

自己回帰モデルによる睡眠脳波時系列の分類

正員 石井 直宏[†] 正員 岩田 彰[†]
 正員 鈴村 宣夫[†] 非会員 杉本 英行^{††}

Classification of Sleeping Electroencephalogram Data by Autoregressive Model

Naohiro ISHII[†], Akira IWATA[†], Nobuo SUZUMURA[†], *Regular Members*
 and Hideyuki SUGIMOTO^{††}, *Nonmember*

あらまし 非定常な時系列は地震、音声、経済変動および生体電気活動など多くの分野で見い出される。これらの非定常な時系列から意味のある情報を抽出すること、あるいはこれらの時系列から系の状態を分類すること、及び系の状態を予測することなどの問題が生じ生じる。本論文では、これらの問題のうち非定常な時系列の分類の問題をとりあげた。具体的に非定常な時系列として睡眠脳波時系列について検討した。はじめに非定常な睡眠脳波時系列を定常部分系列に分割するようなセグメンテーション(区画化)の方法として、時系列のスペクトル誤差量とKullback情報量を導入した。このときKullback情報量がスペクトル情報を推定するための最ゆう法による適合誤差尺度、更には最ゆう法による残差のゆう度比と等価な量となることを導いた。次にこの残差のゆう度比によって一晩中の睡眠脳波の識別を行い、睡眠段階の分類づけをした。

1. ま え が き

非定常な時系列から意味のある情報を抽出すること、あるいは非定常な時系列を作り出す系の状態を推定すること、及びこれらの系の状態を予測することなどの問題が多く分野で見い出される。この種の非定常な時系列の取扱ひ方として、実際的には定常な小区間に分割し、その上で各小区間の特徴パラメータを抽出する方法やはじめに定常な時系列モデルへ適合させ、順次モデルのパラメータを適応的に変化させる方法などがある⁽¹⁾。

本論文は非定常時系列として睡眠脳波時系列^{(2),(3)}をとりあげ、非定常時系列の分類という問題をパターン識別の立場から検討した。時系列のパターン識別において、標準パターンと未知パターンの比較ができるように、非定常時系列を定常小区間に区分化することが必要である。本論文では、はじめに睡眠脳波を自己回帰モデルへ適合させ、その予測残差からBodensteinら⁽⁴⁾

によって導入されたスペクトル誤差量を導入し、適応的に定常な小区間に分類する方法論をとりあげた。又、非定常時系列の定常時系列へのセグメンテーション(区画化)と分類のためKullback情報量⁽⁵⁾を導入した。Kullback情報量は赤池らにより広くシステムの次数の推定⁽⁶⁾に役立ち、又、非線形システムの同定⁽⁷⁾に適用されてきた。又、パターン識別の特徴量の評価関数として、その有用性が調べられてきた。更に、Kullback情報量はマルコフ過程における変数変換によって、正規過程と非正規過程を結びつける不変な量として重要である⁽⁸⁾。

本論文では非定常時系列のセグメンテーションと分類のため導入したKullback情報量が板倉らによってスペクトル情報の推定のため展開させた最ゆう法による適合誤差尺度^{(9),(10)}、更に最ゆう法による予測残差のゆう度比⁽¹¹⁾と等価な量となることを明らかにした。本論文では、睡眠脳波時系列のセグメンテーションの後、区画化された定常小区間の脳波のパターンの分類のため、Kullback情報量と等価な最ゆう法による残差のゆう度比を採用した。このとき睡眠段階に特有な脳波を標準パターンとして決定し、このパターンとセグメンテーションされた区間の脳波のパターンの間で残差のゆう度比の計算を行った。一晩中の睡眠脳波時

[†]名古屋工業大学工学部情報工学科, 名古屋市
 Faculty of Engineering, Nagoya Institute of Technology,
 Nagoya-shi, 466 Japan

^{††}三菱電機計算機製作所, 鎌倉市
 Mitsubishi Electric Corp., Kamakura-shi, 247 Japan
 論文番号: 昭 53-640[D-131]

系列へ上記のセグメンテーション、次に分類の手続きを適用したところ、医師が脳波を見て一晩中の睡眠段階を判定した分類結果とはほぼ等しい結果の得られることを示した。

2. 自己回帰モデルの導入

自己回帰モデルは次のように定義される。いま時刻を表す整数の集合を $I = \{\dots, -1, 0, 1, 2, \dots\}$ とし、定常確率過程 $\{X_t, t \in I\}$ の仮定を一般性を失うことなく

$$E(X_t) = 0$$

とおく。このとき m 次の自己回帰過程は式(1)のように表現される。

$$X_t + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_m X_{t-m} = \varepsilon_t \quad (1)$$

$\{X_t\}$ が定常正規過程であれば、式(1)において $\{\varepsilon_t\}$ が独立な定常正規過程⁽¹⁾となる。ここで $\{\alpha_i\}$ は方程式(1)の係数を表す。

脳波時系列などのように準定常な時系列、すなわち短時間区間内では定常とみなされる^{(2),(3)} 時系列から特徴パラメータを抽出する必要が生じる。例えば、この短時間区間内の時系列へ自己回帰モデルを適合させ、パラメータを抽出することになる。以下に自己回帰モデルとパワースペクトル密度の関係を示す。時刻 $t = n$ の予測誤差、あるいは予測残差を e_n とすると

$$e_n = x_n - \hat{x}_n \quad (2)$$

ここで \hat{x}_n は式(1)で $x_{n-1}, x_{n-2}, \dots, x_{n-m}$ を代入したときの x_n の値、 x_n は実現値とする。式(1)を式(2)へ代入し、Z変換すると

$$E(Z) = \left(1 + \sum_{k=1}^m \alpha_k Z^{-k}\right) X(Z) \equiv A(Z)X(Z) \quad (3)$$

を得る。ここで $E(Z)$ は e_n のZ変換を表し、式(1)の ε_n は e_n に含まれるものとする。 $\{X_t\}$ のパワースペクトルを $p(\omega)$ で表すと

$$p(\omega) = |X(e^{j\omega})|^2 \quad (4)$$

で与えられる。式(4)を自己回帰モデルにより、予測誤差系列 $\{e_t\}$ が平たんなスペクトル σ^2 でモデル化する、すなわち $\{X_t\}$ が式(1)の形に理想的に適合したとする。このときのパワースペクトルを $p_1(\omega)$ とすると

$$p_1(\omega) = \frac{\sigma^2}{|A(e^{j\omega})|^2} \quad (5)$$

となる。一方、式(3)と(4)より $p(\omega)$ の実際の自己回帰モデルによるパワースペクトルは

$$p_2(\omega) = \frac{|E(e^{j\omega})|^2}{|A(e^{j\omega})|^2} \quad (6)$$

となる。式(5)と(6)とパーセバルの定理より

$$E(e_n^2) = \frac{\sigma^2}{2\pi} \int_{-\pi}^{\pi} \frac{p_2(\omega)}{p_1(\omega)} d\omega \quad (7)$$

が成立する。

(A) スペクトル誤差量によるセグメンテーション

二つの定常な信号(定常な小区間)の相違を区分するため、理想的な自己回帰モデルの誤差系列によるパワースペクトルと式(7)の実際の誤差系列のパワースペクトルの差分を評価関数として、次式のように与える⁽⁴⁾。

$$\frac{1}{2\pi} \int_{-\pi}^{\pi} \left(1 - \frac{p_2(\omega)}{p_1(\omega)}\right)^2 d\omega = \frac{1}{2\pi} \int_{-\pi}^{\pi} \left(1 - \frac{E(e^{j\omega})^2}{\sigma_m^2}\right)^2 d\omega \quad (8)$$

ここで $p_1(\omega)$ と $p_2(\omega)$ はそれぞれ、前の区間のパワースペクトルと後の区間のパワースペクトルを表す。 σ_m は、前の区間のパワースペクトルを $p_1(\omega)$ によってモデル化したときの誤差系列の標準偏差である。又、 $p_2(\omega)/p_1(\omega)$ は $p_2(\omega)$ に $p_1(\omega)$ の最適な自己回帰モデルを適用したときの誤差のパワースペクトルの度合いを表していると解釈できる。 $p_2(\omega)/p_1(\omega)$ を共分散関数で書換えると

$$\frac{p_2(\omega)}{p_1(\omega)} \cdot \sigma_m^2 = r_0 + 2 \sum_{K=1}^m r_K \cos(\omega K) \quad (9)$$

ここで $\{r_K\}$ ($K=0, 1, \dots, m$) は $E(e^{j\omega})$ の方の共分散関数である。式(8)に式(9)を代入し、三角関数の直交性を用いると式(8)の積分の値は

$$(\sigma_m^2 - r_0)^2 + 2 \sum_{K=1}^m r_K^2 \quad (10)$$

となる。式(10)の第1項は前の区間の理想的な平たんなパワースペクトルの総量と後の区間のモデル適合による実際的なパワースペクトルの総量の差分の変化分を表す。式(10)の第2項は上述の各々のスペクトルの間の形の変化を表す。式(10)を r_0^2 で正規化するとスペクトル誤差量⁽⁴⁾

$$\left(\frac{\sigma_m^2}{r_0} - 1\right)^2 + 2 \sum_{K=1}^m \left(\frac{r_K}{r_0}\right)^2 \quad (11)$$

が定義できる。スペクトル誤差量の式(11)の導入は、もともと式(5)と式(6)から出発したものであって、その結果、誤差系列が平たんなスペクトル σ^2 を規準パターンとして、以下に続く時系列の誤差系のスペクトルの変化を表現している。従って式(9)のような、以下に続く誤差系列のパワースペクトルの計算という単純化した評価関数となる。しかし式(7)より、現時点の手前の誤差系列がホワイトノイズと考えることは、以後に続く系列のスペクトルの変化を一律な重みづけで計算して

いることと等しい。すなわち現時点の以前の時系列のどの周波数帯域の変化が後の時系列で大きいとか小さいという立場ならば、ホワイトノイズというモデルと違ったものを考えなければならない。そこで本論文で、新たにKullback 情報量によるセグメンテーションを導入した。

(B) Kullback 情報量によるセグメンテーションと分類

Kullback 情報量は、二つの密度関数の差を測る尺度として研究されてきた。又、この情報量はシステム同定の際の自己回帰モデルの次数の推定やパターン認識の特徴量の評価関数として適用されてきた。

Kullback 情報量 $I(1:2)$ は対象とするクラス1とクラス2の密度関数を各々 $f_1(x_1, x_2, \dots, x_K)$ 及び $f_2(x_1, x_2, \dots, x_K)$ とおくと、

$$I(1:2) = \int f_1(x_1, \dots, x_K) \log \frac{f_1(x_1, \dots, x_K)}{f_2(x_1, \dots, x_K)} dx_1 dx_2 \dots dx_K$$

で与えられる⁽⁵⁾。密度関数の各々が正規密度関数 $N(\mu_1, \Sigma_1)$ と $N(\mu_2, \Sigma_2)$ で与えられるとき

$$I(1:2) = \frac{1}{2} \log \frac{|\Sigma_2|}{|\Sigma_1|} + \frac{1}{2} \text{tr} \Sigma_1 (\Sigma_2^{-1} - \Sigma_1^{-1}) + \frac{1}{2} \text{tr} \Sigma_2^{-1} (\mu_1 - \mu_2)(\mu_1 - \mu_2)^t \quad (12)$$

となる。ここで μ_j, Σ_j は各々サンプル長 T 次元ベクトル $\mu_j = [\mu_j(0), \dots, \mu_j(T-1)]$

及び共分散

$$\Sigma_j = \{\sigma_j(s-t), s, t=0, 1, 2, \dots, T-1\}$$

を表す。ここでサンプル長 T が十分大のとき、

$$\log |\Sigma_j| = \int_{-\pi}^{\pi} \log p_j(\omega) \frac{d\omega}{2\pi}$$

の関係を⁽²⁾式(12)へ代入すると

$$I(1:2) = \frac{1}{2} \int_{-\pi}^{\pi} \left(\frac{p_1(\omega)}{p_2(\omega)} - \log \frac{p_1(\omega)}{p_2(\omega)} - 1 \right) \frac{d\omega}{2\pi} + \frac{1}{2} \int_{-\pi}^{\pi} \frac{|D(\omega)|^2}{p_2(\omega)} \frac{d\omega}{2\pi} \quad (13)$$

となる⁽²⁾。ここで

$$D(\omega) = \int_{-\infty}^{\infty} \delta(t) e^{-j\omega t} dt, \quad \delta(t) = \mu_1(t) - \mu_2(t)$$

ここで $\mu_1(t)$ 及び $\mu_2(t)$ は平均値関数であり、脳波時系列などのように直流成分は観測せず、交流成分だけに意味がある場合、すなわち

$$\delta(t) = 0$$

のとき、Kullback 情報量 $I(1:2)$ は次式で与えられ

$$I(1:2) = \frac{1}{2} \int_{-\pi}^{\pi} \left(\frac{p_1(\omega)}{p_2(\omega)} - \log \frac{p_1(\omega)}{p_2(\omega)} - 1 \right) \frac{d\omega}{2\pi} \quad (14)$$

となる。ここで時系列が非定常な正規過程とみなすとき、

$$V(\omega) = \log \left\{ \frac{|E_1(e^{j\omega})|^2}{|A_1(e^{j\omega})|^2} \right\} - \log \left\{ \frac{|E_2(e^{j\omega})|^2}{|A_2(e^{j\omega})|^2} \right\} \quad (15)$$

とおくと

$$I(1:2) = \frac{1}{2} \int_{-\pi}^{\pi} (e^{V(\omega)} - V(\omega) - 1) \frac{d\omega}{2\pi} \quad (16)$$

となり、この式は自己回帰モデルの最ゆう法による適合誤差尺度⁽⁹⁾と等価である。ここで

$$\int_{-\pi}^{\pi} V(\omega) \frac{d\omega}{2\pi} = \int_{-\pi}^{\pi} \log \frac{|E_1(e^{j\omega})|^2}{|E_2(e^{j\omega})|^2} \cdot \frac{d\omega}{2\pi}$$

が成立する⁽¹⁰⁾ことから、

$$I(1:2) = \frac{1}{2} \left\{ \int_{-\pi}^{\pi} \frac{|E_1(e^{j\omega})|^2}{|E_2(e^{j\omega})|^2} \cdot \frac{|A_2(e^{j\omega})|^2}{|A_1(e^{j\omega})|^2} \frac{d\omega}{2\pi} - \int_{-\pi}^{\pi} \log \frac{|E_1(e^{j\omega})|^2}{|E_2(e^{j\omega})|^2} \cdot \frac{d\omega}{2\pi} - 1 \right\} \quad (17)$$

いま、ここで誤差系列のスペクトル $|E_j(e^{j\omega})|^2$ が脳波時系列などの小区間では定常正規過程とみなされる^{(2),(3)}ことから、平たんなスペクトルと解釈できる。すなわち

$$|E_j(e^{j\omega})|^2 = \sigma_j^2 \quad (18)$$

とおくことによりKullback 情報量 $I(1:2)$ は式(19)のように簡単化される。

$$I(1:2) = \frac{1}{2} \left\{ \left(\frac{\sigma_1}{\sigma_2} \right)^2 \int_{-\pi}^{\pi} \frac{|A_2(e^{j\omega})|^2}{|A_1(e^{j\omega})|^2} \cdot \frac{d\omega}{2\pi} - \log \left(\frac{\sigma_1}{\sigma_2} \right)^2 - 1 \right\} \quad (19)$$

式(19)の被積分関数の Z 変換の関係式⁽¹⁰⁾

$$|A_2(z)|^2 = |A_2(z) - A_1(z)|^2 + |A_1(z)|^2$$

より $I(1:2)$ は

$$I(1:2) = \frac{1}{2} \left\{ \left(\frac{\sigma_1}{\sigma_2} \right)^2 \left[1 + \int_{-\pi}^{\pi} \frac{|A_2(e^{j\omega}) - A_1(e^{j\omega})|^2}{|A_1(e^{j\omega})|^2} \cdot \frac{d\omega}{2\pi} \right] - \log \left(\frac{\sigma_1}{\sigma_2} \right)^2 - 1 \right\} \quad (20)$$

となる。

式(16)の右辺は適合度のパラメータ $d = \log(p_1(\omega)/p_2(\omega))$ の関数として調べると d の正、および負の値に対し、非対称性のスペクトルの適合度誤差尺度となることが示されている^{(9),(10)}。しかし誤差の尺度としては d に関して対称性のスペクトル尺度が望ましい。Kullback 情報量では $p_1(\omega)$ と $p_2(\omega)$ を置換えた $I(2:1)$ も $I(1:2)$ と同様に定義できる。そこで $I(1:2)$ と $I(2:1)$ を加えたDivergence⁽⁵⁾ $J(1:2)$ が次式で定義できる。

$$J(1:2) = I(1:2) + I(2:1) \quad (21)$$

$J(1:2)$ は d の正および負の値に対し、対称性のあ

る。スペクトル適合度となるのがCosh尺度¹⁰⁾と同様に示される。

一方、自己回帰モデルにおいて最尤法による予測誤差が最小となるようにパラメータを推定する。このとき、二つの区間の各々の予測誤差のゆう度比を計算すると

$$\frac{\delta}{\alpha} = 1 + \int_{-\pi}^{\pi} \frac{|A_2(e^{j\omega}) - A_1(e^{j\omega})|^2}{|A_1(e^{j\omega})|^2} \cdot \frac{d\omega}{2\pi} \quad (22)$$

が得られる¹⁰⁾。ここで

$$\delta = \sum_{n=-M}^M r_{2a}(n) r_{1x}(n)$$

$$\alpha = \sum_{n=-M}^M r_{1a}(n) r_{1x}(n)$$

となる。 $\{r_{ia}(n)\}$ は*i*区間の時系列に対する自己回帰モデルの係数の自己相関係数列であり、 $\{r_{ix}(n)\}$ は*i*区間の時系列の自己相関係数列である。式(22)で $\sigma_1 = \sigma_2$ のとき

$$I(1:2) = \frac{1}{2} \int_{-\pi}^{\pi} \frac{|A_2(e^{j\omega}) - A_1(e^{j\omega})|^2}{|A_1(e^{j\omega})|^2} \cdot \frac{d\omega}{2\pi} = \frac{1}{2} \left(\frac{\delta}{\alpha} - 1 \right) \quad (23)$$

となる。すなわちKullback情報量は式(22)の予測残差のゆう度比と等価な量となる。ここで述べたKullback情報量は時系列のセグメンテーションと分類へ適用できる。

3 自己回帰モデルの睡眠脳波時系列への適用

睡眠脳波時系列へ自己回帰モデルを適用し、睡眠の深さの段階の分類を脳波パターンの認識によって行う。このとき睡眠脳波パターンの認識の手順は次のようになる。

(1) 一晩中の睡眠脳波データに対し、本論文では、はじめにスペクトル誤差量を用いたセグメンテーションを行う。

(2) 区画化された睡眠脳波データから、その人の典型的脳波の脳波パターンの選択を行う。

(3) (2)の波形パターンの各々のスペクトル特徴量(本論文では自己回帰モデルの回帰係数)の抽出。

(4) (1)の区画化されたパターンと(2)の典型的なパターンとの間のKullack情報量、ここでは式(22)の左辺 δ/α の計算を行う。

(5) 区画化された未知パターンが(4)の計算の結果、最も典型的な脳波パターンに近いものと、その未知パターンの波形の持続時間によって睡眠段階を分類する。

そこで本章では、はじめの(1)について検討する。非定常な脳波を定常な脳波に区分するためのセグメンテ

ーションのパラメータを決定しなければならない。パラメータとして次の(a),(b),(c)及び(d)がある。

(a) スペクトル誤差量の計算のために、幾つかのデータ、ここではフレームの長さから誤差系列の自己相関関数を計算しなければならない。フレームの長さは正確な区画化を行うためには、できるだけ短い方が好ましいが、自己相関関数の信頼できる推定値を得るためには長い方がよい。実際には脳波の波形パターンのうちで短いパターンである紡錘波の長さ程度にするのが適当と思われる。脳波は20msのサンプリング間隔だから、フレームの長さ(データ個数) $N=100 \sim 150$ 、すなわち2秒から3秒がよい。^{(2),(3)}

(b) 自己回帰モデルの次数は重要なパラメータである。次数が高くなると計算量も多くなり、次数は少ない方がよいが、通常脳波のスペクトルは典型的な4個の周波数が存在するから、少なくとも2倍はとる方がよい。すなわち、次数が8以上である⁽⁴⁾。

(c) スペクトル誤差量があるしきい値(θ_1)以上を越えると区画化することであるが、本論文では、もう一つのしきい値(θ_2)を導入する。 θ_2 はスペクトルの変化に対する区画化の遅れを是正するために設けられたものである。 θ_1 より大きな値をとった時点、 $t=n$ より前に $t=n-1, n-2, \dots$ と以前の値を調べて行き、最初に θ_2 を越えた時点で、既に変化が現れはじめているという意味で区画化する。それ故、 θ_1 と θ_2 は小さくとれば、精密な区画化ができるが区画の数が増加する。 θ_1 は0.4~0.5、 θ_2 は0.1~0.3の値とした。

以上のパラメータを決定する第1段階として、シミュレーションにより調べた。データは一樣乱数の雑音の中に周波数と振幅と位相の異なった正弦波が断続的に現れるものを作った。

図1にシミュレーションの波形のセグメンテーション




図1 シミュレーション波形によるセグメンテーションの例

Fig.1-Example of segmentations of the simulated data.

ンの例を示す。最初に設定するフレームのデータ個数 $N=100$ ，自己回帰モデルの次数 $p=10$ ，誤差系列の相関関数の次数 $M=8$ ，スペクトル誤差量のしきい値 $\theta_1=0.4$ である。図1の(a)はスペクトル誤差量の式(11)の第1項でスペクトルのパワー項の比の度合，図1の(b)は式(11)の第2項でスペクトルの形の変化を示す。図1の(c)は式(11)のスペクトル誤差量である。図1の結果は，非定常な波形を包含して区分化していることが分かる。

図2には自己回帰モデルの次数を大きくし，それに伴い誤差系列の相関関数の次数を少し増加した場合の結果を示す。図1と同じシミュレーション波形であるが， p と M の次数を増加しても必ずしも区分化の改良がみられない。

脳波による睡眠深度の段階づけのため Rechtschaffen と Kales¹³ がその判定のためのマニュアルを編成した。以下に簡単に各睡眠段階の特徴的な脳波像について説明する。

(a) Stage W この段階は目ざめの状態である。 α 波と呼ばれる10 Hz 前後の波または低電位で，さまざまな周波数の脳波が混在している。速い眼球運動の記録されることが多い。

(b) Stage 1 この段階は2～7 Hz の波が目立つ。覚醒(めざめの状態)から他の睡眠段階への移行期である。

(c) Stage 2 この段階は紡錘波 (Spindle) と呼ばれる12～14 Hz が少なくとも0.5秒間以上つづき，更に K 複合 (K -Complex) が出現することである。Stage 3 と Stage 4 の定義を満たすだけの高振幅徐波 (0.5 Hz 以上数 Hz まで) がみられないことである。

(d) Stage 3 Stage 3 は記録ページ (本論文では20秒間) の少なくとも20%以上50%以下が数 Hz 以下で75 μ V 以上の振幅の徐波で占められている脳波の状




図2 シミュレーション波形によるセグメンテーションの例

Fig. 2-Example of segmentations of the simulated data.




図3 Stage Wの脳波データのセグメンテーション
Fig. 3-Segmentations of the EEG data during sleep stage W.




図4 Stage 2の脳波データのセグメンテーション
Fig. 4-Segmentations of the EEG data during sleep stage 2.

態である。

(e) Stage 4 この段階は記録ページの50%以上が数 Hz 以下で，波のピークからピークまでの振幅が75 μ V 以上の波で占められた脳波の状態と定義される。

(f) Stage REM 比較的低電位でさまざまな周波数の脳波と散発的な速い眼球運動が出現する。脳波パターンは Stage 1 と似ているが，眼球運動に顕著な特徴がある。

次に上述の睡眠段階の例として，Stage W，Stage 2 及び Stage 3 の各段階へ，スペクトル誤差量を適用した結果を各々図3，4及び図5に示す。いずれもパラメータ $N=100$ ， $p=10$ ， $M=8$ ， $\theta_1=0.4$ 及び区分化しきい値の補正のためのパラメータ $\theta_2=0.3$ である。図3，4及び図5の(a)，(b)，(c) は式(11)の第1項，第2項，




図5 Stage 3の脳波データのセグメンテーション
Fig. 5-Segmentations of the EEG data during sleep stage 3.

および式全体を計算した結果を示す。又、Window = 2 秒間はフレームの長さ $N=100$ のことである。

図3の区画化は必ずしも視察による非定常さの区画化と一致しているとは思われないが、ほぼ波形の系列の違いを判定している。図4のStage2では、その区画化が視察によっても、大体一致していると見なすことができる。

4 睡眠段階の分類

非正常な睡眠脳波^{(2),(3)}から定常な小区間に区画化する。その上で脳波から分類上重要となる波形パターンを選び出して標準波形パターンとし、その波形のスペクトル特徴量を求める。ここではスペクトル特徴量として自己回帰モデルの係数とした。又、標準パターンとして次のような波形を選択した。

- (1) 高振幅 δ 波 ($L-\delta$)
- (2) 低振幅 δ 波 ($S-\delta$)
- (3) θ 波
- (4) Stage 1 に特徴的な波形(1)
- (5) Stage REM に特徴的な波形 (REM)
- (6) α 波 (α)
- (7) 紡錘波 (Sp)

標準波形パターンと他の区画との未知波形の Kullback 情報量, すなわち本論文では残差のゆゑ度比の式(22)により, 未知波形パターンの分類を行った. 更に図 6 に示すように脳波を 20 秒ごとにそこに含まれる①, ②及び③などの波形のパターンの種類とその波形の時間長を調べて, 識別のアルゴリズムを構成した.

図7に睡眠段階の識別のためのアルゴリズムのフローチャートを示した。このフローチャートの説明は次のようになる。はじめ α 波が存在するかどうかで大きく二つに分ける。以下に(A)と(B)で示す。

(A) $[\alpha > 0]$ の場合

このときは α 波が存在することを示す。

[$L-\delta$] の存在, すなわち高振幅の δ 波が 1 ブロック (20 秒間) 内に α 波と併存するような場合については, Stage を判定しがたいので決定できない (undetermined) とする。

〔Max〕という表示は1ブロック内で識別された波形のうち、どの波形が一番時間長として長いという意味である。 α 波の時間が長ければStageWである。Stage1かREMであればStage1（現在のところ、Stage1とREMは脳波では区別できないと考えて、Stage1とREMの脳波の区別をしていない）紡錘波




図6 脳波波形とその時間長による識別
Fig.6-Classification by the segmented EEG
and its length of data.

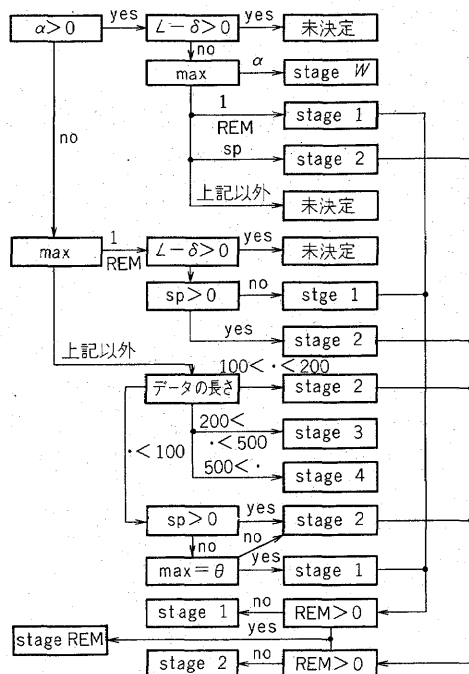


図7 睡眠段階の分類のフローチャート
Fig.7-Flow chart of classification of sleep stages.

(Sp)であればStage 2, その他の波形であれば決定できないとする。

(B) $[\alpha \leq 0]$ の場合

このときは α 波が存在しないことを示す。この次に脳波の波形で時間長で一番長いものを調べる。〔Max〕を調べ、もしStage 1, REMであれば、更に〔 $L-\delta$ 〕が存在するかを調べる。もし存在すれば、決定できないとする。存在しなければ、紡錘波 (Sp) を調べる。紡錘波があれば Stage 2, なければ Stage 1 とする。Stage 1 又は REM が〔Max〕から流れ、〔 $L-\delta$ 〕が存在する場合 (例えば hump などの波が生じた場合) も考えられるが、ここでは決定できないとしている。

(c) [Max] で Stage 1, REM 以外のとき

〔 $L-\delta$ 〕の時間長によって段階づけを行う。これが〔Length of Data〕のところである。この時点で可能

性が高いStageとしては、Stage 2, Stage 3 及び Stage 4である。これらのStageの判定の場合 Rechtschaffen, Kalesらによる高振幅の δ 波の割合が必要となる。〔 $L-\delta$ 〕の時間長がデータ数にして (1ブロック=1,000個のデータ)

・ <100 なら次のアルゴリズムへ

100 $<$ ・ <200 なら Stage 2

200 $<$ ・ <500 なら Stage 3

500 $<$ ・ なら Stage 4

更に〔 $L-\delta$ 〕の波形を識別する際にKullback 情報量だけでなく、波形の平均2乗値を参考にする。

$S-\delta$ (低振幅 δ 波) }

$L-\delta$ (高振幅 δ 波) }

と判定されたとき、波形の平均2乗値を考える。

平均2乗値 ≥ 300 なら〔 $L-\delta$ 〕

< 300 なら〔 $S-\delta$ 〕

とする。

(D) 〔 $L-\delta$ 〕がデータ数にして100より少ないとき
このときはStage 1の可能性もでてくる。紡錘波 (Sp)が存在すれば、Stage 2とする。もし θ 波の長さが〔Max〕であればStage 1とする。

(E) REMのStageの判定

本研究では脳波だけでREMの判定をしていない。脳波でStage 1又はStage 2と判定された波形のうちで眼球運動を視察によって与えておき、REM特有の速い眼球運動が存在すれば、それはStage REMであるとしている。特にこの眼球運動は、急速かつ左右同期した水平眼球運動である。

いままで述べたセグメンテーションの方法および分類のアルゴリズムが実際の一晚中の睡眠脳波時系列でいかなる結果を示すかを以下に述べる。被験者は24才の男子の終夜睡眠データである。医師は脳波データ、眼球運動および筋電図などのポリグラフと呼ばれるものから視察によって睡眠段階を判別する。そこで医師が判定した結果と上述のセグメンテーションと分類の方法によって計算機により類別した結果の比較を表1に示す。表1の縦列は医師が20秒間(1ブロック)ごとに判別した睡眠区分である。そして行が計算機による判定結果を表す。又、表1の右端の列が図7の決定できない(undetermined)個数を示したものである。表1の下の方は医師の判定を正解として、計算機の行の正解の比率を ϕ で表したものである。

表1から、計算機はStage WとStage 2の場合に高い識別率をあげている。しかし他のStageの誤分類の

表1 医師と計算機による睡眠段階の判定の比較

	W	1	2	3	4	R	
W	313	23	6	2	0	0	33
1	23	149	51	6	0	1	37
2	1	32	403	15	1	0	28
3	0	0	39	50	24	0	1
4	0	0	9	24	74	0	0
R	0	16	0	5	0	70	16
ϕ	91	65	89	44	69	77	

原因として主なものをあげると、

- (1) Stage 1をStage 2と見ていること。
- (2) Stage 3をStage 2とStage 4とみていること。
- (3) Stage 4をStage 3とみていること。

などである。

Stage 3とStage 4の分類は、両者とも高振幅 δ 波が最も多くみられる場合である。前に述べたアルゴリズムでは、この両者の区別は、その区画の δ 波の継続の時間長だけに依存している。

次に医師が睡眠段階に用いる睡眠図を図8に示す。睡眠段階の判定は、脳波は20秒ごとに、そこに含まれている波と眼球運動および筋電図から視察によって行う。図8のWは目ざめの状態、RはREMのStage, 1, 2, 3及び4は各々睡眠の深さの段階を表す。




図8 医師による睡眠段階の分類
Fig.8-Classification of sleep stages read by physician.




図9 計算機による睡眠段階の分類
Fig.9-Classification of sleep stages read by computer.

これに対し、計算機による睡眠段階の時間的経過を図9に示す。表1において、分離の困難な区画は、図9では、睡眠段階が急に変化しないという理由で、一つ手前の区画と同じ睡眠段階に属するものとして表している。この結果、医師による睡眠図と計算機による睡眠図の大まかなところは、ほぼ同じ睡眠の段階を示していることが分かる。

睡眠脳波パターンの判別は、異なる医師の視察によっても必ずしも同じ分類とはならず、20%程度の違いがあるともみなされている。従って本研究の計算機によるパターンの識別の結果は、医師による判別にほぼ近いとみなすことができよう。

5. む す び

非定常な時系列の分類の手続きとして、自動的に定常区間に区分するセグメンテーションの方式をとりあげた。まずスペクトル誤差量によるセグメンテーション、次にKullback 情報量によるセグメンテーションとパターンの分類の方法を新たに導入した。このKullback 情報量は自己回帰モデルの最尤法による残差のゆがみ比に等価であり、又、Divergence はCosh の尺度に等しいことを明らかにした。次に非定常時系列として、一晩中の睡眠脳波の時系列をとりあげ、上述の手続きを進め睡眠脳波による睡眠段階の分類を行った。その結果、本研究の計算機の結果は、医師による判別に近いとみなされることが分かった。

残された問題は局所的な非定常さの分類だけでなく、大域的な非定常さの情報を分類にいかに取り入れるかなどにある。

謝辞 本研究に関して御指導および御協力を賜った愛知県総合保健センターの富田隆雄先生に感謝致します。

文 献

- (1) 松沢, 石井, 岩田, 鈴村: “時間的に可変な時系列モデルによる適応的同定”, 信学論 (A), J61-A, 2, p. 143 (昭53-02).
- (2) Sugimoto, H., et al.: “Stationarity and normality test for biomedical data”, Computer Programs in Biomedicine, 7, p. 293 (1977).
- (3) Sugimoto, H., et al.: “On the stationarity and normality of the electroencephalographic data during sleep stages”, Computer Programs in Biomedicine, 8, p. 224 (1978).
- (4) Bodenstein, G. and Praetorius, H.M.: “Feature extraction from the electroencephalogram by adaptive segmentation”, Proc. IEEE, 65, 5, p. 642 (May 1977).
- (5) Kullback, S.: “Information theory and statistics”, John Wiley (1959).
- (6) Akaike, H.: “Information theory and an extension of the maximum likelihood principle”, Int. Symp. on Information Theory, Akademia Kiado, Budapest (1973).
- (7) 沖田, 太田, 山口: “Kullback の情報量を用いた非線形系の同一定法”, 信学論 (D), J60-D, 9, p. 655 (昭52-09).
- (8) 石井, 岩田, 鈴村: “情報量による自己回帰モデルの評価と非正規過程への適用”, 信学論 (A), J61-A, 1, p. 25 (昭53-01).
- (9) 板倉, 齊藤: “統計的手法による音声スペクトル密度とホルマント周波数の推定”, 信学論 (A), J53-A, 1, p. 35 (昭45-01).
- (10) Gray, A.H. and Markel, J.: “Distance measures for speech processing”, IEEE ASSP, 24, 5, p. 380 (1976).
- (11) Ogawara, M.: “A note on the test of serial correlation coefficients”, Annals of Math. Statistics, 22, p. 115 (1951).
- (12) Shumway, R.H. and Unger, A.N.: “Linear discriminant functions for stationary time series”, J. American Stat. Assoc., 69, 348, p. 948 (1974).
- (13) Rechtschaffen, A. and Kales, A.: “A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects”, N.I.H. Maryland (1968).

(昭和53年6月19日受付)