

修士論文

肘関節屈曲運動イメージにおける
左右識別のためのEEGを用いた
特徴量の検討

同志社大学大学院 生命医科学研究科
医工学・医情報学専攻 医情報学コース
博士前期課程 2013年度 1029番

大久保 祐希

指導教授 廣安 知之教授

2015年1月23日

Abstract

In this study, we obtained the electroencephalogram (EEG) data related to left- or right-hand elbow flexion motor imagery and examined the window width for feature extraction. The overlap processing was used to extract the feature values from the window, which was less than 1.0 second. FFT (Fast Fourier Transform), wavelet transform and FIR (Finite Impulse Response) filter were used to extract the feature values. We recorded 20 subjects of EEG of elbow flexion motor imagery and we performed left- or right classification with the features extracted by the previous method or the overlap processing. When classification accuracy of the overlap processing was compared with that of the previous method, the overlap processing was superior to the previous method. The best performance was showed when the window width was 512 using FFT. On the other hand, the best performance was showed when the window width was 256 using wavelet transform.

目 次

1	序論	1
2	Electroencephalograph	3
2.1	EEG の計測原理	3
2.2	既存手法	4
3	肘関節屈曲運動イメージにおける左右識別のための特徴量の検討	10
3.1	オーバーラップ処理を用いた特徴量抽出方法	10
3.2	実験概要	11
3.3	識別方法	12
3.4	実験結果と考察	13
4	結論	15

1 序論

近年, EEG (Electroencephalograph)¹⁾ や fNIRS (functional Near-Infrared Spectroscopy) 装置^{2,3)}, MRI (Magnetic Resonance Imaging) 装置^{4,5)} などの非侵襲脳機能計測装置が発展してきた. EEG は頭皮上に金属の電極を電解液などを使用し設置することで, 脳波を計測できる装置である^{6,7)}. fNIRS 装置は頭皮上から近赤外光を照射することにより, 非侵襲的に大脳皮質内の神経活動に連動した脳血流変化に伴う酸素化ヘモグロビン (Oxy-Hb) と脱酸素化ヘモグロビン (Deoxy-Hb) の濃度変化量を計測する装置である⁸⁾. MRI 装置は BOLD (blood oxygenation level-dependent) 効果⁹⁾ に基づき, 脳内における血流量の変化から脳の神経活動を推定する装置である¹⁰⁾. Fig. 1 に EEG, fNIRS 装置, MRI 装置の例を示す. また近年では, EEG と fNIRS 装置, EEG と fMRI 装置など 2 種類の機器を同時に用いて脳活動を計測する研究が行われている. 2 種類の機器を同時に使用することで, それぞれの機器の欠点を補いながら計測し解析を行うことができる¹¹⁾.

また, 上記のような非侵襲脳機能計測装置の発展により, ヒトの脳機能に関する研究が活発化している. それによりヒトの高次脳機能が解明されつつあり, その利用対象として BMI (Brain Machine Interface) が注目されている^{12,13)}. BMI とは末梢神経系, 感覚器, 運動器を介さず, 脳と機械間で直接相互作用させる技術の総称である¹⁴⁾. ヒトの脳は, 通常末梢神経系を通じて信号を伝達し, 受容器や効果器を介しながら外部環境と関わりを持つ. しかし, その仲介となる末梢神経系や受容器, 効果器を省き, 脳と外部環境を直接作用させることが BMI である. 脳機能を補償する BMI 技術は 6 種類に大別される¹⁴⁾.

- (1) 感覚書き込み型
- (2) 運動読み出し型
- (3) 意思決定書き込み型
- (4) 意思決定読み出し型
- (5) 情動/動機書き込み型
- (6) 情動/動機読み出し型

その中でも, 運動読み出し型 BMI は主に完治が困難な身体障害者を対象とした技術であり, 彼らの生活の質 (Quality of Life : QOL) の向上を目的として, 医療・福祉技術としての応用が期待されている^{15,16)}. 運動読み出し型 BMI の例として, EEG から得られた脳波によるコンピュータのカーソルの操作^{17,18)} や車いすの運転^{19,20)} が挙げられる. これらを代表とする BMI にはユーザが運動をイメージした時の信号を解析する必要があり, これまで多くの研究者が運動イメージの解析手法について検討してきた²¹⁻²³⁾. 運動イメージは感覚運動のメンタルシミュレーションと定義される^{24,25)}. 運動イメージを行うと, 実際に身体を動かさずとも感覚運動野付近で β リズムや μ リズムが活動する²³⁾. また, 右手の運動イメージを行うと左半球の感覚運動野が活動し, 左手の運動イメージを行うと右

半球の感覚運動野が活動する．このように運動イメージを行うと右半球と左半球で明確な差が生じる²⁶⁾．

BMI における過去の研究では，右手，もしくは左手の運動イメージ時における脳波を EEG で計測し，FFT (Fast Fourier Transform)²⁷⁾ やウェーブレット変換²⁸⁻³¹⁾，FIR (Finite Impulse Response) フィルタ^{32,33)} を用いて識別に用いる特徴量を抽出する方法が考案されている．これらの研究では運動イメージを行う時間を 1 秒以上とり，イメージを行なっている全ての時間における脳波から特徴量を抽出している．しかし，実際に運動を行なっている場面での BMI の利用を考慮すると，イメージには 1 秒以上の時間を要しないため，不必要な脳波のデータ処理も行なっている可能性がある．そこで我々はオーバーラップ処理を用いた FFT によって最も強く運動イメージを行ったとされる区間を算出し，その区間におけるパワースペクトルの積分値を特徴量とする手法を提案した．本稿では，提案手法の有効性を検討するために FFT とウェーブレット変換，FIR フィルタで特徴量を抽出する 3 種類の手法を使用し左右識別を行い，識別精度について検討した．

本稿の構成を以下に示す．第 2 章で本実験に使用する EEG を用いた脳波の計測原理と脳波を用いた BMI システムに使用される特徴量抽出の既存手法について述べる．第 3 章で提案手法の有効性を示すために肘関節屈曲運動イメージにおける左右識別のための特徴量抽出手法について検討する．第 4 章で本稿の結論を述べる．

2 Electroencephalograph

本章では、本実験に使用される EEG の計測原理と脳波を解析するための既存手法について述べる。

2.1 EEG の計測原理

EEG は神経細胞から生じる電気信号を頭皮上から脳波として計測する機器である。脳波 (Electroencephalogram) とは、脳にある神経細胞から生じる電気活動である。人の脳内には約 140 億個の神経細胞が存在するといわれている⁶⁾。神経細胞は、本体の細胞体、信号受信を行い分岐し周囲に伸びる多数の樹状突起、信号出力を行う軸索から構成される。Fig. 2 に神経細胞の概略図を示す。

神経信号が送られる際には、樹状突起から信号が入力され、細胞体を通り、軸索まで伝達される。情報が電気信号となって伝達し、これを脳波として計測するのが EEG である。脳波を調査することにより、脳の機能状態を簡易かつ非侵襲的に検査することが可能である。そのため医療分野において、てんかんの診断、脳炎や脳症による脳障害の有無を判断するために利用されている⁶⁾。

脳波は、頭皮上に付けた電極から導出した電位変化を縦軸に、時間経過を横軸にとって記録したものである。Fig. 3 に、実際に EEG を用いて計測された脳波の一例を示す。また、Fig. 4 にヒトの頭皮上に電極を付けた図を示す。Fig. 4 より頭皮上に電極をつけた場合、頭皮や頭蓋骨など何層もの膜を経て、距離のある大脳皮質から電気信号を取得することになる。1つの電極に入力されるのは電極の直径の約 3 倍の範囲の大脳皮質からの電位であり、そこに含まれる神経細胞は数百万個に及ぶ。従って、EEG はこれらの膨大な数の神経細胞が発生させる電位の総和を脳波として観測している。

EEG は、生体計測器、生体アンプ、電極で構成される。Fig. 5 に脳波計の一部の概略図を示す。Fig. 5 のようにヒトの頭部に 2 つの電極を貼り付けると電極間にわずかな電位差 (電圧) が生じ、その電位の大きさは数十 μV 程度である。この小さな電位を増幅器により計測可能な電圧に増幅することで脳波が観察できる。得られた脳波は、アナログデータであるため、AD 変換器でデジタルデータに変換する。このように、得られた脳波は、増幅器および AD 変換機を経て計測される。

増幅器は一般的に差動増幅器が用いられる。Fig. 6 に差動増幅器の模式図を示す。差動増幅器は、探査電極からの入力 G1 と基準電極からの入力 R、接地電極からの入力 E を使用する。G1 と E で検出される電圧と、R と E で検出される電圧を全く同じ増幅度を持つ 2 つの増幅器でそれぞれ増幅し、それらの差を求めシグナルを検出する。このような計測を行うことで交流雑音の相殺が可能となり、計測波形に交流雑音がもつ高周波成分の混在を防ぐことができる。差動増幅器は、交流雑音を除去するほかに、電極の分極電圧やインピーダンスの変化による緩やかな同相変動のキャンセル、電源電圧変動による影響の軽減などの役割を持つ。

電極の配置方法は、検査対象者や脳波計のチャンネルによりさまざまであるが、一般的

には国際 10-20 法という電極配置法を使用する．Fig. 7 に標準的な 21 個の電極を持つ電極配置の図を示す．国際 10-20 法は，EEG を用いて計測する際に使われる標準的な電極配置法であり³⁴⁾，被験者の頭部の大きさを計測することで電極配置を決定する方法である．鼻根 (Nasion) と後頭結節 (Inion) の間および左右両耳介前点間をそれぞれ計測し，それを 10% および 20% で均等間隔に分割する．これにより，何度も実験を繰り返しても同一部位に電極を配置することができ，再現性のある結果を得ることが可能となる．

2.2 既存手法

運動イメージにおける脳波の解析手法のアプローチは主に 4 種類に分類される．まず 1 つ目としては，識別のための特徴量を抽出する手法の検討である²⁸⁾．2 つ目として特徴量を抽出する際に使用する周波数帯域の検討³⁵⁾，3 つ目として特徴量を識別するために使用される識別器の検討³⁶⁾，そして 4 つ目としてチャンネルの選択^{32,37)} である．本実験では 1 つ目のアプローチである特徴量抽出手法について検討を行った．

既存の左右識別のための特徴量の抽出方法はフーリエ変換²⁷⁾，ウェーブレット変換²⁸⁻³¹⁾，FIR フィルタ^{32,33)} がある．各手法について以下に記載する．

2.2.1 フーリエ変換

フーリエ変換は時系列データに含まれる周波数の分布を求める方法の 1 つであり，このことをフーリエ解析という³⁸⁾．フーリエ変換対を以下の式に示す．時間領域で表現できる波形を周波数領域 (2.1)，また周波数領域で表現できる波形を時間領域 (2.2) に変換できる．

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) e^{j\omega_0 t} d\omega \quad (2.1)$$

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega_0 t} dt \quad (2.2)$$

FFT は離散フーリエ変換 (DFT : Discrete Fourier Transform) の対称性を利用し，大幅に演算量を減少させ高速に変換を行う方法である．式 (2.3) に離散フーリエ変換，式 (2.4) に離散フーリエ逆変換を示す．

$$X_k = \frac{1}{N} \sum_{i=0}^{N-1} x_i e^{-j\frac{2\pi}{N} ki} \quad (2.3)$$

$$x_i = \sum_{k=0}^{N-1} X_k e^{j\frac{2\pi}{N} ki} \quad (2.4)$$

また，式 (2.3) において $e^{-j\frac{2\pi}{N}} = W_N$ とすると式 (2.5) のように表すことができる．

$$X_n = \sum_{k=0}^{N-1} x_k W_N^{kn} \quad (2.5)$$

W_N を回転因子と呼び、式 (2.6) のように複素平面の単位円を N 分割した点として表すことができる。

$$W = e^{-j\frac{2\pi}{N}} = \cos\left(\frac{2\pi}{N}\right) + j \sin\left(\frac{2\pi}{N}\right) \quad (2.6)$$

この回転因子において式 (2.7)、式 (2.8) の関係が成立する。

$$W = e^{-j2\pi} = 1 \quad (2.7)$$

$$W^k = W^{k+N} = \dots = W^{k+2N} \quad (2.8)$$

FFT は回転因子の性質を利用することで、大幅に演算量を減少させ高速に変換を行うことが可能となる。

一般的に解析に用いる信号は有限であり、それはある特定の区間における信号を切り出す。そのため、切り出した位置により解析結果に大きな影響を与えることがある。信号の切り出し位置による影響を抑えるために、フーリエ解析を行う前の波形に窓関数を適用する。窓関数には様々な形が考えられており、入力となる離散信号に窓関数をかけたあとに離散フーリエ変換を行う。窓関数に要求される条件は以下の通りである。

- 主極 (main-lobe : メインローブ) の幅が小さいこと
主極が狭いほど、主成分の周波数分解能が高くなる。
- 副極 (side-lobe : サイドローブ) の振幅が小さいこと
副極が小さいほど、小さいスペクトルを検出する能力が高まる。

代表的な窓関数は以下の通りである。

(1) 方形窓 (Rectangular Window)

周波数分解能は優れているが、サイドローブが大きい。式 (2.9) に方形窓の式を示す。

$$h(n) = \begin{cases} 1, & 0 \leq n < N-1 \\ 0, & \text{otherwise} \end{cases} \quad (2.9)$$

(2) ハニング窓 (Hanning Window)

中央値が 1 の持ち上げた \cos (Raised Cosine) の波形である。周波数分解能はやや劣るが、サイドローブが比較的小さい。式 (2.10) にハニング窓の式、Fig. 8 にハニング窓の概形を示す。

$$h(n) = \begin{cases} 0.5 - 0.5 \cos\left(\frac{2\pi n}{N-1}\right), & 0 \leq n < N-1 \\ 0, & \text{otherwise} \end{cases} \quad (2.10)$$

(3) ハミング窓 (Hamming Window)

ハミング窓ではメインローブが広がってしまうため、これを改善するために端を持ち上げた窓である。方形窓とハミング窓の長所を生かした窓関数である。式 (2.11) にハミング窓の式、Fig. 9 にハミング窓の概形を示す。

$$h(n) = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), & 0 \leq n < N-1 \\ 0, & \text{otherwise} \end{cases} \quad (2.11)$$

(4) ガウス窓 (Gaussian Window)

ガウス関数は、周波数変換後の形状もガウス関数となるため、これを窓として用いると時間-周波数の対称性が良くなる。時間周波数解析である短時間フーリエ変換は、この窓を用いる。式 (2.12) にガウス窓の式を示す。

$$h(n) = \begin{cases} \exp\left\{-\frac{2m^2}{(N-1)^2} \left(n - \frac{N-1}{2}\right)^2\right\}, & 0 \leq n < N-1 \\ 0, & \text{otherwise} \end{cases} \quad (2.12)$$

本稿では、運動イメージ時の脳波に対しハミング窓をかけた後 FFT を行い、特定の周波数帯域におけるパワースペクトル値の積分値を識別のための特徴量とした²⁷⁾。

2.2.2 ウェーブレット変換

ウェーブレット変換とは、周波数領域の表現を可能にするフーリエ解析の特徴を生かしつつ、信号の時間的または空間的推移を同時に捉えることができる時間周波数解析手法の1つである³⁹⁾。関数 $f(x)$ に対するウェーブレット変換式は式 (2.13) で与えられる。

$$W_\psi(b, a) = \int_{-\infty}^{\infty} \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) f(x) dx \quad (2.13)$$

式 (2.13) における b はトランスレート・パラメータ、 a はスケール・パラメータ、 $\psi(x)$ はマザー・ウェーブレットを示す。以下に代表的なウェーブレットの種類を示す³⁹⁾。

- Haar ウェーブレット

Haar ウェーブレットは Haar によって 1909 年頃作られた関数であり、スケーリング関数 $\phi_H(x)$ とマザーウェーブレット $\psi_H(x)$ の組をなす。スケーリング関数を式 (2.14)、マザーウェーブレットを式 (2.15) に示す。

$$\phi_H(x) = \begin{cases} 1, & -1 \leq x < 1 \\ 0, & \text{otherwise} \end{cases} \quad (2.14)$$

$$\psi_H(x) = \begin{cases} 1, & 0 \leq x < 1/2 \\ -1, & 1/2 \leq x < 1 \\ 0, & \text{otherwise} \end{cases} \quad (2.15)$$

- Gabor ウェーブレット

Gabor ウェーブレットは Gabor 変換 (式 (2.16)) の欠点を改善したマザーウェーブレットである。式 (2.17) に Gabor ウェーブレットの式を示す。式 (2.17) における σ は実数である。Fig. 10 に $\sigma=8$ の場合における Gabor のマザーウェーブレットの実部を示す。このマザーウェーブレットは連続ウェーブレット変換に適しているが、基底関数ではないため離散ウェーブレット変換には適していない。Gabor ウェーブレットは Morlet のウェーブレットと呼ばれることもある。

$$\hat{f}(\omega, b) = \int_{-\infty}^{\infty} \frac{1}{2\sqrt{\pi}\sigma} e^{-\frac{(x-b)^2}{\sigma^2}} e^{-i\omega x} f(x) dx \quad (2.16)$$

$$\psi(x) = \frac{1}{2\sqrt{\pi}\sigma} e^{-\frac{x^2}{\sigma^2}} e^{-ix} \quad (2.17)$$

- メキシカン・ハット

メキシカン・ハットは Gabor ウェーブレットに類似しており、ガウス関数の 2 階導関数を使用する。式 (2.18) にメキシカン・ハットの式を示す。式 (2.18) は Fig. 11 のような関数である。

$$-\frac{1}{2} \frac{d^2}{dx^2} e^{-x^2} = (1 - 2x^2) e^{-x^2} \quad (2.18)$$

- フレンチ・ハット

フレンチ・ハットはメキシカン・ハットの滑らかさを犠牲にし、全体的な形を区分的に近似した関数である。フレンチ・ハットは式 (2.19) と定義される。

$$\psi(x) = \begin{cases} 1, & -1 \leq x < 1 \\ -1/2, & -3 \leq x < -1, \quad 1 \leq x < 3 \\ 0, & \text{otherwise} \end{cases} \quad (2.19)$$

- Shannon ウェーブレット

Shannon ウェーブレットは式 (2.20) で定義され、これを Fig. 12 に示す。

$$\psi(x) = 2f(2x) - f(x), \quad f(x) = \frac{\sin \pi x}{\pi x} \quad (2.20)$$

- Meyer ウェーブレット

Meyer ウェーブレットはフーリエ変換を用いた直交ウェーブレットであり、式 (2.21) で定義される。ただし、 $\hat{f}(x)$ は式 (2.22)、 $g(x)$ は式 (2.23)、 $\phi(x)$ は式 (2.24)、 n は実数である。 $\psi(x)$ はコンパクト・サポートではないが無限回微分可能である。 $n = 3$ の時の $\psi(x)$ を Fig. 13 に示す。

$$\psi(x) = 2\phi(2x-1) - \phi(x-1/2) \quad (2.21)$$

$$\hat{f}(x) = \left(\frac{g(2 \mp 3\omega/2\pi)}{g(1)} \right)^{1/2} \quad (2.22)$$

$$g(\omega) = \int_0^\omega t^n(1-t)^n dt, \quad 0 \neq \omega \quad (2.23)$$

$$\phi(x) = \frac{1}{2\pi} \int_{-\infty}^\infty \hat{f}(x) e^{i\omega x} d\omega \quad (2.24)$$

- Daubechies ウェーブレット

Daubechies ウェーブレットは Daubechies により作られた直交ウェーブレットであり、直交基底を作る連続、且つサポート・コンパクトなウェーブレットを実現した。これは自然数 N によって番号付けられた一連のスケーリング関数 ${}_N\phi(x)$ 、その N に対応するウェーブレット ${}_N\psi(x)$ と表す。 ${}_1\phi(x)$ と ${}_1\psi(x)$ はそれぞれ Haar のスケーリング関数とウェーブレットとなる。 ${}_2\phi(x)$ 、 ${}_2\psi(x)$ はそれぞれ式 (2.25)、式 (2.26) となる。式 (2.25) において $p_k \neq 0, (k = 0, 1, 2, 3)$ 、且つ $p_k = 0, (k \neq 0, 1, 2, 3)$ とする。また、式 (2.26) における q_k は 0 でない任意の連続する 4 つの整数とする。Fig. 14 に $N = 3$ と $N = 8$ の Daubechies のウェーブレットを示す。

$$\phi(x) = \sum_{k \in \mathbb{Z}} p_k \phi(2x - k) \quad (2.25)$$

$$\psi(x) = \sum_{k \in \mathbb{Z}} q_k \phi(2x - k) \quad (2.26)$$

- Symlet

Daubechies のウェーブレットは対称性を持たないため、Symlet はこの問題点を改良するために非対称性を極力抑えた直交ウェーブレットである。Fig. 15 に $N = 4$ と $N = 7$ の Symlet を示す。

- Coiflet

Coiflet のウェーブレットは Daubechies のマザーウェーブレット (式 (2.26)) において式 (2.27) の条件を満たすウェーブレットである。Fig. 16 に $N = 4$ の Coiflet を示す。

$$\int_{-\infty}^\infty x^l \phi(x) dx = 0, \quad l = 1, \dots, N-1 \quad (2.27)$$

本稿では、運動イメージを行った区間の脳波に対し Gabor ウェーブレットの適用後、絶対値をとりその特定の周波数帯域における平均値と標準偏差を識別のための特徴量とした³¹⁾。

2.2.3 デジタルフィルタ

デジタルフィルタとは、デジタル信号において入力信号から特定の成分を抽出し、出力信号を得る働きをするものである。デジタルフィルタで最も使用されるフィルタは IIR (Infinite Impulse Response) フィルタと FIR (Finite Impulse Response) フィルタである。

IIR フィルタとはインパルス応答が無限に続くフィルタであり、式 (2.28) で与えられる⁴⁰⁾。ここで、 x_i は入力、 y_i は出力、 a_m は x_i の重み、 b_m は y_i の重みを示す。Fig. 17 に IIR フィルタのブロック図を示す。

$$y_i = \sum_{k=0}^{K-1} a_k x_{i-k} + \sum_{m=1}^M b_m y_{i-m} \quad (2.28)$$

FIR フィルタとはインパルス応答の継続時間が有限なフィルタであり、式 (2.29) で与えられる⁴⁰⁾。ここで、 x_i は入力、 y_i は出力、 N はフィルタオーダー、 h_n はフィルタ係数を示す。Fig. 18 に FIR フィルタのブロック図を示す。

$$y_n = \sum_{n=0}^{N-1} h_n x_{i-n} \quad (2.29)$$

識別のための特徴量として使用する特定の周波数帯域をバンドパス FIR フィルタにより抽出する。今回の実験は $N = 20$ を使用した。その後、運動イメージ時の脳波を二乗し平均値をとり、それらを左右識別のための特徴量とした³²⁾。

3 肘関節屈曲運動イメージにおける左右識別のための特徴量の検討

先行研究²⁷⁻³³⁾では運動イメージを1秒以上行い、イメージ中の全ての時間における脳波から特徴量を抽出している。しかし、実際に運動を行なっている場面でのBMIの利用を考慮すると、イメージには1秒以上の時間を要しないため、不必要な脳波のデータ処理も行なっている可能性がある。そのため、解析に用いるウィンドウ幅を1秒以内とするオーバーラップ処理を用いて特徴量を抽出し運動イメージの左右識別を行った。次節にオーバーラップ処理を用いた特徴量の抽出方法について述べる。

3.1 オーバーラップ処理を用いた特徴量抽出方法

本手法では、EEGによって測定された脳波にウィンドウ幅を1秒以下に設定した周波数解析のオーバーラップ処理を行い、識別のための特徴量を抽出する。周波数解析としてFFTとウェーブレット変換を使用した。オーバーラップ処理を用いることで最も強く運動をイメージできた時間を算出し、左右識別に有効な特徴量が抽出可能であると考えられる。以下にFFT、もしくはウェーブレット変換を用いたオーバーラップ処理について述べる。

3.1.1 FFTを用いたオーバーラップ処理

FFTを用いたオーバーラップ処理は、周波数解析においてパワースペクトルを評価する際に有効な手法として用いられている^{41,42)}。また、本手法では左右の運動野付近において運動イメージ時のパワースペクトルの差が最大となる時間を算出する。以下に特徴量抽出の手順を示す。

Step.1 感覚運動野付近に位置し、左右半球において対称に位置しているC3-C4, FC1-FC2, FC5-FC6, CP1-CP2の4パターンのチャンネルの組み合わせに着目する。Fig. 19にこれらのチャンネルの測定位置を示す。

Step.2 Step.1で着目したチャンネルの脳波に対して、運動イメージを開始した時間からFFTのウィンドウ幅までの脳波に、ハミング窓をかけFFTを行う。

Step.3 FFTから得られた値の絶対値をとり、パワースペクトルの積分値を算出する。

Step.4 ハミング窓を1サンプル移動し、FFTを行う。

Step.5 Step.2 - 4を運動イメージが終わる時間まで繰り返す。

Step.6 左右の運動野におけるパワースペクトル積分値の差の絶対値が最大となる時間を算出し、その時間をFFT開始時間とする。Fig. 20は左肘関節屈曲運動の運動イメージ時において、ある測定チャンネルA, Bのパワースペクトル値の差が最大となる時間が510msであることを表している。

Step.7 ある1つの測定チャンネルに対して、Step.6 で得られた開始時間からFFTのサンプル数までの脳波に、ハミング窓をかけFFTを行う。

Step.8 Step.7 で得られた値のパワースペクトル積分値を算出する。

Step.9 Step.7-8 を全ての測定チャンネルで行い、左右識別のための特徴量として用いる。

FFTの開始時間を決定する際、運動に関係する脳波である β 波に着目する。

3.1.2 ウェーブレット変換を用いたオーバーラップ処理

本手法では左右の運動野付近において運動イメージ時のウェーブレット係数の平均値の差が最大となる時間を算出する。以下に特徴量抽出の手順を示す。

Step.1 感覚運動野付近に位置し、左右半球において対称に位置しているC3-C4, FC1-FC2, FC5-FC6, CP1-CP2の4パターンのチャンネルの組み合わせに着目する。

Step.2 Step.1 で着目したチャンネルの脳波に対して、運動イメージを開始した時間からウィンドウ幅までの脳波にウェーブレット変換を行う。

Step.3 ウェーブレット変換により得られたウェーブレット係数の絶対値をとり、特定の周波数帯域におけるウェーブレット係数の平均値を算出する。

Step.4 解析のためのウィンドウを1サンプル移動し、Step.2, 3を行う。

Step.5 Step.2-4 を運動イメージが終わる時間まで繰り返す。

Step.6 左右の運動野におけるウェーブレット係数の平均値の差の絶対値が最大となる時間を算出し、その時間をウェーブレット変換開始時間とする。

Step.7 ある1つの測定チャンネルに対して、Step.6 で得られた開始時間からウィンドウ幅までの脳波にウェーブレット変換を行いウェーブレット係数の絶対値をとる。

Step.8 Step.7 で得られた値の特定の周波数帯域におけるウェーブレット係数の平均値を算出する。

Step.9 Step.7-8 を全ての測定チャンネルで行い、左右識別のための特徴量として用いる。

ウェーブレット変換におけるマザーウェーブレットとして既存手法と同様にGaborウェーブレットを使用した³¹⁾。また、ウェーブレット変換の開始時間を決定する際、FFTを用いたオーバーラップ処理と同様に β 波に着目する。

3.2 実験概要

本実験では、左右の肘関節屈曲運動におけるMIの脳波を計測し、3種類の周波数解析により抽出された特徴量の識別率と識別に使用される特徴量を抽出するためのウィンドウ幅について検討した。

被験者は、年齢：22～24 歳，利き腕：左 1 名，右 19 名の成人男性計 20 名である．被験者には、事前に本実験の趣旨，方法，課題等について十分に説明し，実験に関する同意を得た．

生体計測器としてティアック社の Polymate AP1532，アクティブ電極変換器として g.tec 社の g.GAMMAbox を使用した．サンプリング周波数は 1kHz，AD 変換器は 16bit である．電極の設置方法は国際 10-20 法³⁴⁾を参考に行い，基準電極を A1，A2，接地電極を AFz とした．探査電極は計 8 個を使用した．Fig. 21 に測定部位を示す．

課題の流れは先行研究⁴³⁾を参考に設計した．レスト及びタスクは 17 インチのディスプレイを用いて提示した．Fig. 23 に課題の流れを示す．レストでは画面中央に「+」を 5 秒間表示し，被験者はそれを注視する．タスクでは画面中央に左右のどちらかを向く矢印を 1.25 秒間表示し，被験者はその矢印が示す方向の腕における屈曲運動を 1 回のみイメージする．矢印の表示回数は，左右でそれぞれ 10 回ずつであり，被験者は 1 つの課題に対し計 20 回の運動イメージを行う．1 つの課題の合計施行時間は 130 秒である．また，それぞれの被験者はこの課題を 5 回ずつ行ったため，計 100 回の運動イメージを試行した．

被験者は椅子に座った状態で課題を行い，被験者と画面の距離を 70cm とした．また被験者は肘を机の上に置き，左右の前腕を肩幅，且つ画面と垂直にし，軽く握りこぶしを作り手の甲を下にした状態で課題を行った．Fig. 22 に実験風景を示す．

3.3 識別方法

運動に関係する脳波である β 波と μ 波に着目し左右識別のための特徴量として用いた． β 波の帯域は 13–30Hz であり⁴⁴⁾，その中に含まれる 13–16Hz は low β 帯域と呼ばれている^{32,45)}．今回， β 波の帯域が 13–16Hz と 13–30Hz の場合について手法を適用した．そのため，左右識別のための特徴量は β 波の帯域 (13–16Hz または 13–30Hz) と μ 波の帯域 (8–12Hz) を用いた．

識別方法には，SVM (Support Vector Machine) を用いた．SVM は入力空間を高次元特徴空間に写像することにより，線形分離性を高める性質を持つ⁴⁶⁾．SVM では高次元特徴空間へ写像するためにカーネル関数 $K(\mathbf{x}, \mathbf{x}')$ が使用される．カーネル関数として線形カーネル，多項式カーネル，ラジアル基底関数カーネル，3 層ニューラルネットカーネルがあり⁴⁶⁾，本実験ではラジアル基底関数カーネルを使用した．ラジアル基底関数カーネルは式 (3.1) で定義される．式 (3.1) における γ は分布の関係を制御するパラメータである．

$$K(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (3.1)$$

SVM はカーネル関数を用いて入力空間を写像した後，線形分離を行う．線形分離は式 (3.2) に基づき行われる．式 (3.2) における \mathbf{w}^T は m 次元係数ベクトル， b はバイアス項である．

$$D(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (3.2)$$

\mathbf{w}^T を決定するためにマージン最大化が用いられる．マージン最大化とは，クラス間に引かれる判別境界と各クラスに属するデータのなかで判別境界に最も近いデータとの距離（マージン）が最も大きくなるような判別境界を引く概念である．判別境界を引く際に用いられるものが SV (Support Vector) である．これにより，SVM は未学習データに対して高い汎化性能を持つことが知られている⁴⁷⁾．Fig. 24 に SVM における識別例を示す．

今回の実験では識別に用いるチャンネルの数を 2-8 とした．例えば，識別に用いるチャンネルの数が 2 の場合，1 つのチャンネルで β 波と μ 波の帯域における特徴量がそれぞれ 1 個ずつあるため，計 4 個の特徴量を用いて識別を行う．また，測定チャンネルが 28 個あるため， ${}_{28}C_2 = 378$ 通りの組み合わせが成立する．全ての組み合わせにおける識別率を算出し，最も識別率が高いチャンネルの組み合わせの識別率を使用した．これらのチャンネルは，識別のための特徴量を抽出する開始時間を決定するために使用したチャンネルと同一でなくともよい．

識別の評価として， K -fold Cross Validation を用いた． K -fold Cross Validation とは，任意の統計量の推定法の 1 つである．標本点の集合を K 個の標本群に分割し，そのうちの 1 つをテスト事例，残る $K-1$ 個を訓練事例とする．その後， K 個に分割した標本群それぞれテスト事例として K 回検定を行う． K 回の実験を繰り返すことで，全てのデータをテスト事例として用いることができる．このようにして得られた K 回の結果を平均して 1 つの推定値を得る⁴⁸⁾．本実験では， $K = 4$ を使用した．

3.4 実験結果と考察

Fig. 25 に FFT，ウェーブレット変換，FIR フィルタの各周波数解析手法を用いた時の識別率について示す．また，Fig. 25 で示した識別率はオーバーラップ処理を使用しない手法で特徴量を抽出した結果である．Fig. 25(a)，Fig. 25(b) より各 β 帯域において FIR フィルタを用いて抽出した特徴量の識別率は，FFT やウェーブレット変換を用いた時の識別率より低い結果であった．そのため，FIR フィルタによる特徴量抽出は左右識別に適さないと考え，以下の結果は FFT とウェーブレット変換を用いた時の識別率について述べる．

Fig. 26 に FFT を用いて各 β 帯域から特徴量を抽出した時の各被験者における識別率の結果を箱ひげ図として示す．ウィンドウ幅が 256，512 の時はオーバーラップ処理を行い，1250 の時はオーバーラップ処理を行っていない時の識別率である．Fig. 26(a)，Fig. 26(b) よりオーバーラップ処理を行った場合の識別率の方がオーバーラップ処理を行わなかった場合の識別率より分散が小さい．このことから，オーバーラップ処理を行うことで被験者に依らず安定した識別率を得ることができたと考える．また，Fig. 26(a)，Fig. 26(b) よりウィンドウ幅を 512 にした時の結果はウィンドウ幅を 256 にした時の結果より識別率の上側ヒンジと中央値が高く，且つ被験者間の分散が小さかった．ウィンドウ幅が 256 の時の識別率と 512 の時の識別率に対し Welch の t 検定を有意水準 5%で行った結果，有意差が得られたことより，FFT を使用する時はウィンドウ幅を 512 にするべきであると考えられる．

Fig. 27 にウェーブレット変換を用いて各 β 帯域から特徴量を抽出した時の識別率の結果

を箱ひげ図として示す。ウィンドウ幅が 128, 256, 512 の時はオーバーラップ処理を行い、1250 の時はオーバーラップ処理を行っていない時の識別率である。Fig. 27(a), Fig. 27(b) よりウィンドウ幅を 128 とした時、識別率の中央値が最も低い結果であった。この結果から、128 のウィンドウ幅は左右の運動イメージの解析区間として不十分であることが分かる。各 β 帯域においてウィンドウ幅が 256, 512, 1250 の時の全被験者の識別率に対し、一元配置分散分析を有意水準 5%で行った結果、有意差が得られなかった。しかし、ウィンドウ幅が 256, 512 の時の中央値はウィンドウ幅が 1250 の時より高い結果であった。また、BMI システムにはリアルタイム処理が必要であり、解析区間を短くすることでシステム応答をより早くすることができる。そのため、ウェーブレット変換を使用する際はウィンドウ幅を 256 にするべきであると考ええる。

Fig. 28 にウィンドウ幅が 512, 且つ FFT を用いた時の各被験者における識別率を示す。Fig. 28 より、被験者 C, E, F, I, N, O, Q, T において特徴量として使用する周波数帯域により識別率に 5%以上の差が得られた。また、Fig. 29 にウィンドウ幅が 256, 且つウェーブレット変換を用いた時の各被験者における識別率を示す。Fig. 29 より、被験者 A, D, I, M において FFT を用いた時と同様に特徴量として使用する周波数帯域により識別率に 5%以上の差が得られた。これらの結果から、更なる識別率の向上には各被験者において特徴量を抽出するために使用する周波数帯域の選択が必要であると考ええる。

4 結論

本稿では、左右の肘関節屈曲運動における運動イメージ時の脳波を計測し、解析の際のウィンドウ幅を変化させた時の左右の運動イメージにおける識別率を検討した。ウィンドウ幅を1秒以下に設定し特徴量を抽出する際はオーバーラップ処理を使用した。既存手法は1秒以上の脳波に対しFFTやウェーブレット変換、FIRフィルタから抽出された特徴量を用いて運動イメージの左右識別を行った。本実験ではオーバーラップ処理を使用し、既存手法と同様の周波数解析を用いて1秒以下の脳波から特徴量を抽出し、左右識別を行った。特徴量として用いる β 波の帯域を13–16Hz、または13–30Hz、 μ 帯域を8–12Hzとし、20人の被験者に対しSVMを用いて識別を行った。既存手法により抽出された特徴量を用いて識別を行った時、 β 帯域が13–16Hz、または13–30Hzの場合においてFIRフィルタの識別率はFFTやウェーブレット変換を用いた時の識別率より低い結果となった。FFTとウェーブレット変換についてオーバーラップ処理を行った結果、両周波数解析手法においてオーバーラップ処理を行うことで識別率の向上が見られた。FFTを用いたオーバーラップ処理では、ウィンドウ幅を512とした場合、最も良い結果が得られた。またウェーブレット変換を用いたオーバーラップ処理では、ウィンドウ幅を256とした場合、最も良い結果が得られた。また、特徴量として使用する周波数帯域により識別率に5%以上の差が得られた被験者がいたため、更なる識別率の向上には各被験者において特徴量を抽出するために使用する周波数帯域の選択が必要であると考えられる。

謝辞

本研究を遂行するにあたり、3年間に渡って熱心なご指導ご鞭撻を頂きました、同志社大学生命医科学部の廣安知之教授に心より感謝致します。また、本研究を進める上で多くのご助言と丁寧なご指導を頂きました、同志社大学生命医科学部の山本詩子助教と同志社大学理工学部の中中美里特別任用助教に心より感謝致します。私の研究を進める上で多くのご助言と、本論文の修正に多大なる時間を割いて頂いた同志社大学生命医科学研究科博士前期課程の中村友香氏と吉田倫也氏に心より感謝致します。さらに、本研究を遂行するにあたり活発な議論をして頂いたBMI班の皆様や、実験の際の被験者を快諾してくださった研究室の皆様は心よりお礼申し上げます。最後に研究生生活を経済的、精神的に支えてくれた家族と心の支えとなった方々に深く感謝し、修士論文とします。

参考文献

- 1) G.L. Ahern and G.E. Schwartz, “Differential lateralization for positive and negative emotion in the human brain: EEG spectral analysis,” *Neuropsychologia*, Vol.23, No.6, pp.745–755, 1985.
- 2) A. Villringer, J. Planck, C. Hock, L. Schleinkofer and U. Dirnagl, “Near infrared spectroscopy (NIRS): A new tool to study hemodynamic changes during activation of brain function in human adults,” *Neuroscience Letters*, Vol.154, No.12, pp.101–104, 1993.
- 3) S. Perrey, “Non-invasive NIR spectroscopy of human brain function during exercise,” *Methods*, Vol.45, No.4, pp.289–299, 2008.
- 4) B. Biswal, F.Z. Yetkin, V.M. Haughton and J.S. Hyde, “Functional connectivity in the motor cortex of resting human brain using echo-planar mri,” *Magnetic Resonance in Medicine*, Vol.34, No.4, pp.537–541, 1995.
- 5) P.A. Bandettini, A. Jesmanowicz, E.C. Wong and J.S. Hyde, “Processing strategies for time-course data sets in functional mri of the human brain,” *Magnetic Resonance in Medicine*, Vol.30, No.2, pp.161–173, 1993.
- 6) 市川忠彦, 脳波の旅への誘い, 星和書店, 2006.
- 7) 末永和栄, 最新脳波標準テキスト, メディカルシステム研修所, 2004.
- 8) 酒谷 薫, NIRS -基礎と臨床-, 新興医学出版社, 2012.
- 9) S. Ogawa, T.M. Lee, A.R. Kay and D.W. Tank, “Brain magnetic resonance imaging with contrast dependent on blood oxygenation,” *The National Academy of Sciences of the United States of America*, Vol.87, No.24, pp.9868–9872, 1990.
- 10) S.A. Huettel, A.W. Song and G. McCarthy., *Functional Magnetic Resonance Imaging*, 2nd edition, Sinauer Associates Inc, 2009.
- 11) S. Fazli, J. Mehnert, J. Steinbrink, G. Curio, A. Villringer, K.R. Muller and B. Blankertz, “Enhanced performance by a hybrid nirs-eeeg brain computer interface,” *NeuroImage*, Vol.59, No.1, pp.519–529, 2012.
- 12) G. Schalk, D.J. McFarland, T. Hinterberger, N. Birbaumer and J.R. Wolpaw, “BCI2000: a general-purpose brain-computer interface (BCI) system,” *IEEE Transactions on Biomedical Engineering*, Vol.51, No.6, pp.1034–1043, 2004.
- 13) E. Buch, C. Weber, L.G. Cohen, C. Braun, M.A. Dimyan, T. Ard, J. Mellinger, A. Caria, S. Soekadar, A. Fourkas and N. Birbaumer, “Think to move: a neuromagnetic

- brain-computer interface (BCI) system for chronic stroke,” *Stroke*, Vol.39, No.3, pp.910–917, 2008.
- 14) 長谷川良平, “ブレイン-マシン インターフェースの現状と将来,” 電子情報通信学会誌, Vol.91, No.12, pp.1066–1075, 2008.
 - 15) T. Weiss, E. Hansen, R. Rost, L. Beyer, F. Merten, C. Nichelmann and C. Zippel, “Mental Practice of Motor Skills Used in Poststroke Rehabilitation has Own Effects on Central Nervous Activation,” *International Journal of Neuroscience*, Vol.78, No.3-4, pp.157–166, 1994.
 - 16) G. Pfurtscheller and C. Neuper, “Future prospects of ERD/ERS in the context of brain-computer interface (BCI) developments,” in *Event-Related Dynamics of Brain Oscillations*, Vol.159, pp.433–437, Elsevier Science, 2006.
 - 17) D.J. McFarland, L.A. Miner, T.M. Vaughan and J.R. Wolpaw, “Mu and beta rhythm topographies during motor imagery and actual movements,” *Brain Topography*, Vol.12, No.3, pp.177–186, 2000.
 - 18) J.R. Wolpaw, D. Flotzinger, G. Pfurtscheller and D.J. McFarland, “Timing of EEG-based cursor control,” *Journal of Clinical Neurophysiology*, Vol.14, pp.529–538, 1997.
 - 19) D. Huang, K. Qian, D.Y. Fei, W. Jia, X. Chen and O. Bai, “Electroencephalography (eeg)-based brain-computer interface (BCI): A 2-d virtual wheelchair control based on event-related desynchronization/synchronization and state control,” *Neural Systems and Rehabilitation Engineering*, Vol.20, No.3, pp.379–388, 2012.
 - 20) R. Chai, S.H. Ling, G.P. Hunter and H.T. Nguyen, “Toward fewer eeg channels and better feature extractor of non-motor imagery mental tasks classification for a wheelchair thought controller,” in *Engineering in Medicine and Biology Society (EMBC)*, pp.5266–5269, 2012.
 - 21) G. Pfurtscheller, C. Neuper, A. Schlogl and K. Lugger, “Separability of eeg signals recorded during right and left motor imagery using adaptive autoregressive parameters,” *IEEE Transactions on Rehabilitation Engineering*, Vol.6, No.3, pp.316–325, 1998.
 - 22) A. Schlogl, F. Lee, H. Bischof and G. Pfurtscheller, “Characterization of four-class motor imagery eeg data for the BCI-competition 2005,” *Journal of Neural Engineering*, Vol.2, No.4, pp.14–22, 2005.
 - 23) G. Pfurtscheller, C. Brunner, A. Schlogla and F.H.L. daSilva, “Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks,” *NeuroImage*, Vol.31, No.1, pp.153–159, 2006.

- 24) J. Decety and D.H. Ingvar, "Brain structures participating in mental simulation of motor behavior: A neuropsychological interpretation," *Acta Psychologica*, Vol.73, No.1, pp.13–34, 1990.
- 25) M. Jeannerod and V. Frak, "Mental imaging of motor activity in humans," *Current Opinion in Neurobiology*, Vol.9, No.6, pp.735–739, 1999.
- 26) G. Pfurtscheller and C. Neupe, "Motor imagery activates primary sensorimotor area in humans," *Neuroscience Letters*, Vol.239, No.23, pp.65–68, 1997.
- 27) M. Polak and A. Kostov, "Feature extraction in development of brain-computer interface: a case study," in *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, Vol.4, pp.2058–2061, 1998.
- 28) P. Herman, G. Prasad, T.M. McGinnity and D. Coyle, "Comparative analysis of spectral approaches to feature extraction for eeg-based motor imagery classification," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol.16, No.4, pp.317–326, 2008.
- 29) W. Ting, Y. Guo-zheng, Y. Bang-hua and S. Hong, "EEG feature extraction based on wavelet packet decomposition for brain computer interface," *Measurement*, Vol.41, No.6, pp.618–625, 2008.
- 30) W. Hsu and Y. Sun, "EEG-based motor imagery analysis using weighted wavelet transform features," *Journal of Neuroscience Methods*, Vol.176, No.2, pp.310–318, 2009.
- 31) B. Xu and A. Song, "Pattern recognition of motor imagery eeg using wavelet transform," *Journal of Biomedical Science and Engineering*, Vol.1, pp.64–67, 2008.
- 32) N. A. Moubayed, B.A. Hasan, J.Q. Gan, A. Petrovski and J. McCall, "Continuous presentation for multi-objective channel selection in Brain-Computer Interfaces," in *2012 IEEE Congress on Evolutionary Computation (CEC)*, pp.1–7, 2012.
- 33) E. Haselsteiner and G. Pfurtscheller, "Using time-dependent neural networks for EEG classification," *IEEE Transactions on Rehabilitation Engineering*, Vol.8, No.4, pp.457–463, 2000.
- 34) V. Jurcak, D. Tsuzuki and I. Dan, "10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems," *NeuroImage*, Vol.34, No.4, pp.1600–1611, 2007.

- 35) M. Pregenzer, G. Pfurtscheller and D. Flotzinger, “Automated feature selection with a distinction sensitive learning vector quantizer,” *Neurocomputing*, Vol.11, No.1, pp.19–29, 1996.
- 36) S.M. Zhou, J.Q. Gan and F. Sepulveda, “Classifying mental tasks based on features of higher-order statistics from EEG signals in brain-computer interface,” *Information Sciences*, Vol.178, No.6, pp.1629–1640, 2008.
- 37) Y. Wang, S. Gao and X. Gao, “Common spatial pattern method for channel selection in motor imagery based brain-computer interface,” in *Engineering in Medicine and Biology Society*, pp.5392–5395, 2005.
- 38) 本郷哲, 菅野裕佳, 田中達彦, デジタル信号処理の基本と応用, SoftBank Creative, 2008.
- 39) 榊原 進, ウェーブレットビギナーズガイド, 東京電機大学出版局, 1995.
- 40) 本郷 哲, 菅野裕佳, 田中達彦, デジタル信号処理の基本と応用, ソフトバンククリエイティブ, 2008.
- 41) K. Li, X. Li, S. Ma and G.W. Irwin, *Life System Modeling and Intelligent Computing*, Springer, 2010.
- 42) G. Pfurtscheller, G.R. Muller-Putz, A. Schlogl, B. Graimann, R. Scherer, R. Leeb, C. Brunner, C. Keinrath, F. Lee, G. Townsend, C. Vidaurre and C. Neuper, “15 years of BCI research at Graz University of technology: current projects,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol.14, No.2, pp.205–210, 2006.
- 43) O. Carrera-Leon, J.M. Ramirez, V. Alarcon-Aquino, M. Baker, D. D’Croz-Baron and P. Gomez-Gil, “A motor imagery BCI experiment using wavelet analysis and spatial patterns feature extraction,” in *2012 Workshop on Engineering Applications (WEA)*, pp.1–6, 2012.
- 44) A.K. Engel and P. Fries, “Beta-band oscillations - signalling the status quo?,” *Current Opinion in Neurobiology*, Vol.20, No.2, pp.156–165, 2010.
- 45) H. Laufs, J.L. Holt, R. Elfont, M. Krams, J.S. Paul, K. Krakow and A. Kleinschmidt, “Where the BOLD signal goes when alpha EEG leaves,” *NeuroImage*, Vol.31, No.4, pp.1408–1418, 2006.
- 46) 阿部重夫, パターン認識のためのサポートベクトルマシン入門, 森北出版株式会社, 2011.
- 47) 宮越喜浩, 加藤昇平, “重み付き学習ベイジアンネットワークを用いた欠損値補完手法,” *電気学会論文誌 C*, Vol.132, No.2, pp.299–305, 2012.

- 48) 井之上直矢, 山下幸彦, “標本点ごとにカーネルパラメータを学習するサポートベクターマシン,” 電子情報通信学会技術研究報告. IBISML, 情報論的学習理論と機械学習, Vol.110, No.265, pp.265–270, 2010.

付 図


1	非侵襲脳機能計測装置	1
2	神経細胞	1
3	実際に計測される脳波の一例	1
4	電極と大脳皮質	2
5	脳波計の原理	2
6	差動増幅器の仕組み	2
7	国際 10-20 法を用いた電極の配置図	3
8	ハニング窓の概形	3
9	ハミング窓の概形	3
10	$\sigma = 8$ の場合における Gabor のマザーウェーブレットの実部	4
11	メキシカン・ハット	4
12	Shannon ウェーブレット	4
13	$n = 3$ の時の Meyer ウェーブレット	5
14	$N = 3$ と $N = 8$ の Daubechies ウェーブレット	5
15	$N = 4$ と $N = 7$ の Symlet	5
16	$N = 4$ の Coiflet	6
17	IIR フィルタのブロック図	6
18	FIR フィルタのブロック図	6
19	運動野付近の測定チャンネル	7
20	FFT 開始時間決定の例	7
21	測定部位	8
22	実験風景	8
23	課題の流れ	8
24	SVM の識別例	9
25	各周波数解析を使用した時の識別率	9
26	FFT を使用した時の各ウィンドウ幅における識別率	10
27	ウェーブレット変換を使用した時の各ウィンドウ幅における識別率	11
28	FFT を用いた時の各被験者における識別率 (ウィンドウ幅 : 512)	11
29	ウェーブレット変換を用いた時の各被験者における識別率 (ウィンドウ幅 : 256)	12



(a) EEG



(b) NIRS 装置



(c) MRI 装置

Fig. 1 非侵襲脳機能計測装置




Fig. 2 神経細胞




Fig. 3 実際に計測される脳波の一例




Fig. 4 電極と大脳皮質




Fig. 5 脳波計の原理

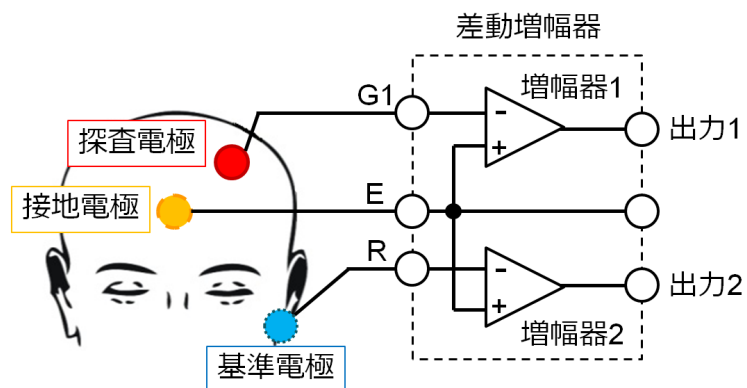


Fig. 6 差動増幅器の仕組み




Fig. 7 国際 10-20 法を用いた電極の配置図




Fig. 8 ハニング窓の概形




Fig. 9 ハニング窓の概形




Fig. 10 $\sigma = 8$ の場合における Gabor のマザーウェーブレットの実部




Fig. 11 メキシカン・ハット




Fig. 12 Shannon ウェーブレット




Fig. 13 $n = 3$ の時の Meyer ウェーブレット




Fig. 14 $N = 3$ と $N = 8$ の Daubechies ウェーブレット




Fig. 15 $N = 4$ と $N = 7$ の Symlet




Fig. 16 $N = 4$ の Coiflet

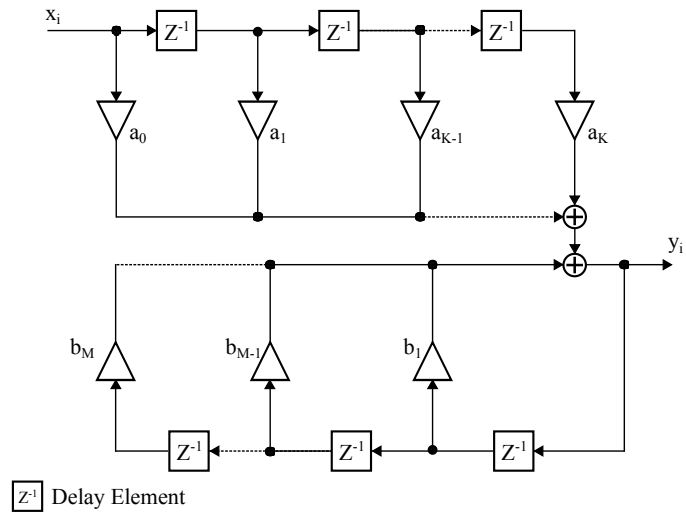


Fig. 17 IIR フィルタのブロック図

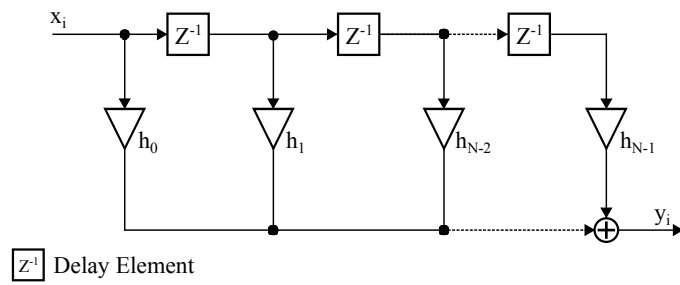


Fig. 18 FIR フィルタのブロック図




Fig. 19 運動野付近の測定チャンネル




Fig. 20 FFT 開始時間決定の例




Fig. 21 測定部位




Fig. 22 実験風景

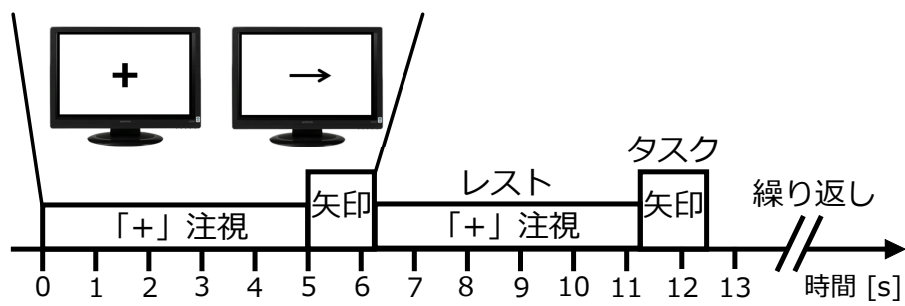


Fig. 23 課題の流れ


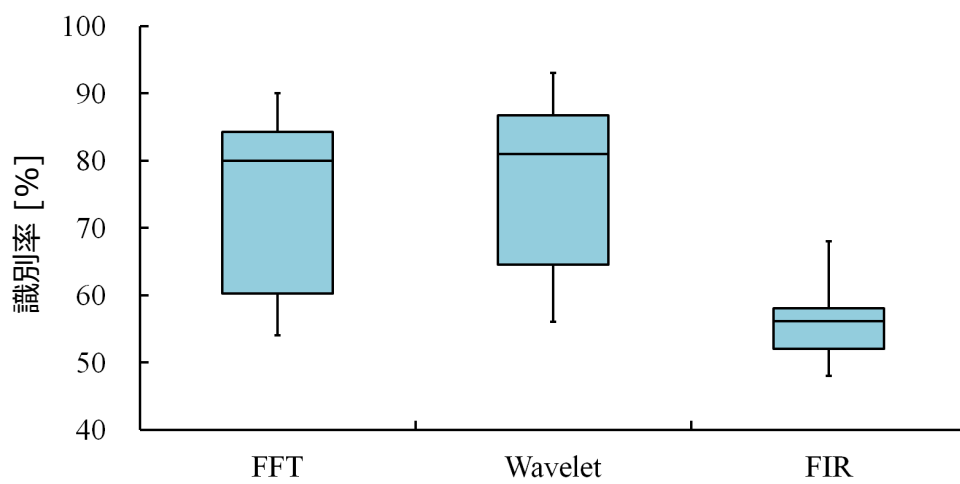



Fig. 24 SVM の識別例




(a) β 帯域 : 13-16Hz




(b) β 帯域 : 13-30Hz

Fig. 25 各周波数解析を使用した時の識別率




(a) β 帯域 : 13-16Hz




(b) β 帯域 : 13-30Hz

Fig. 26 FFT を使用した時の各ウィンドウ幅における識別率



(a) β 帯域 : 13-16Hz



(b) β 帯域 : 13-30Hz

Fig. 27 ウェーブレット変換を使用した時の各ウィンドウ幅における識別率

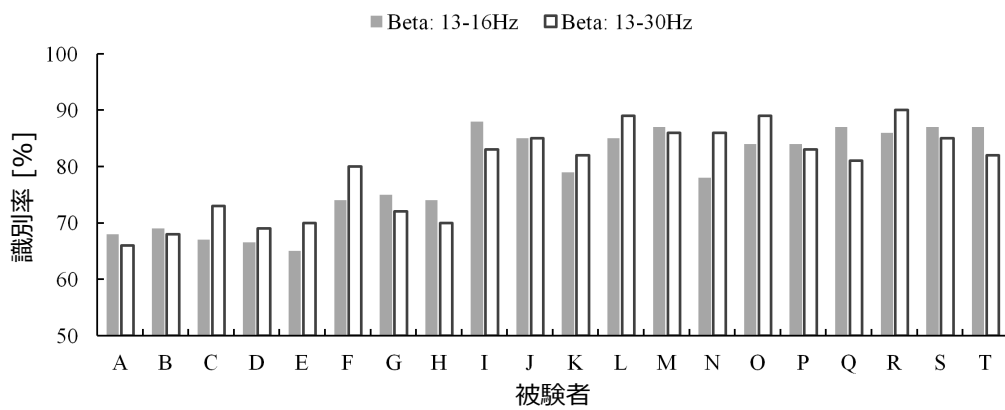


Fig. 28 FFT を用いた時の各被験者における識別率 (ウィンドウ幅 : 512)

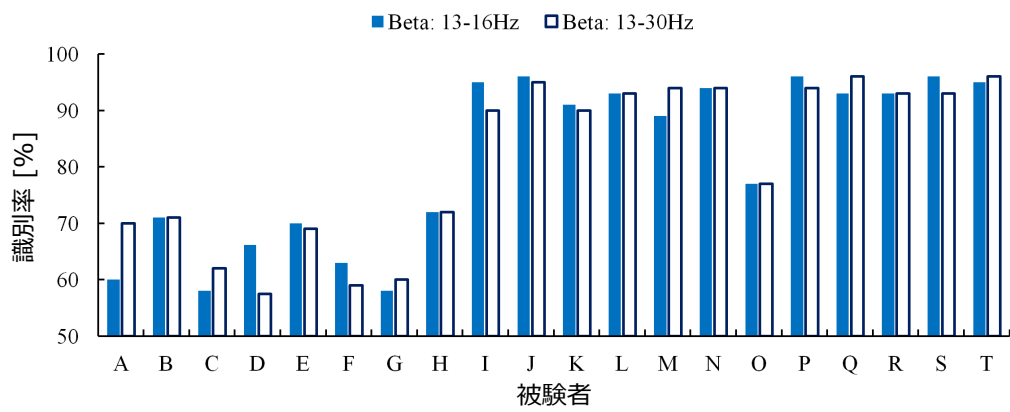


Fig. 29 ウェーブレット変換を用いた時の各被験者における識別率 (ウィンドウ幅 : 256)