：在学生の脳と心を調べる、高知学園短期大学紀要、第33号、pp.83-92、(2002)
- 2) 武田常広：電子情報通信レクチャーシリーズD-24 脳工学、p.181、コロナ社、東京、2003
- 3) メディカルシステム研修所：最新脳波標準テキスト、p.14、東京、2001
- 4) 大熊輝雄：臨床脳波学 第5版、pp77-102、医学書院、東京、1999
- 5) 緒方茂樹、谷口あづさ、古閑永之助：音楽鑑賞と脳波、臨床脳波28(8) 548-553、1986：8
- 6) 緒方茂樹：音楽鑑賞時の脳波変動，脳波と筋電図17(1)：20-28、1989
- 7) 住谷正夫、安久正統：K.L展開を用いた聴覚ストレス時の α 波パターンの特徴抽出、電子情報通信学会論文誌D-2、vol.J80-D-2、no.9、pp.2556-2564、1997
- 8) A. Hiraiwa, K. Simohara and Y. Tokunaga : EEG topography recognition by neural networks, IEEE Engineering in Medicine and Biology, vol. 9, no. 3, pp. 39-42, 1990
- 9) J. R. Walpow, D. J. McFarland, G. W. Neat, and C. A. Forneris : An EEG-based brain-computer interface for cursor control, Electroencephalography and Clinical Neurophysiology, vol. 78, pp. 252-259, 1991
- 10) S. L. Lin, Y. J. Tsai and C. Y. Liou : Conscious mental tasks and their EEG signals, Medical & Biological Engineering & Computing, vol. 33, pp. 421-425, 1993
- 11) C. W. Anderson, S. V. Devulapalli and E. A. Stolz : EEG signal classification with differential signal representations, Neural Networks for Signal Processing V, pp. 475-483, IEEE Service Center Piscataway, NJ, 1995
- 12) 山田奨治：脳波キーボードの入力速度向上手法と評価、電子情報通信学会論文誌A、vol. J79-A、no.2、pp.329-336、1996
- 13) 福田 修、辻 敏夫、金子 真：ニューラルネットによる時系列脳波パターンの識別、電子情報通信学会論文誌D-2、vol.J80-D-2、no.7、pp.1896-1903、1997
- 14) メディカルシステム研修所：人間工学のための生体計測の基礎コース研修資料、2004
- 15) Adriaans P. and Zantinge D., Data Mining, Addison-Wesley, Reading, Mass., 1996 (山本、梅

- 村(訳) データマイニング、共立出版、東京、1998)
- 16) 森下真一、宮野 悟、発見科学とデータマイニング、共立出版、東京、2001
 - 17) 赤間世紀、データベース技術の最新動向、インターフェース、No.10、pp.108-119、2002
 - 18) T. Kohonen, The self-organizing map In : Special Issue on Neural Networks 1 : Theory and modeling, C. G. Y. Lan and B. Widrow (Eds.), Proc. IEEE. 78(9), pp. 1464-1480, 1990
 - 19) 徳高平蔵、岸田 悟、藤村喜久朗：自己組織化マップの応用－多次元情報の2次元可視化－、pp. 7 -10、海文堂、東京、1999

(2005年10月11日受付；2005年11月21日受理)

