

## ウェーブレットの脳波解析への応用 (Application of Wavelet Method to EEG Analysis)

井上 勝裕 (Katsuhiko Inoue)  
Kyushu Institute of Technology

### 1. はじめに

脳波 (EEG) が脳内の状態によって変化することは、脳波の発見者である Berger によって 1929 年に報告され、1933 年に Adrian によって追試・確認が行われて以来、病的疾患の診断のみならず、脳のメカニズムを解明する上で興味ある研究対象として、多くの研究者によって研究が行われてきている[1]. 睡眠脳波ステージは、脳波、眼球運動図 (EOG)、筋電位図 (EMG) からの情報をもとに判読されるが、その一晚の遷移状況である睡眠パターンは、騒音等の睡眠環境の異常による外的要因や、不規則な睡眠時間、極度の疲労、病的疾患等の内的要因により乱される。従って、これを計測することにより、被験者の健康状態を知ったり、外的環境の評価が可能となる。また、最近では、選択反応時の事象関連電位の変動や、外的光刺激の周波数に応じた脳波周波数変動、動作想像時の脳波変動を検出し、手足の不自由なハンディキャップユーザのためのコンピュータや装置のインタフェースとして利用しようという BCI (Brain Computer Interface) あるいは BMI (Brain Machine Interface) と呼ばれる研究もさかんに行われている。

我々も、脳波波形パターンを識別する手法として、統計的パターン認識手法や波形形状認識手法、離散ウェーブレット変換を利用した睡眠脳波ステージ自動判定システムを構築し、有効な結果を得ており[2,3]、BCI に関しても、右手・左手動作想像時の脳波変動を検出し、AIBO をリアルタイムに操作できるシステムを構築してきている[4].

一方、ウェーブレット変換は、1982 年という比較的最近導入された信号解析技術であるが、理論面の整備や応用研究がさかんに行われており、非定常信号の解析ツールとして期待を集めている。生体信号においても、心電図や脳波の解析などに広く使われている。応用面で考えた場合、ある程度特徴量が特定できる現象に関しては、その特徴量の抽出に適した個別の手法を適用すべきであると思われるが、新しい現象を解析し、より重要な特徴量に関して検討を行いたい場合、ウェーブレット手法は、非常に便利なツールであると考えられる。

我々は、これまで、脳波から視察では抽出が困難な睡眠に関するより詳細な情報を抽出することを目的に、ウェーブレット解析手法を適用する研究や、BCI システムにおいて動作想像とシステムの操作ミスを認知した時の脳波変動を同時に検出することを目的に、通常積分変換を使用せず非線形作用素を用いるモルフォロジーフィルタを使用した多重解像度解析手法に関する研究を進めてきており[5]、本稿では、これらの手法について紹介する。

### 2. 睡眠に関する情報抽出

#### 2.1 睡眠脳波

正常睡眠時の脳波は比較的規則正しいリズムを有しており、 $\alpha$  波、様々な周波数成分を含む低電位波 (図中、L 波と略す)、高振幅徐波などの背景脳波と、それらに重畳して出現する睡眠紡錘波、K-複合波、頭頂部鋭波、運動覚醒波、鋸歯状波などがある。これらの波形パターンの一例を図 1 に示す。睡眠脳波ステージは、脳波波形パターンの出現率や出現系列と急速眼球運動 (REMs : Rapid Eye Movements) 情報、筋電位情報をもとに定義され、一般に、覚醒段階 (Stage W) と睡眠段階 (Stage 1 ~ 4, Stage REM) の 6 段階に分けられている[6,7].

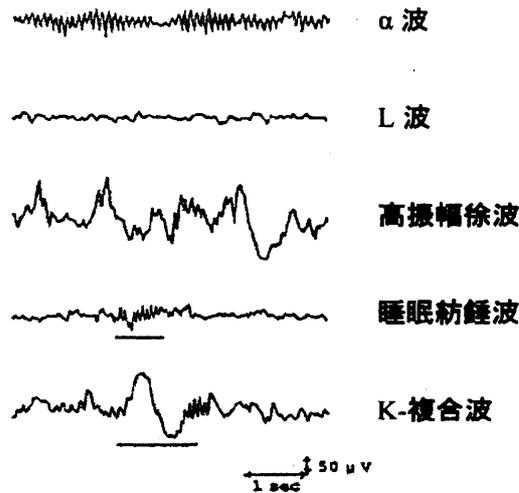


図1 代表的な睡眠脳波波形パターン

## 2.2 ウェーブレット変換を利用した睡眠脳波解析

(1)式で示される連続ウェーブレット変換はパラメータ  $a$  (スケーリングパラメータ) と  $b$  (シフトパラメータ) を有する積分変換である. この変換によって, 時間-周波数情報を得ることができる. ここでは, 周波数情報と関連付けの容易な(2)式に示すガボール関数を使用する.

$$(W_{\psi}f)(b,a) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

$$\psi(t) = \frac{1}{2\sqrt{\pi}\sigma} \exp(-t^2 / \sigma^2) \exp(jt) \quad (2)$$

(2)式における減衰係数  $\sigma$  の値を調整することによって, 周波数と時間の分解能を調整できる. チャープ波のウェーブレット変換結果の例が図2である.  $\sigma=1.0$  の場合, 低周波数領域での時間分解能が高い反面, 高周波数領域における周波数分解能が低くなっているのに対し,  $\sigma=6.0$  の場合, その逆になっていることがわかる.

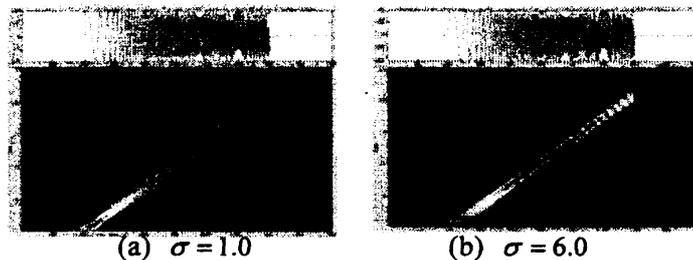


図2 チャープ波のウェーブレット変換結果

### 【修正ウェーブレット変換】

通常のウェーブレット変換は, 窓幅を周波数に応じて自動的に変化させ, 時間一周波数解析を行うものであるが, 睡眠脳波の場合,  $\alpha$ 波や睡眠紡錘波のように比較的周波数の高い波は, 連続した波形として定義されているのに対し, 高振幅徐波やK-複合波のような低い周波数の波は単一波として定義されている. このことは, 通常のウェーブレット変換が処理窓内の波形数を同じになるよう窓幅を調整することに対し, 睡眠脳波波形処理用に他の窓幅選択法が存在することを示唆している. そこで, ここでは, 理論的な直交性は失われるが, 次のような  $\sigma$  調整式を導入した修正ウェーブレット変換法を考えることにする.

$$\sigma = \sigma_{\min} + \frac{K}{1 + \exp[-K_T(1/a - 1/a_c)]} \quad (3)$$

ただし、 $\sigma_{\min}, K, K_T, a_c$  は定数である。ここでは、各パラメータの値を  $\sigma_{\min} = 0.8, K = 10, K_T = 2.5, a_c = 0.1$  と設定しているが、この場合、低周波領域 ( $1/a \ll 1/a_c$ ) や、高周波領域 ( $1/a \gg 1/a_c$ ) において  $\sigma$  の値は以下のようになる。

$$\begin{cases} a \gg a_c : \sigma \approx \sigma_{\min} + K / \exp[K_T/a_c] = 0.8 \\ a = a_c : \sigma = \sigma_{\min} + K/2 = 5.8 \\ a \ll a_c : \sigma \approx \sigma_{\min} + K = 10.8 \end{cases}$$

この設定を用いた場合の EEG 波形と対応する修正ウェーブレット関数を図 3 に示すが、徐波帯域では単一波、睡眠紡錘波帯域では 6 波程度の窓幅を持つよう設定していることがわかる。1 エポック (20 秒) の脳波データに対する通常のウェーブレット変換結果を図 4 に、修正ウェーブレット変換結果を図 5 に示す。両者を比較すると、修正ウェーブレット変換を用いることによって、 $\beta$  波帯域における周波数分解能が改善されていることがわかる。図 6 は、終夜のウェーブレット変換の結果を示している。図 5 に示されている 1 エポック (20 秒) の平均値をプロットしたものである。なお、ここでは、サンプリング周波数 500Hz で採取した EEG 信号 (C3-A2) を分析に用いている。

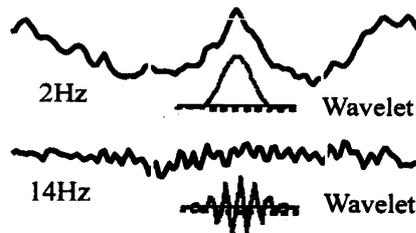


図 3 EEG 波形と対応するウェーブレット関

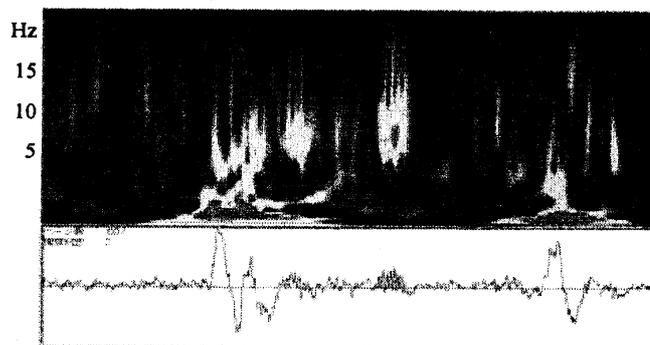


図 4 ウェーブレット変換結果

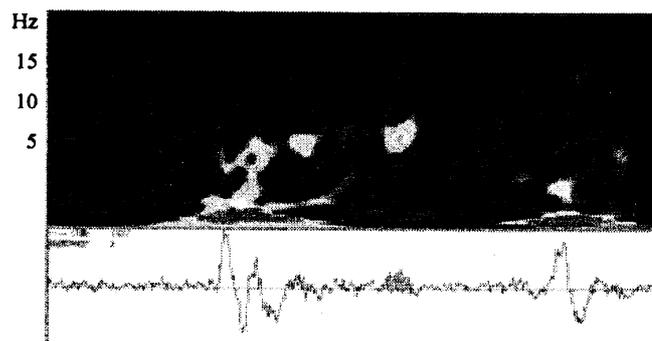


図 5 修正ウェーブレット変換結果

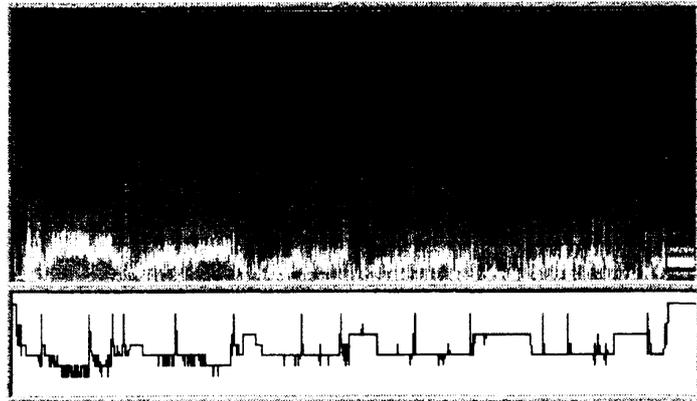


図6 終夜睡眠データの修正ウェーブレット変換結果

睡眠脳波をウェーブレット変換して得られる時間一周波数解析結果から抽出できる情報としては、パワーが高い周波数自身の変動状況や、脳波波形が持つ高周波成分の変動状況等が考えられるが、ここでは、脳波波形が持つ高周波成分の変動状況を抽出する方法について考える。図7に、そのアルゴリズムの概要を示すが、得られた時間一周波数解析結果に、画像処理を施し、その輪郭線を抽出することにより、特性曲線を得ようとするものである。

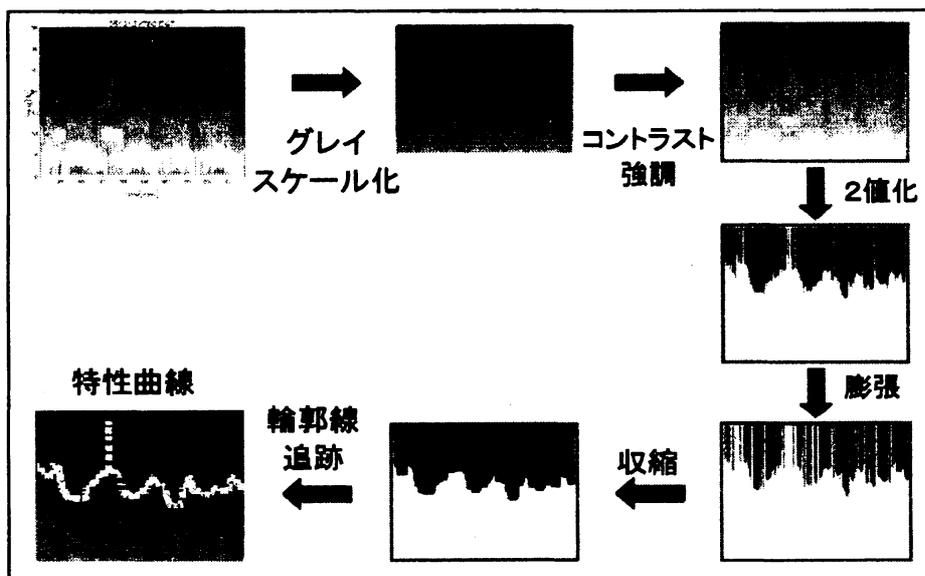


図7 処理アルゴリズム

この処理によって抽出した特性曲線の一例を図8に示す。図中、左列上段がウェーブレット変換結果、左列下段が睡眠脳波ステージ遷移状況、右列上段が特性曲線抽出結果、右列下段が心電位を処理して得られた HF, LF 成分の変動状況である。右列上段の図に、HF 成分を上下反転させたグラフもあわせて示しているが、本手法によって得られる特性曲線は、HF 成分（副交感神経活動）の変動と非常に良く似た変動を示していることがわかる。このことは、脳波だけを解析することによって、連続的な自律神経リズムの変動を把握できること、つまり睡眠状態を離散的なステージではなく、連続した状態として、より詳細に解析できる可能性を示している。

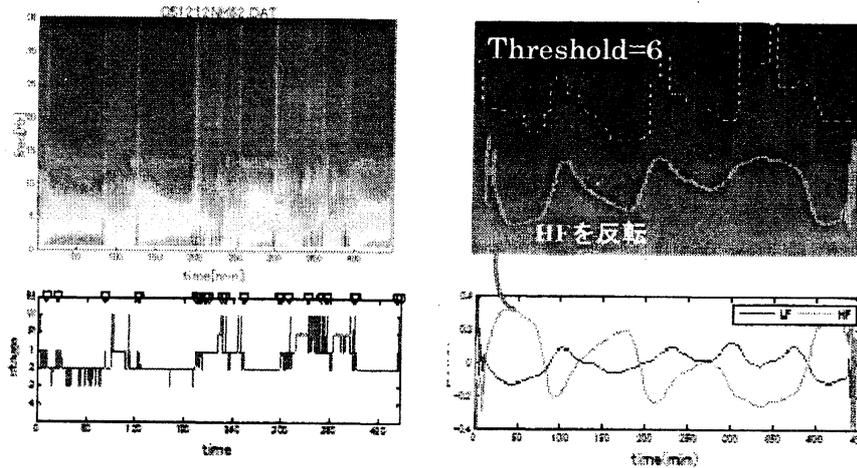


図8 特徴抽出結果

### 3. 覚醒時脳波からの情報抽出

覚醒時においても、種々の要因によって脳波は変動する。認識、記憶、行動、注意などの精神活動・認知活動がその要因となるが、動作想像時には、運動野の脳波に ERD/ERS の現象が観測され、選択反応実験時には、標的刺激提示時に、P300 と呼ばれる事象関連電位が出現することが知られている。

#### 3.1 右手・左手動作想像実験

本稿において使用している脳波データ採取実験時のタイミングチャートを図9に示す。ディスプレイ上に、まず十字が表示され、2秒後に実験開始予告音としてビープ音が鳴り、その1秒後に左右向きの矢印が表示され、被験者はその指示に従って、右手あるいは左手を動かすことを想像する。そして、前もって推定しておいたパラメータを用いて、どちらの手の動作想像をしているかを識別し、その結果を被験者へのフィードバック情報としてディスプレイに表示する。これを1試行として、1回の実験で数十試行繰り返す。なお、脳波採取電極を図10に示すが、運動野の局所脳波を導出するため、スモールラプラシアンフィルタとよばれる空間フィルタを使用している。例えば、C3電極からの信号としては、C3電極から導出される信号から、C3電極の周りに配置した4つの電極から導出される信号の平均値を引いたものを使用している。

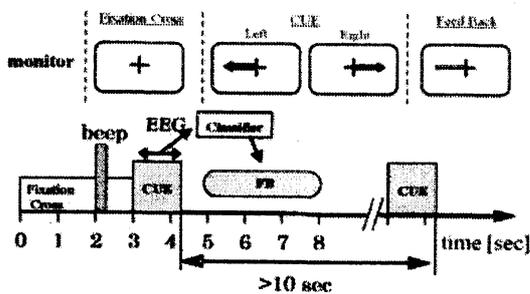


図9 BCI 実験時のタイムチャート

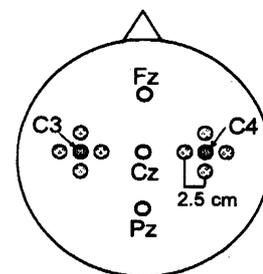


図10 脳波採取電極位置

### 3.2 ARモデルに基づくパターン認識法

脳波信号  $y_t$  は、次に示す自己回帰モデルにより励起されるものと仮定する。

$$y_t = \sum_{j=1}^m \phi_j y_{t-j} + v_t = \Phi^T z_{t-1} + v_t \quad (4)$$

$$\Phi = [\phi_1, \phi_2, \dots, \phi_m]^T \quad z_{t-1} = [y_{t-1}, y_{t-2}, \dots, y_{t-m}]^T.$$

ただし、 $v_t$  は、平均値 0、分散  $\rho$  の正規分布に従う各段独立な確率量である。

$$v_t = N[v_t; 0, \rho], \quad E[v_t, v_s] = \rho \delta_{t,s}$$

特徴パラメータ  $\theta$  を  $\theta = [\Phi^T, \rho]^T$  と定義し、最初の  $m$  個の観測値  $y_1, y_2, \dots, y_m$  を(4)式における初期条件として利用するものとして、次式を仮定する。

$$p(y_1, y_2, \dots, y_m, \theta_k) = p(y_1, y_2, \dots, y_m) \cdot p(\theta_k)$$

また、クラス  $C_k$  において、特徴パラメータ  $\theta$  は一定であると仮定する

$$p(Z_N / C_k) = p(Z_N / \theta_k) \quad Z_N = \{y_1, y_2, \dots, y_N\}.$$

これらの仮定より、条件付き確率密度関数は、以下のように表現できる。

$$p(Z_N / C_k) = P(y_1, y_2, \dots, y_m) \left( \frac{1}{2\pi\rho_k} \right)^{\frac{N-m}{2}} \cdot \exp \left[ -\frac{1}{2\rho_k} \sum_{t=m+1}^N (y_t - \Phi_k^T \cdot z_{t-1})^2 \right] \quad (5)$$

ここでは、電極位置 C3 と C4 の 2 つの電極から導出された信号を利用してパターン認識を行うため、次に示すベイズ判定法を採用することにする。

$$k^* = \text{Arg Max}_k \Pr(C_k / Z_{DN}) \quad (6)$$

ただし、

$$Z_{DN} = \{ Y_{1N}, Y_{2N} \}$$

$$Y_{1N} = \{ y_{11}, y_{12}, \dots, y_{1N} \} : \text{信号(C3)}, \quad Y_{2N} = \{ y_{21}, y_{22}, \dots, y_{2N} \} : \text{信号(C4)}$$

また、空間フィルタによって前処理された脳波信号を使用するので、C3 と C4 の脳波信号は互いに独立であると仮定でき、具体的な判別式は(8)式ようになる。なお、各クラスにおけるパラメータは、確率密度関数が陽な関数として得られているので、最尤推定法を使用して推定する。

$$p(Z_{DN}, C_k) = p(Y_{1N}, Y_{2N} / C_k) = p(Y_{1N} / C_k) \cdot p(Y_{2N} / C_k) \quad (7)$$

【判別式】

$$k^* = \text{Arg Max}_k \left[ \ln(\Pr(C_k)) - \frac{N-m}{2} \ln(2\pi\rho_{1k}) - \frac{1}{2\rho_{1k}} \sum_{t=m+1}^N (y_{1,t} - \Phi_{1k}^T \cdot z_{1,t-1})^2 \right. \\ \left. - \frac{N-m}{2} \ln(2\pi\rho_{2k}) - \frac{1}{2\rho_{2k}} \sum_{t=m+1}^N (y_{2,t} - \Phi_{2k}^T \cdot z_{2,t-1})^2 \right] \quad (8)$$

ここで、 $\Pr(C_k)$  はクラス  $C_k$  の先験確率である。6 人の被験者に対して実験を行い、パターン認識した結果を図 11 に示す。3 名は 10 日間の実験、他の 3 名は 20 日間の実験を行った結果であるが、10 日間で十分学習できる被験者がいる一方、20 日間でも不十分な被験者がいることがわかる。また、被験者 04-m2 は、10 日間の実験を行い 95% 以上の精度を得た被験者であるが、1 年後に再度 4 日間実験を行ったところ、3 日目からほぼ 100% の精度で識別できており、一度獲得した動作想像法は、ある程度長期間保持できるものと思われる。

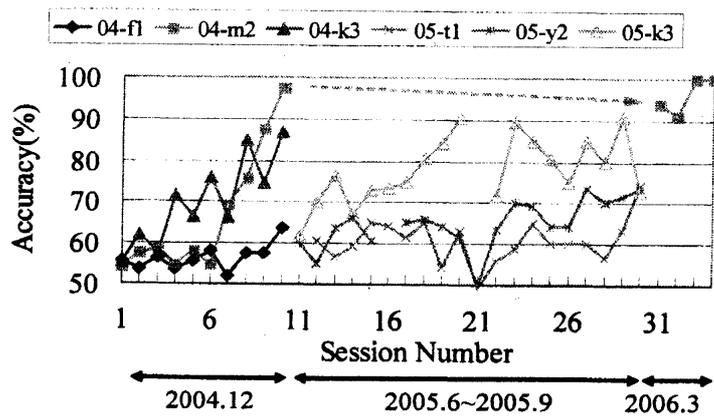


図 11 パタン認識結果

### 3.3 BCI を利用した AIBO 操作システム

上述の識別手法を組み込んだインタフェースにより、AIBO を操作を行うシステムを図 12 に示す。AIBO には、右前あるいは左前に一步前進するプログラムが組み込まれており、PC で被験者の脳波を識別し、その結果をもとに右前に進むのか、左前に進むのかを無線 LAN によって AIBO に伝達する。制御信号を送信するタイミングチャートが図 13 であるが、AIBO が一步動作するために 1.5 秒要することから、1.5 秒毎に、過去 2 秒間の脳波信号を用いて識別を行い、どちらに進むかの指令を与えるようにしている。

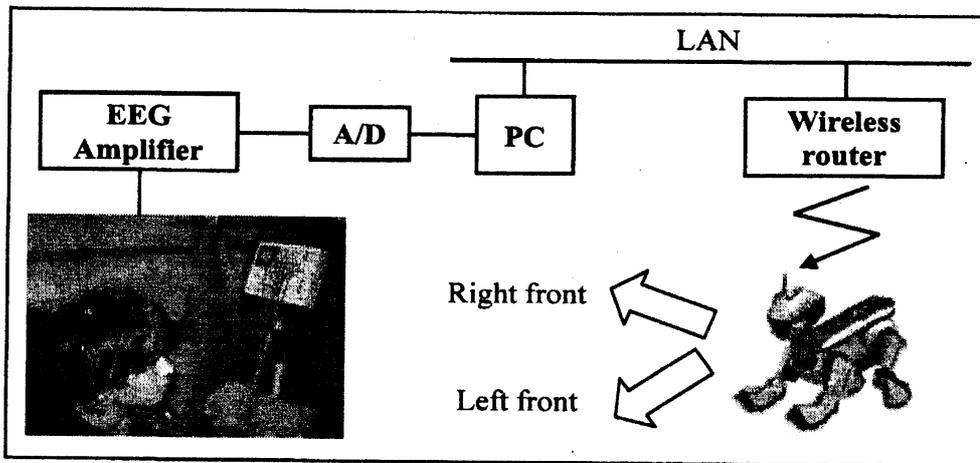


図 12 AIBO 操作システム

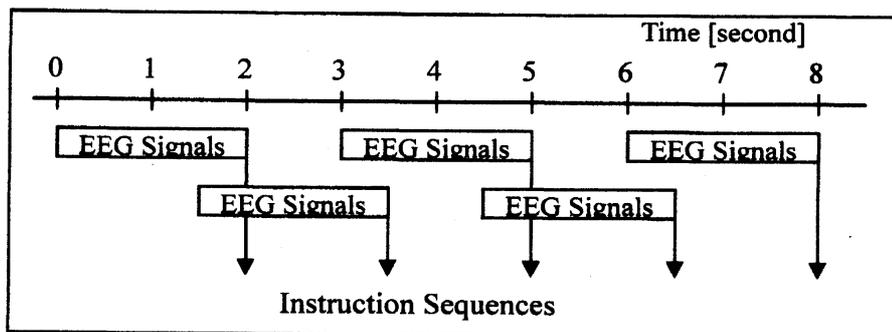


図 13 制御タイミングチャート

## 【実験】

図 14 に、実験の様子を示す。被験者の前に並べられた 2 本の瓶を避けて八の字を描くよう AIBO を操作する実験である。この実験には、前述のパターン識別実験に参加した 6 名のうちの 2 名 (04-m2, 04-k3) が参加したが、そのうち、95%以上の精度を得ることができた被験者 04-m2 は、指示通りに操作を実行できた。このことより、十分学習を行う必要があるものの、脳波からの情報によって、システム操作が可能であることを確認した。

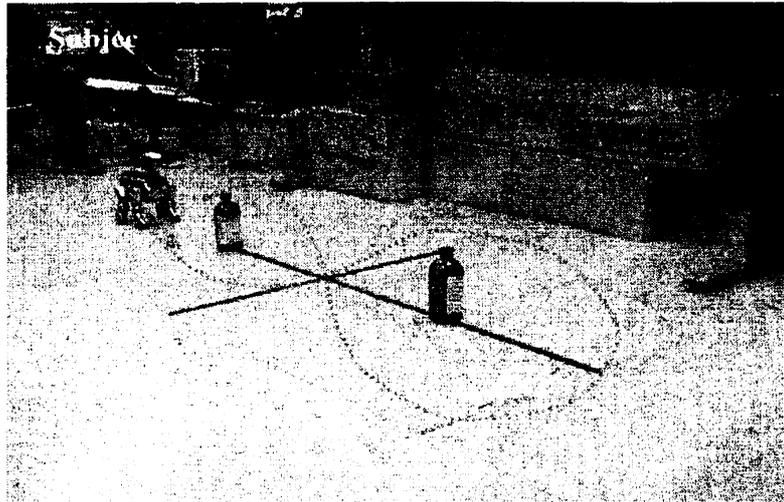


図 14 実験風景

## 3.4 モルフォロジカル・フィルタを用いた特徴抽出

本節では、非線形演算による信号処理を行うモルフォロジカルフィルタを利用した多重解像度解析を行い、信号に含まれる特徴を抽出して、動作想像の種別の認識や、装置の操作ミスが被験者が検知した時の脳波変更を検出する手法について説明する。

## 3.4.1 モルフォロジカルフィルタ

モルフォロジーの基本演算として、Minkowski 和  $\oplus$ 、Minkowski 差  $\ominus$  があり、その定義は以下の通りである。

$$[f \oplus g] = \max_{\substack{t+u \in F \\ u \in G}} \{f(t-u) + g(u)\} \quad (9)$$

$$[f \ominus g] = \min_{\substack{t+u \in F \\ u \in G}} \{f(t-u) - g(u)\} \quad (10)$$

ここで、 $f(t)$  は処理対象である原波形、 $g(t)$  はフィルタの特性を決定する構造関数である。また、 $F$  は処理対象の定義域、 $G$  は構造関数の定義域を表し、定義域外で信号は負の無限大の値を持つものとする。これらを組み合わせた、Erosion, Dilation, Opening, Closing の 4 つをモルフォロジカルフィルタの基本演算とする。これらは、

$$\text{Erosion : } (f \ominus g^s)(t) = \min_{u \in G} \{f(t+u) - g(u)\} \quad (11)$$

$$\text{Dilation : } (f \oplus g^s)(t) = \max_{\substack{t+u \in F \\ u \in G}} \{f(t+u) + g(u)\} \quad (12)$$

$$\text{Opening : } f_g(t) = [(f \ominus g^s) \oplus g](t) \quad (13)$$

$$\text{Closing : } f_g^s(t) = [(f \oplus g^s) \ominus g](t) \quad (14)$$

で定義される。ここで、 $g^s(t) = g(-t)$ である。Erosion は構造関数の形状で負方向に膨らませる効果があり、Dilation は構造関数の形状で正方向に膨らませる効果がある。それらを続けて処理した Opening は、構造関数を負方向から押し当てたとき、構造関数が処理対象に進入できる部分は残し、進入できない部分を除去する特性がある。Closing は、Opening とはグラフ的に上下逆で、構造関数を正方向から押し当て、負方向の突起形状を除去する特性がある。さらに、正負の突起形状を除去するものとして、Opening と Closing を組み合わせた Open-Closing フィルタを定義できる[8]。これは構造関数に比べて小さな凸部を削る平滑化であり、一種の非線形な低域通過フィルタである。構造関数のスケールを大きくすると、その通過帯域はそれだけ狭くなる。また、高域通過フィルタは、低域通過フィルタの出力結果を元の信号から引き去ることで構成される。

$$\text{Low Pass : } \quad \psi^\uparrow(t) = (f_g)^\uparrow(t) \quad (15)$$

$$\text{High Pass : } \quad \omega^\uparrow = f(t) - \psi^\uparrow(t) \quad (16)$$

### 3.4.2 非線形多重解像度解析

Open-Closing フィルタは、低域通過フィルタであり、これと原波形との差分をとることにより高域通過フィルタも得られる。さらに、通過できる帯域は、構造関数の形状に依存するため、基準となる構造関数のスケールを変えて出力波形を出すことは、多重解像度解析を行うことを意味する[9]。k=3 の場合の信号分解の概念図を図 15 に示す。また、入力信号  $x_0$  は、各レベルの信号を加算することにより再構成することができる。つまり、ここで考えている手法は、ウェーブレット関数のかわりに有限サポート幅を持つ構造関数を使用し、積分変換のかわりに Minkowski 和・差等の非線形演算を利用する、ウェーブレット変換の拡張系と考えることができる。

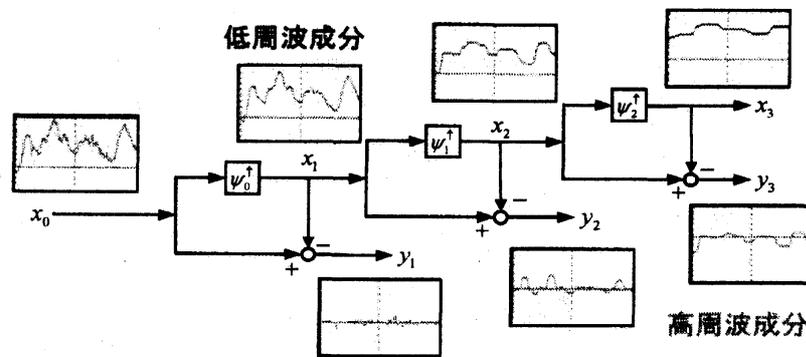


図 15 3 レベル信号分解の概念図

図 16 に通常のウェーブレット(Daubechies 6)を用いた多重解像度解析結果を、図 17 にモルフォロジー(構造関数 Haar)を用いた多重解像度解析結果を示す。原波形の 5~8[sec] (動作想像時) に出現している高周波成分は、分解された高周波成分において、線形手法であるウェーブレットでは、Level 5 程度まで影響を及ぼし、非線形手法であるモルフォロジーでは、Level 3 程度まで影響を及ぼしていることがわかる。

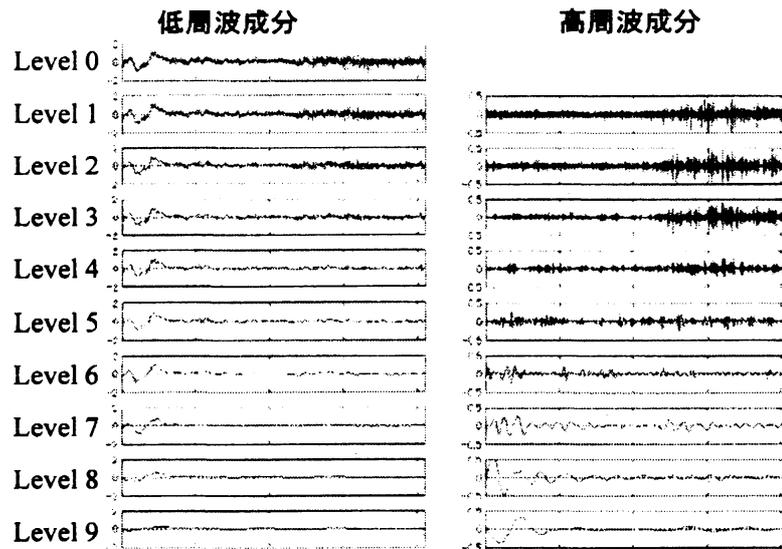


図 16 多重解像度解析結果  
(ウェーブレット : Daubechies 6)

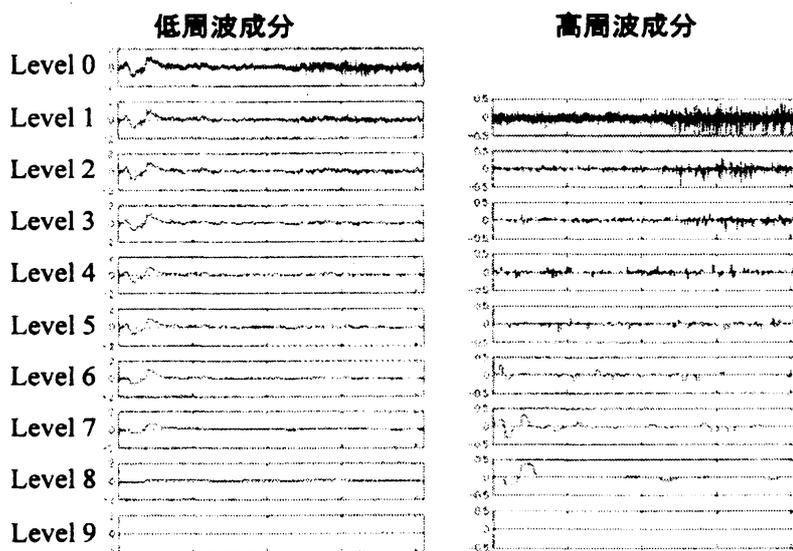


図 17 多重解像度解析結果  
(構造関数 : Haar 関数)

### 3.4.3 多重解像度解析を利用した脳波波形識別

本節では、多重解像度解析を用いて脳波信号の分離を行い、特定のレベルの信号のみを使用して再構成した信号に対して特徴量を抽出し、パターン識別を行う。処理に使用する再構成信号  $\hat{y}$  を表 1 に示す。なお、再構成信号 ID=0 は、原信号自身を表している。

表 1 再構成信号

再構成信号ID	0	1	2	3	4	5	6	7	$L_u$	$L_v$	$L_w$
再構成に用いる信号レベル	$x_0$	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	$y_7$	$y_4, y_5, y_6$	$y_5, y_6, y_7$	$y_4, y_5, y_6, y_7$

【IV 成分を用いた動作想像の識別】

ERD/ERS の特徴を抽出する手法が、いくつか提案されている。ここでは、特徴量の抽出が比較的容易な次式に示す Intertrial Variance (IV) を用いる。

$$IV(t) = \frac{1}{M-1} \sum_{i=1}^M (\tilde{y}^i(t) - \bar{y}(t))^2 \quad (t=1,2,\dots,N) \quad (17)$$

$$\bar{y}(t) = \frac{1}{M} \sum_{i=1}^M \tilde{y}^i(t) \quad (t=1,2,\dots,N)$$

ここで、 $M$  は試行数、 $N$  は一試行で得られる時系列データ点数、上添え字の  $i$  は何番目の試行かを表している。このように、IV は信号と試行間平均との差の二乗平均で計算される。ERD/ERS は、何も考えていないときの IV 値の平均値との比で表される。

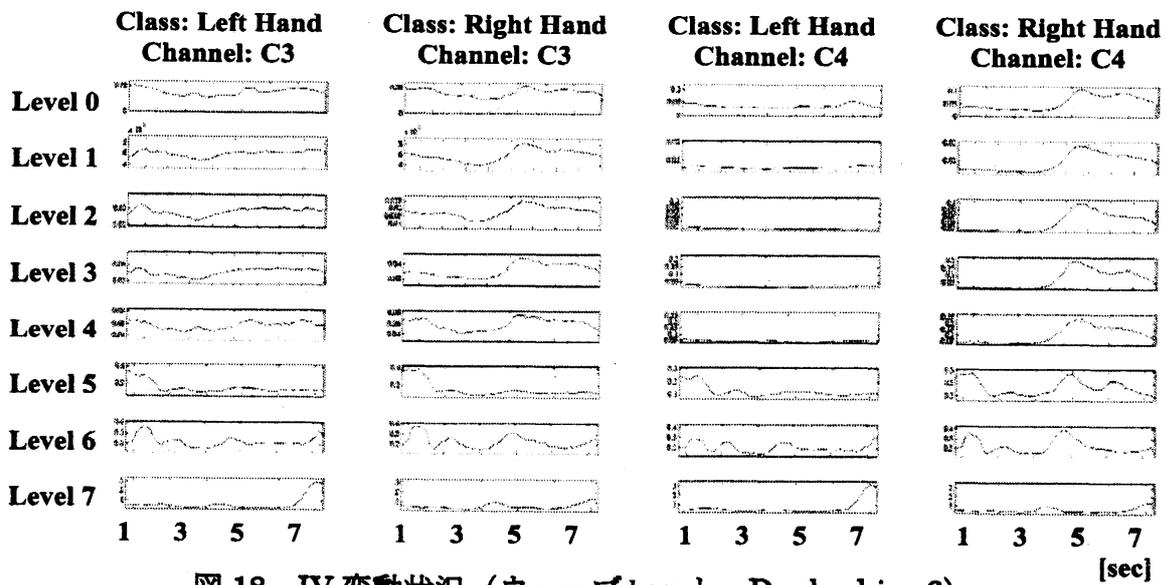


図 18 IV 変動状況 (ウェーブレット : Daubechies 6)

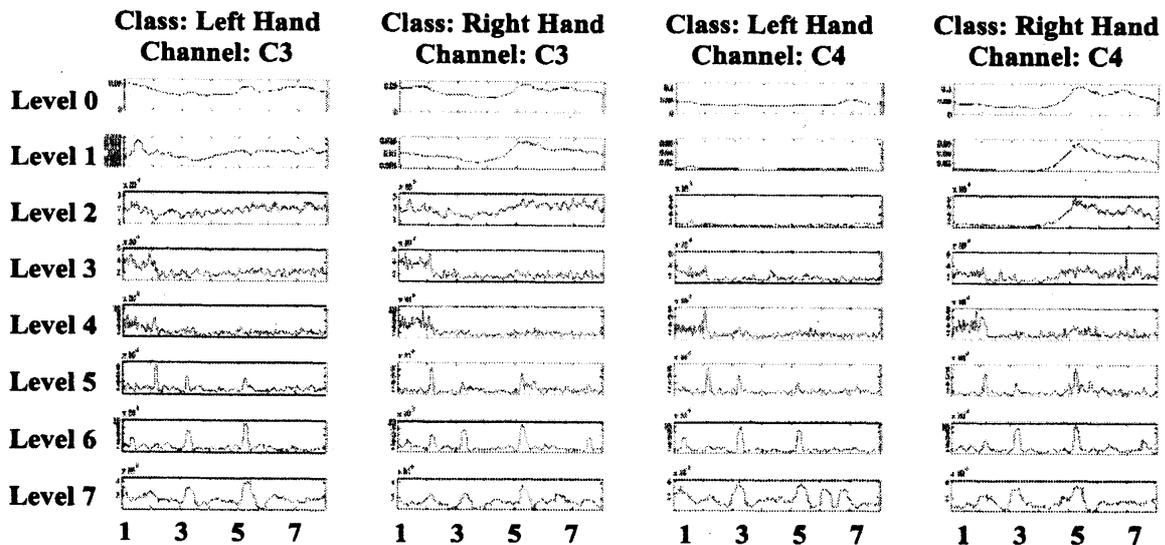


図 19 IV 変動状況 (モルフォロジー)

一例として、Daubechies 6 のウェーブレットと、モルフォロジーの分解系列に対して IV を求めた結果を図 18, 図 19 に示す。特に、右手動作想像クラスのチャンネル C3 において、ウェーブレット解析の場合ではレベル 1~4 に、動作想像の開始時刻(3~4[sec])でパワーの減少(ERD)と、その後(4~7[sec])のパワーの増加(ERS)が見られ、モルフォロジーの場合ではレベル 1~2 に、この特徴が確認できる。

特徴量 IV 値の分布は正規分布であり、時刻間で、その確率量は独立であると仮定すると、ベイズ判別式は、次式のようになる。

$$k^* = \underset{k}{\text{Arg Max}} \Pr(C_k | \tilde{y}(1), \tilde{y}(2), \dots, \tilde{y}(N))$$

$$= \underset{k}{\text{Arg Min}} \left\{ \frac{1}{2} \sum_{t=1}^N \ln \sigma_{k,t}^2 + \frac{1}{2} \sum_{t=1}^N \left\{ \frac{1}{\sigma_{k,t}^2} (\tilde{y}(t) - \bar{y}_k(t))^2 \right\} - \ln \Pr(C_k) \right\} \quad (18)$$

ただし、

$$\bar{y}_k(t) = \frac{1}{M} \sum_{i=1}^M \tilde{y}_k^i(t)$$

$$\sigma_{k,t}^2 = \frac{1}{M-1} \sum_{i=1}^M (\tilde{y}_k^i(t) - \bar{y}_k(t))^2$$

ここで、 $\Pr(C_k)$  はクラス  $C_k$  の先験確率であり、 $\tilde{y}_k^i(t)$  は、クラス  $C_k$  の  $i$  番目の試行における再構成信号である。

本手法を利用し、右手左手動作想像時の脳波(C3,C4) において、どちらの手の動作を想像したかを認識した結果を図 20 に示す。この結果より、本手法において、レベル 1,2 において高い精度が得られていることわかる。比較のため、通常のウェーブレット(Daubechies 6)を適応した結果、および AR モデルを用いたパタン識別結果(Level 0 のみ)を示しているが、通常のウェーブレット手法に比べて、本手法のほうが精度の良い帯域が狭いこと、つまり、動作想像に関連する情報を本質的に含む帯域の特定が容易であることを示している。また、AR モデルを用いた場合でも同様の識別精度が得られているが、AR モデルの場合、一般には、推定された各クラスの AR 係数から計算できる AR スペクトルから特徴のある帯域を見つけることは容易でなく、ここでの結果は、信号の持つ物理的意味を考察する上で、本手法のほうが適していることを示しているといえる。

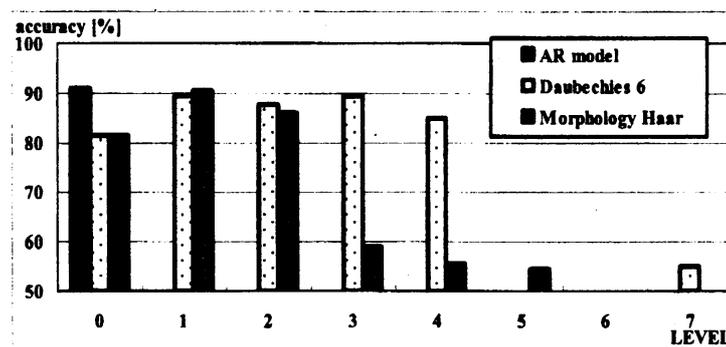


図 20 右手左手動作想像の識別結果

### 【面積を特徴量とした誤作動の検出】

一般には、BCI システムの誤動作時には、正成分のエラーポテンシャルが出現するといわれている[10]。そこで、ここでは、指示(被験者の動作想像)と同じ向きのフィードバックが表示された場合と、逆向きのフィードバックが表示された場合を脳波から識別することを目的として、(19)式に示す量を事象関連電位に関係する特徴パラメータとして、再構成信号  $\tilde{y}(t)$  から計算する。ここで、 $H(\cdot)$  は、(20)式で示されるヘビサイド関数である。

$$s = \sum_{t=1}^N \{H(\tilde{y}(t)) \cdot \tilde{y}(t)\} \quad (19)$$

$$H(\tilde{y}(t)) = \begin{cases} 1 & \tilde{y}(t) \geq 0 \\ 0 & \tilde{y}(t) < 0 \end{cases} \quad (20)$$

なお、判別法としては、特徴量  $s$  が正規分布である確率量であると仮定し、ベイズ認識法を採用する。フィードバックは、図9のように試行開始時5秒目から示されるので、処理データ区間を(1)5.0秒～5.5秒(処理データ長:0.5秒)、(2)5.0秒～6.0秒(処理データ長:1.0秒)、(3)5.0秒～6.5秒(処理データ長:1.5秒)として識別した結果が図21である。これより、処理における最適データ長は0.5秒であり、レベル4,6,7から再構成された信号において、高い精度が得られていることがわかる。同様な実験を3人の被験者に対して行ったところ、70%~80%の精度で、正しいフィードバックが表示された場合と間違ったフィードバックが表示された場合の識別が可能であること、つまり、BCIシステムの誤作動を被験者が認知したことが、ある程度検出可能であることを確認している。

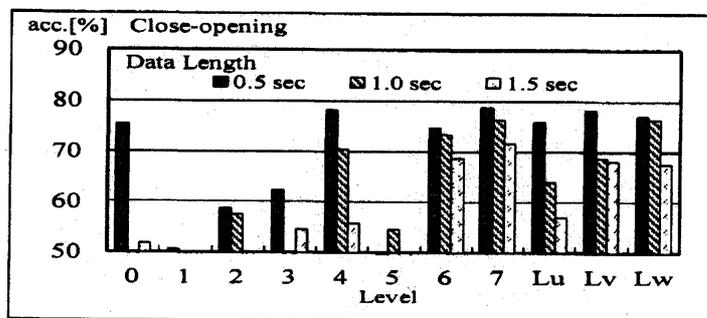


図 21 誤作動認知に関する検出結果

#### 3.4.4 考察

一般的には、動作想像時に脳波に出現するIVの変化は、被験者ごとに帯域の異なるバンドパスフィルタを用いて帯域を狭められた脳波波形において抽出される。一方、多重解像度解析によって分解した各レベルの波形を、それぞれバンドパスフィルタ後の波形であると考えるのであれば、それらの系列におけるIVの変化を見ることで、動作想像に関連のあるレベル帯域を特定できると考えられる。IVの変化が顕著であった帯域は、ウェーブレットの場合はレベル4まで(図18)、モルフォロジーの場合はレベル2まで(図19)であったが、これは、波形の分解の際に高周波成分の影響が表れたレベル帯域と同じである(図16, 図17参照)。また、分解した各レベルの信号毎に、右手左手動作想像クラスのパターン識別を行った結果、高周波成分の影響が表れる帯域、IVに大きな変化が表れる帯域に対応して、ウェーブレットではレベル1~4で高い認識精度が得られ、モルフォロジーではレベル1~2で高い認識精度が得られている(図20)。このことは、脳波波形に表れるパルス形状成分に、動作想像に直結した情報があることを示唆しているものと思われる。

一方、モルフォロジー手法において、レベル5~7の帯域における2[sec], 3[sec], 5[sec]付近に大きなピークが見られる(図19)。これらは、本実験システムにおいて、被験者が視聴覚刺激を受ける時刻(2[sec]: Beep音, 3[sec]: 方向指示表示開始, 5[sec]: フィードバック表示開始)であり、このレベル帯域は、視聴覚誘発電位の成分を抽出しているものと考えられる。このように、多重解像度解析を用いることで、動作想像に関係のある情報と視聴覚誘発電位に関係のある情報を、別々のレベル帯域に分解できることがわかる。特に、モルフォロジー手法を用いる場合、狭い帯域に特徴を集約することが可能であるため、情報の分解能が良く、同じ信号から同時に種々の情報を抽出するために適した方法であるといえる。

#### 4. おわりに

本稿では、ウェーブレット解析手法を睡眠脳波解析やBCIに適用する上で、必要な修正を加えた手法を紹介するとともに、実際の脳波データに適用してどの程度の情報を抽出できるかを紹介した。睡眠脳波解析における修正ウェーブレット解析手法においては、最適な $\sigma$ の調整法や得られた睡眠情報の定量的解析が、BCIシステムにおけるモルフォロジカルフィルタを用いた多重解像度解析についても、最適構造関数の選定等、検討すべき課題が残されており、今後、これらについて検討を進めていきたいと考えている。

#### 参考文献

- [1] 大熊輝雄: 臨床脳波学第5版: 医学書院 (1999)
- [2] 井上勝裕: 学習用 PSG Stager, 不眠研究会第16回研究発表会, pp. 110-136, 2000
- [3] 井上勝裕: 睡眠脳波ステージ自動判定システムの構築への適用, ウェーブレット解析の産業応用, 電気学会ウェーブレット解析の産業応用に関する協同研究委員会編, 朝倉書店, pp. 178-202, 2005
- [4] K. Inoue, K. Kumamaru, G. Pfurtscheller: Robot Operation based on Pattern Recognition of EEG Signals: Proc. of the 3rd International Brain-Computer Interface Workshop and Training Course 2006, pp. 116-117, Graz, Austria, 2006
- [5] K. Inoue, M. Fujio, T. Yamaguchi, G. Pfurtscheller: Mathematical morphological multi-resolution analysis of EEG signals during misoperation of BCI system: Proc. of the 4th International Brain-Computer Interface Workshop and Training Course 2008, pp. 74-79, Graz, Austria, 2008
- [6] A. Rechtschaffen, A. Kales: A manual of standardized terminology, techniques and scoring system for sleep stages of human subject, Public Health Service U.S. Government Printing Office, Washington D.C., 1968
- [7] T. Hori, Y. Sugita *et. al.*: Proposed Supplements and Amendments to 'A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects', the Rechtschaffen & Kales (1968) standard; Psychiatry and Clinical Neurosciences, Vol. 55, pp.305-310, 2001
- [8] J. Goutsias *et. al.*: Nonlinear Multiresolution Signal Decomposition Schemes - Part I: Morphological Pyramids: IEEE Trans. on Image Processing, Vol. 9, No.11, 2000
- [9] J. Goutsias *et. al.*: Nonlinear Multiresolution Signal Decomposition Schemes - Part II: Morphological Wavelets: IEEE Trans. on Image Processing, Vol. 9, No.11, 2000
- [10] G. Schalk, J. R. Wolpaw, *et. al.*: EEG-Based communication: presence of an error potential: Clinical Neurophysiology, Vol. 111, pp. 2138-2144. 2000