硬膜下電位からのサル捕食運動中の状態判別と ロボットアーム動作決定

佐藤 圭太^{*1} 森下 壮一郎^{*1} 渡辺 秀典^{*2} 西村 幸男^{*2}
加藤 龍^{*1} 伊佐 正^{*2} 横井 浩史^{*1}

Discrimination Analysis and Movement Decision of the Prosthetic Arm by Using Monkey ECoGs Data Associated with Self-feeding Motions

Keita Sato^{*1}, Soichiro Morishita^{*1}, Hidenori Watanabe^{*2}, Yukio Nishimura^{*2},
Ryu Kato^{*1}, Tadashi Isa^{*2} and Hiroshi Yokoi^{*1}

Brain Machine Interface (BMI) technology is a promising technology for the rehabilitation of patients with serious paralytic impairments. In particular, BMI using Electrocorticograms (ECoGs) provides an interesting new possibility because of its long-term stability, low degree of invasiveness, high spatial-temporal resolution and high signal per noise ratio (S/N ratio). Nevertheless, there are no BMIs with ECoG for devices that incorporate many degrees of freedom, such as the artificial hand. In this paper, as a preliminary experiment, we constructed a signal processing module and decision of movement of external devices such as a robot arm. We observed the self-feeding motions of a monkey (*Macaca fuscata*) employing ECoG electrodes. We applied the Fast Fourier Transform to the ECoGs and performed bandpass filtering to obtain amplitudes of a few frequency bands. We then implemented Linear Discriminant Analysis (LDA) to classify the motion patterns into four classes. Then, we decided the movement of the robot arm from the cumulative incidences of these classes. We have achieved two noteworthy results, namely a discrimination ratio between 53–61% and a delay of beginning times of ± 0.15 seconds.

Key Words: Brain Machine Interface, Electrocorticogram, Linear Discriminant Analysis, Decision of Movement

1. はじめに

脳の情報処理活動から運動器官を介さずに直接外部機器の操作を可能にする技術はBMI (Brain Machine Interface) と呼ばれている。これは、筋萎縮性側索硬化症や頸椎損傷などの四肢の随意運動が不可能な重度の身体麻痺を持つ患者の日常生活動作にかかわる身体機能を有効に支援する手段として期待されている [1]。現在、脳波による車椅子の制御は実用に近い形ですでに実現されている [2]。しかしながら日常生活動作の再建のためにはそれだけでは不十分であり、上肢の身体機能を代替する装置も必要である。また、上肢を用いた日常生活動作のうち重要なものとして物体の把持と移動を含んだリーチングタスクがあり、これを再建できるBMIの開発により患者のQOL (Quality of Life) は飛躍的に向上する。しかしながら、BMIによるリーチ

ングタスクの実現には応答の早さや動作の複雑さが要求されるので、これを満たすような脳活動の計測手法の検討や運動意図の抽出手法の開発が必要である。

脳活動情報の取得法には血流変化などを計測して脳の神経細胞の活動を間接的に取得しようとするものと、電気的活動を計測して直接的に取得しようとするものがある。前者は、血中ヘモグロビンの量などの二次的な変化を計測するので時間応答性が悪い。後者は、神経細胞の活動を直接的に計測するので時間応答性に大変優れている。電気的活動を計測するものも、さらに身体への侵襲度によって非侵襲型と侵襲型に分類される [3]。前者の代表的なものに脳波 (EEG: Electroencephalogram) がある。これは頭皮上に置かれた電極から、頭皮上に現れる神経細胞の活動電位を計測したもので、身体に外傷を与えないので容易かつ安全に計測できるが、空間分解能が 10 [mm] 以上であり、運動の計画・実行を行っているときとされる一次運動野の活動を詳細に計測することができない。また、顔面筋電位などの環境ノイズに弱く、これを緩和するために時間的に平均を取った上で特徴量を算出する必要がある、応答性が悪い。

一方、侵襲型の手法は一般に 50 [μm]–5 [mm] 程度の十分な空間分解能を持つ [3]。侵襲型の代表的なものに、皮質内電極に

原 2011 年 6 月 18 日

^{*1}電気通信大学情報理工学研究所知能機械工学専攻

^{*2}自然科学研究機構生理学研究所

^{*1}Department of Mechanical Engineering and Intelligent Systems,
The University of Electro-Communications

^{*2}National Institute for Physiological Science

■ 本論文は有用性で評価されました。

よる計測がある。これは、針状の電極を大脳皮質に刺入して神経細胞の個々の活動あるいは複数の細胞の活動の総和を計測したものである[4]。高い空間分解能およびS/N比で計測が行えるが、皮質内の神経細胞の退行性変化を引き起こすので、長期間に渡る適用が難しい[5][6]。

この難点を補うものとして、硬膜下電位(ECoG: Electrocorticogram)の計測がある。これは、硬膜下に置かれた電極から、電極近傍の電位を計測するものであり、皮質内電極に比べると侵襲性が低いことから低侵襲型とも呼ばれる。頭皮上電極に比べて高い空間分解能をもち、また神経細胞を傷つけないので皮質内電極を用いるものに比べて長期間に渡る計測に優位で安全性も高い[7]。このことから、硬膜下電位はBMIの応答性や動作の多様性、および安全性を同時に満たす手段として注目されており、上述した重度の身体麻痺患者のリーチングタスクの実現にもっとも適していると考えられる。これまでに二次元でのカーソル移動や三次元手先位置、上肢の姿勢判別などが行われている[7]~[10]。なお、これらの研究は脳の活動情報から対象となる運動を精度よく判別もしくは推定を行うことに主眼が置かれている。しかしながら、いかに操作者の動作意図や状態の判別が正しく行われても、その結果をそのまま外部機器の動作決定に用いると、機器がその動作に追従しきれなかったり、誤判別があったときの動作が不安定になったりする等の問題がある。場合によっては機器が暴走する恐れすらある。これを防ぐには外部機器の性能を考慮して動作意図の判別結果から機器の動作を決定する必要がある。

以上のことから、本論文では、高い応答性を有しながらも安定して機器を制御できる低侵襲型BMIの構築を目指し、硬膜下電位からの上肢運動の判別とそれに基づいた外部装置の動作決定を行う。具体的には、上肢運動の判別結果を基に、誤判別の発生を加味し安定した上肢運動代替機器の動作をリアルタイムかつタイミングを合わせて決定することを目的とする。そして、硬膜下電極が留置されたサルを対象として実証実験を行い、本手法の有用性を検証する。

2. 硬膜下電位の計測

本論文では低侵襲型BMIの構築を目指し、硬膜下電位からの運動判別とそれを基にした外部機器の動作決定を行う。動作決定までの過程は、硬膜下電位の計測、硬膜下電位の前処理と判別、上肢運動代替機器の動作決定の3つの段階に分割することができる。本章ではその第一の段階である硬膜下電位の計測について述べる。

2.1 計測対象

現状では、安全性や倫理上の問題からヒトを対象とした研究は、検査や治療のために埋め込まれた臨床用の電極を流用して行われており[8]~[10]、日本においては大阪大学が主体で、てんかん焦点の同定のために硬膜下電極を留置した患者の協力を得て電動義手を制御する実験が進められている[8]。一般に、侵襲型の電極を用いたBMIの実験的な研究は、主に動物を対象として行われている。特に上肢の運動を推定する研究ではサルが用いられている[4][7]。これはサルが、ヒトと同様に記憶や手指の器用な運動のコントロールなどの高次脳機能を有しているからであり、身体機能も同様に類似しているからである。よって、本論文でもサル(ニホンザル、オス、9歳)を対象にして実験を行って有効性や安全性を確認する。またこの実験の手続きのすべては、岡崎3機関動物実験委員会の大学共同利用機関法人自然科学研究機構動物実験規定に則って行われている。

対象とする運動は、物体を掴みにいって、それを把持し、移動して放すといった上肢の基礎的な動作であるリーチングタスクである捕食運動である。

2.2 捕食運動

本論文における捕食運動とは、目の前にある食物に手を伸ばし、掴んで、口に運んで食べるという一連の運動を指す。サルとは意志の疎通を行うことは困難であり、腕の軌道や動作速度、動作タイミングを指定することができない。そこで本論文では腕の詳細な軌道は考慮せずに、待機状態、物体へのアプローチ、把持したままの移動、手から解放といった4つのフェーズに分けることで上肢運動の基本的な構成要素を抽出し、それに合わせた上肢運動代替機器の動作決定を行うことによりBMIによる捕食運動を実現する。

以上のことから、脳活動から運動の状態を推定するにあたって、捕食運動中で大きく変化する手首の位置に着目して捕食運動中の状態を複数の離散的なクラスに分けて判別を行った。具体的には、手首の運動の方向が切り替わる位置を境界として次のような4クラスを定義し、判別を試みた(Fig. 1)。

- (a) 待機時 (Waiting)
- (b) 餌に手を伸ばしているとき (Reaching)
- (c) 餌を口に運んでいるとき (Feeding)
- (d) 待機状態へ至るまで (Resting)

また、本論文で1試行は、(a) → (b) → (c) → (d) → (a)の一巡とする。

2.3 硬膜下電位の計測

一般に、身体の活動部位と脳の賦活部位は関係があり、特に

Fig. 1 Four classes during self-feeding

一次運動野は運動の実行と計画を担う部位であることが知られている。また一次運動野のうちでも各運動器官に対応する領域が解剖学的に分かっている。この知見に基づき本研究では、一次運動野の上肢の運動にかかわる部分に合計 32 個の硬膜下電極を留置する。電極留置の様子を Fig. 2 に示す。

次に Fig. 3 に硬膜下電位の計測概要を示す。左脳に硬膜下電極を留置したサルに右腕で目前に差し出された報酬を捕食する運動を行わせ、その際の硬膜下電位を神経信号計測システム (Plexon 社製, OmniPlex) でサンプリングレート 500 [Hz] で記録する。それと同時に、クラスを決定するための手首の三次元位置をモーションキャプチャシステム (MotionAnalysis 社製, Eagle, Cortex) でサンプリングレート 500 [Hz] で計測する。

Fig. 2 The indwelling site of subdural electrodes

Fig. 3 The schematic view of acquisition ECoGs

3. 硬膜下電位の前処理と判別

硬膜下電位は、皮質表面の電氣的ポテンシャルを計測するので、個々の神経の電氣的活動に由来する信号が重畳された形で観測される [7]~[10]。そのため特定の活動部位や神経細胞を特定するのは非常に困難であるが、従来研究および予備実験では硬膜下電位および皮質内脳波 (LFP: Local Field Potential) のいくつかの周波数帯が動作判別に有用であることが確認されている [7] [11]。よって本論文でも硬膜下電位の周波数成分を抽出することにより解析を進めた。

3.1 硬膜下電位の前処理

Fig. 4 に硬膜下電位の前処理の概要を示す。捕食運動中に計測された硬膜下電位信号に短時間フーリエ変換を施し、パワースペクトルを算出する。窓サイズは 256 [ms]、シフトサイズは 8 [ms] とした。これら処理を全電極分施し、パワースペクトルを算出する。そのパワースペクトルに対し、バンドパスフィルタを施し、時刻 t における 4 つの周波数帯の時系列の強度 $\delta(t)$ (1–4 [Hz]), $\beta(t)$ (20–30 [Hz]), $\gamma_L(t)$ (80–150 [Hz]), $\gamma_H(t)$ (150–250 [Hz]) を取得する。ここで、 δ は LFP からの動作推定に優位であると考えられる報告がある [11]、 β は集中時に活発に見られると言われており、 γ_L 、 γ_H に関しては運動判別に有用であるとされる high γ 帯を便宜上 2 つに分けたものである。これらの特徴量を並べた列ベクトルを次式で表す。

$$\mathbf{x}'(t) = (\sigma(t), \beta(t), \gamma_L(t), \gamma_H(t))^T \quad (1)$$

ここで、 T は転置を意味する。さらに、次式のように時刻 t における特徴ベクトルを定義する。

$$\mathbf{x}(t) = \begin{pmatrix} \mathbf{x}'_1 \\ \vdots \\ \mathbf{x}'_k \\ \vdots \\ \mathbf{x}'_{32} \end{pmatrix} \quad (2)$$

k は電極番号 ($k = 1, \dots, 32$) であり、 $\mathbf{x}'_k$ は時刻 t における電極 k の特徴量を表すベクトルである。このとき、特徴ベクトル $\mathbf{x}(t)$ の次元数 d は $4 \times 32 = 128$ となる。

3.2 線形判別分析による判別

前節の手続きにより得られたパワースペクトルを線形判別分析により判別する。線形判別分析は、教師あり学習のひとつであ

Fig. 4 The feature extraction of ECoGs

り、すでに与えられているデータ（学習データ）のクラス内分散が最小かつクラス間分散が最大になるような境界超平面あるいは直線を求めてクラス未知のデータを判別する手法である [12]. 境界超平面もしくは直線を表す関数は判別関数と呼ばれる. 判別関数の定数部を比較することにより判別に関与する各変数の寄与の程度を知ることができる. また、その変数に対応する電極のチャンネルや周波数成分を見ることで生理学的な知見も得られるという長所がある. 以下に判別の手続きを述べる. ここで、前述した四つのクラス、Waiting, Reaching, Feeding, Resting をそれぞれ、 ω_c ($c = 1, 2, 3, 4$) とする. まず、クラス ω_i とクラス ω_j とを判別する判別関数 $g_{ij}(\mathbf{x}(t))$ が次式を満たすものとして定義する.

$$\begin{cases} \mathbf{x}(t) \in \omega_i \rightarrow g_{ij}(\mathbf{x}(t)) > 0 \\ \mathbf{x}(t) \in \omega_j \rightarrow g_{ij}(\mathbf{x}(t)) \leq 0 \end{cases} \quad (3)$$

また、 $g_{ij}(\mathbf{x}(t))$ を係数ベクトル $\mathbf{w}_{ij}$ および係数 w_{ij} を用いて次式で表す.

$$g_{ij}(\mathbf{x}(t)) = \mathbf{w}_{ij}^T \mathbf{x}(t) + w_{ij} \quad (4)$$

以降、 $\mathbf{w}_{ij}$, w_{ij} を求める手続きについて述べる.

クラス ω_c に属するデータ $\mathbf{x}(t)$ の集合を X_c , そのサイズを N_c , 平均 $\bar{\mathbf{x}}_c$ とするとき、変動行列を次式で定義する.

$$S_c = \sum_{\mathbf{x} \in X_c} (\mathbf{x} - \bar{\mathbf{x}}_c)(\mathbf{x} - \bar{\mathbf{x}}_c)^T \quad (5)$$

次に、任意の 2 クラス ω_i, ω_j におけるクラス内変動行列 W_{ij} を式 (6), クラス間変動行列 B_{ij} を式 (7) と計算する.

$$W_{ij} = S_i + S_j = \sum_{n=i,j} \sum_{\mathbf{x} \in X_c} (\mathbf{x} - \bar{\mathbf{x}}_n)(\mathbf{x} - \bar{\mathbf{x}}_n)^T \quad (6)$$

$$B_{ij} = \sum_{n=i,j} N_n (\bar{\mathbf{x}}_n - \bar{\mathbf{x}})(\bar{\mathbf{x}}_n - \bar{\mathbf{x}})^T \quad (7)$$

さらに、クラス間・クラス内変動比を $J(\mathbf{w}_{ij})$ として次のように定義する.

$$J(\mathbf{w}_{ij}) = \frac{\mathbf{w}_{ij}^T B_{ij} \mathbf{w}_{ij}}{\mathbf{w}_{ij}^T W_{ij} \mathbf{w}_{ij}} \quad (8)$$

線形判別分析の基本的な考え方は、クラス内変動に対するクラス間変動の比、すなわちクラス間・クラス内変動比を最大にする写像 $\mathbf{w}_{ij}$ を求めることにある. 写像 $\mathbf{w}_{ij}$ は、 $J(\mathbf{w}_{ij})$ の最大化問題を解くことで得られる. これは $W_{ij}^{-1} B_{ij}$ の固有値問題に帰着する.

以上の手続きを経て、合計 32 電極分の硬膜下電位を Waiting, Reaching, Feeding, Resting の 4 種類のクラスのどのクラスに属するかを判別する.

4. 上肢運動代替機器の動作決定

前章までの手続きで、捕食運動中の硬膜下電位の計測と判別を行った. 本章では、前章の手続きで得られた判別結果から、誤判別を許容して安定した制御が行えるように、各クラスと判別された結果の累積頻度により、支援機器の動作を決定する.

Fig. 5 The robot arm with wire-driven mechanism

4.1 ワイヤ牽引式ロボットアーム

本論文では、重度の身体麻痺患者の上肢の運動を代替し得る機器としてワイヤ牽引式のロボットアームを採用する (Fig. 5). このロボットアームは、サーボモータで各関節から伸びたワイヤを牽引して関節の屈曲伸展を行う. 制御は各モータの回転角と移行時間をコントローラに指示することにより行われる. すなわち、このロボットアームの動作は、事前に決められた数種類の姿勢のうちの、ある姿勢からある姿勢への移行により行われる.

4.2 ロボットアーム動作決定

前述のようにサルの捕食運動の 1 試行にかかる時間は一定ではなく、各状態を維持する時間もまちまちである. これを本研究で用いるロボットアームで追従するためには、サルの状態遷移に応じてロボットアームの状態遷移の開始トリガを生成する必要がある. 以下、その方法を検討する.

Fig. 6 のように、サルの捕食運動を表現するクラスは各姿勢間の遷移に対応し、境界は姿勢となる. 一方、ロボットアームの状態は姿勢で定義される. したがって、上述の 4 つの状態に対応するようにロボットアームを動作させるには、動作中の状態遷移を検出してそのタイミングをロボットの姿勢変化のトリガとすればよい.

しかし、一般に状態判別の結果は誤判別を含むので、そのままの判別結果では適切に状態遷移を検出できない. これを解決するために、判別結果をクラスごとにカウントし、それらがある閾値に達したときを状態遷移のタイミングと見なす. これにより、1 試行中で合計 4 回の状態遷移があるが、Resting から Waiting への遷移は姿勢の変更がないため、姿勢変更のトリガを生成する必要がない. したがってロボットアームの姿勢変化は 3 回でよい. ここでその 3 回の姿勢変化を Fig. 6 中のロボットアームの姿勢 A から姿勢 B への変化、姿勢 B から姿勢 C への変化、姿勢 C から姿勢 A の変化とし、それぞれ「Reaching motion」, 「Feeding motion」, 「Resting motion」とする. このとき、重要なのは、3 回の姿勢変化のトリガの生成がロボットアームの性能の範囲内で行えていることと、リアルタイム性を持つことである. 本論文では上記の条件を達成するために、まず、リアルタイム性を持ち安定した姿勢変化のトリガを生成で

Fig. 6 Correspondences of monkey moving classes with robot arm movement

きる閾値を決定し、次に設計した閾値をもって正しい動作決定ができるか否かを確認する。

$$K_c(t_0) = 0 \quad (c = 2, 3, 4) \quad (9)$$

とする。そして時刻 t で判別された結果を基に頻度を次のように計算する。

$$K_c(t) = K_c(t - \Delta t) + \Delta K_c(t) \quad (10)$$

$$\Delta K_c(t) = \begin{cases} 1 & (r(t) = \omega_c) \\ 0 & (r(t) \neq \omega_c) \end{cases}$$

各クラスの頻度が、それぞれある閾値 θ_c に達したところで、ロボットアームにそれぞれの動作「Reaching Motion」, 「Feeding Motion」, 「Resting Motion」を行わせる。実際にサルの手が安静状態から動き始めた時刻 T_{a2} , 餌を掴み口に運び始めた時刻 T_{a3} , 手を安静状態へ持っていった時刻 T_{a4} と, $K_c(t)$ が θ_c に達した時刻 $T_c(\theta_c)$ との差をそれぞれとる。そして、それらを動作開始時刻の差 $D_c(\theta_c)$ と定義し、以下のように算出する

$$D_c(\theta_c) = T_c - T_{ac} \quad (11)$$

動作開始時刻の差が正であれば、ロボットアームの動作はサルの動作に比べて遅れている。一方、動作開始時刻の差が負であればロボットアームの動作はサルの動作に比べて早い。

複数回の試行から平均 $\bar{D}_c(\theta_c)$ を算出して、それらができるだけ近くなり、かつ分散 $\sigma_c(\theta_c)^2$ ができるだけ小さくなるような閾値 $\tilde{\theta}_c$ の決定をそれぞれ行う。以上の手続きで決定した閾値に基づいてロボットアームを動作させた場合、トリガの発生順が前後してしまい正しい順で動作が行われない可能性がある。また、ロボットアームの応答速度では追従しきれない間隔でトリガが発生すること考えられる。これらを防ぐために、まず決定した閾値 $\tilde{\theta}_c$ により各試行でロボットアームの動作が Reaching Motion, Feeding Motion, Resting Motion の順で正しく行われるか、すなわち、

$$T_2(\tilde{\theta}_2) < T_3(\tilde{\theta}_3) < T_4(\tilde{\theta}_4) \quad (12)$$

となるか否かを確認する。次に、式 (13) で定義するトリガ発

生間隔が ΔT_{23} , ΔT_{34} ロボットアームの応答速度で追従できる範囲（それぞれ 0.25 [s] 以上）であるか否かを確認する。

$$\begin{cases} \Delta T_{23} = T_3(\tilde{\theta}_3) - T_2(\tilde{\theta}_2) \\ \Delta T_{34} = T_4(\tilde{\theta}_4) - T_3(\tilde{\theta}_3) \end{cases} \quad (13)$$

ΔT_{23} , ΔT_{34} がそれぞれ 0.25 [s] 以上であれば、ロボットアームの動作は正しい順かつ応答性能の範囲内で行われることを示す。すなわち安定した動作決定が行えることになる。

次に、評価に用いるすべての試行について以上の条件を満たす $\tilde{\theta}_c$ を決定し、そのときの $\bar{D}_c(\tilde{\theta}_c)$ を人間の単純反応時間（約 0.20 [s]）と比較してリアルタイム性の評価を行う。差が単純反応時間以下であれば、誤判別の影響が少ないリアルタイムなロボットアームの動作決定が行えたことになる。

5. 硬膜下電位からのロボットアーム動作決定実験

本章では、第 3 章および第 4 章で述べた提案手法の妥当性を検討するために、実際のサルの捕食運動中の硬膜下電位から捕食運動を構成する 4 つの運動クラスを判別し、それにあわせたロボットアームの動作決定を実施した。

5.1 実験設定

サルの捕食運動中の硬膜下電位と手首位置を計測し、硬膜下電位の信号に第 3 章で示した前処理を施して、同時に計測した手首位置を元に各時刻におけるクラスを決定した。計測中にサルは 95 回の試行を行った。このうち、サルが休止したり別の運動をしたりせずに連続的に試行を行っている部分を切り出したところ、4 つのシーケンス（各試行数 14, 27, 13, 41）が得られた。このうちの 3 つのシーケンス（計 81 試行）のデータを学習データにし、残りのシーケンス（14 試行）のデータで判別を行って評価した。なお、判別を行う間隔 Δt は 8 [ms] とした。

5.2 結果：捕食運動の 4 クラス判別

前述の手続きで得られた判別結果を Fig. 7 に示す。誤判別は全体にわたって生じているが、特にクラスが遷移する前後で誤判別の発生が多くなることが分かる。

次に、14 試行の各運動クラスの判別率および誤判別率の平均

Fig. 7 The actual monkey moving classes and results of discrimination

Table 1 Discrimination ratio and error ratio [%]

	Waiting	Reaching	Feeding	Resting
Discrimination ratio	60.6	60.3	52.8	61.1
Error ratio (Waiting)		11.6	9.5	18.3
Error ratio (Reaching)	5.5		30.6	3.6
Error ratio (Feeding)	4.4	31.8		11.0
Error ratio (Resting)	15.6	12.2	10.8	

値を **Table 1** に示す。全体の判別率の平均は 52.8% となる。各運動クラス ω_i の判別率 $R_c(\omega_i)$ および誤判別率 $R_e(\omega_i, \omega_j)$ は、時刻 t における実際のサルのクラスを $s(t)$ とし、次のように算出した。

$$R_c(\omega_i) = \frac{N_r(\omega_i)}{N_s(\omega_i)} \times 100 \quad (14)$$

$$R_e(\omega_i, \omega_j) = \frac{N_r(\omega_{i,j})}{N_s(\omega_i)} \times 100 \quad (15)$$

上式で、 $N_r(\omega_i)$ 、 $N_s(\omega_i)$ はそれぞれ、 $r(t) = \omega_i$ 、 $s(t) = \omega_i$ と判別された数である。また、式 (15) 中の $N_r(\omega_{i,j})$ は、 $s(t) = \omega_i$ のときに $r(t) = \omega_j$ と判別された数である。つまり、誤判別率は、本来 ω_i と判別されるべきところ ω_j ($j \neq i$) と判別してしまった割合である。Table 1 によると、Reaching と Feeding、および Waiting と Resting とがそれぞれ互いに誤判別されることが多い。なお、Reaching と Feeding の相互の誤判別率が高いのは、いずれも大きく腕が動く運動であるためにパターンが類似するからだと考える。また、Waiting と Resting の相互の誤判別率が高いのも同様にいずれも腕を脱力している運動であるためにパターンが類似しているからだと推測される。さらに、全体の傾向として状態遷移の前後に対応するクラスと誤判別される割合が多いことが分かる。

この判別結果から、そのままロボットアームの動作を決定すると安定したロボットアームの動作を行うことができない。そこで次節で、状態遷移が起こるタイミングで各クラスの判別結果の出現頻度の変化を利用して状態遷移のタイミングを検出してロボットアームの動作を決定する。

5.3 結果：判別決定に基づいたロボットアームの動作決定

前述のように、状態が遷移する前後で誤判別が多くなることと、そのとき前後のクラスに誤判別する割合が多いことを考慮してロボットアームの動作トリガの生成を行う。具体的には、状態遷移が起こるタイミングにおける各クラスの判別結果の出現頻度の変化を利用することで状態遷移のタイミングを検出してロボットアームの動作を決定する。本論文で解く最適化問題は、式 (12) (13) の制約下で $\bar{D}_c$ および σ_c^2 を最小化する問題である。

まず、式 (12) (13) の条件は考慮せずに閾値 $\bar{\theta}_c$ を暫定的に決定する。その基準を以下に示す。

- (ア) 実際にサルの手の運動が切り替わる時刻 T_{ac} とロボットアームの運動が切り替わる時刻 $T_c(\theta_c)$ ができるだけ同じであること ($\bar{D}_c$ が 0 にできるだけ近いこと)
- (イ) 安定してロボットアームが動くこと (試行ごとの動作開始時刻の差 D_c の分散が小さいこと)

閾値 $\bar{\theta}_c$ を暫定的に決定するために、各クラス c における閾値 θ_c を変化させたときの動作開始時刻の差 D_c の平均 $\bar{D}_c$ 、および分散 σ_c^2 を算出した。その結果を **Fig. 8** に示す。 $\bar{D}_c$ が負の値を取るときは、サルの手が実際に動き始める時刻より、ロボットアームが動き始める時刻のほうが早いことを示す。この結果より、累積頻度は単調増加する量であるので、閾値 θ_c の値が大きくなるほど動作開始時刻の差 D_c の平均 $\bar{D}_c$ も大きくなる。すなわち、 θ_c の値を大きくするとロボットアームの動作がサルに比べて遅くなることが分かる。また、分散に着目すると $\sigma_2(\theta_2)^2$ 、 $\sigma_3(\theta_3)^2$ は $\sigma_4(\theta_4)^2$ と比べて θ_c による変動が少なく、実験を行った範囲では、ほぼ一定と見なせる。したがって、 $\bar{\theta}_c$ ($c = 2, 3$) については、分散は考慮に入れず $\bar{D}_c$ がになるような $\bar{\theta}_c$ に決定すればよい。また $c = 4$ の場合も、 $\bar{D}_4$ がに近い値になるところで $\sigma_4(\theta_4)^2$ もちょうど最小になる。以上を基に、閾値 $\bar{\theta}_c$ をそれぞれ $\bar{\theta}_2 = 15$ 、 $\bar{\theta}_3 = 57$ 、 $\bar{\theta}_4 = 24$ と暫定的に決定した。

次に式 (12)、(13) の条件を考慮した $\bar{\theta}_c$ の更新を行う。手続きは次に示す。

Fig. 8 Averages and variances of differential time when start moving between robot arm and monkey

Table 2 The duration of generated trigger and the result fulfill the equation (12), (13) or not ($\tilde{\theta}_2 = 15$, $\tilde{\theta}_3 = 57$, $\tilde{\theta}_4 = 24$)

Trial	1	2	3	4	5	6	7	8	9	10	11	12	13	14
ΔT_{23} [s]	1.02	0.43	1.48	0.91	0.43	1.50	1.53	0.92	1.45	3.02	0.90	2.15	1.56	1.08
ΔT_{34} [s]	1.57	1.63	0.08	1.33	1.21	-0.13	0.47	1.17	0.58	-0.38	1.23	1.06	1.27	1.18
Result	○	○	×	○	○	×	○	○	○	×	○	○	○	○

Table 3 The duration of generated trigger and the result fulfill the equation (12), (13) or not ($\tilde{\theta}_2 = 11$, $\tilde{\theta}_3 = 50$, $\tilde{\theta}_4 = 27$)

Trial	1	2	3	4	5	6	7	8	9	10	11	12	13	14
T_{23} [s]	0.68	0.40	1.48	0.90	0.25	1.49	1.51	0.89	1.38	2.45	0.88	2.13	1.53	0.93
T_{34} [s]	2.27	1.72	0.46	1.41	1.45	0.36	0.55	1.25	0.74	0.26	1.32	1.14	1.35	1.38
Result	○	○	○	○	○	○	○	○	○	○	○	○	○	○

1. 決定した値で式 (12), (13) が満たされるか確認し, 満たせばその値で決定する.
2. 満たさなければ, $\tilde{\theta}_c$ の近傍の値を改めて新たな $\tilde{\theta}_c$ とし, 1. の手続きを繰り返す.

ロボットアームが正しい順番かつ性能の範囲内で制御できるかを確認するために, 上記のパラメータ設定で各試行におけるトリガ間隔を算出した. 結果を **Table 2** に示す. ここで, Result の欄は式 (12), (13) の条件を同時に満たすか否かを表す. 条件を満たす場合を ○, 満たさない場合を × で示した. これはすなわち, $\Delta T_{23} \geq 0.25$ [s] かつ $\Delta T_{34} \geq 0.25$ [s] を満たすときである.

この結果, 試行 6, 10 において ΔT_{34} が負の値を示した. これは $K_2(t)$ が $\tilde{\theta}_2$ に達する時刻よりも $K_3(t)$ が $\tilde{\theta}_3$ に達する時刻のほうがあとになる場合, すなわちロボットアームが待機位置に移動する動作よりもハンドを口に運ぶ動作のほうが先に行われてしまうことを表している. 次に, Table 2 の ΔT_{23} の欄を見ると, すべての試行において制約条件の下限の 0.25 [s] を上回っており, まだ小さくすることが可能である. したがって, 閾値 $\tilde{\theta}_2$, $\tilde{\theta}_3$ を下げて, 閾値 $\tilde{\theta}_4$ を上げることで ΔT_{34} は大き

くなると考えられる. この考えに基づき, ΔT_{34} が 0.25 [s] 以上になるように $\tilde{\theta}_3$ を小さく, $\tilde{\theta}_4$ を大きくして, その上で $\tilde{\theta}_2$ を小さくすることで, すべての試行で条件を満たすような閾値を $\tilde{\theta}_2 = 11$, $\tilde{\theta}_3 = 50$, $\tilde{\theta}_4 = 27$ と決定した.

上記のパラメータ設定でトリガ間隔および動作が順に行われるか否かを判定した結果を **Table 3** に示す. 全 14 試行において条件が満たされたことが分かる. これは, 本研究で採用したロボットアームの性能で実現可能かつ正しい順序で動作が行われるということを示している. また, このときの動作開始時刻の差の平均 $\bar{D}_c$ は, $\bar{D}_2 = -0.10$ [s], $\bar{D}_3 = -0.16$ [s], $\bar{D}_4 = 0.15$ [s] であった. これは, 人間の単純応答時間 0.20 [s] より十分小さい. 以上の結果から, 本研究で提案した手法により誤判別の影響を受けずにリアルタイムかつ誤動作のないロボットアームの制御が可能になることが示された.

6. 結論と今後の展望

本論文では, 重度の肢体麻痺患者の上肢運動を支援するための BMI の構築を目指し, サルの硬膜下電位からロボットアームの動作決定を行った. 具体的には運動として物体の把持, 移

動が含まれるリーチングタスクである捕食運動を対象とし、手首位置に基づいて捕食運動を4クラスに分けて定義した。そして捕食運動中の硬膜下電位信号に短時間フーリエ変換を施してパワースペクトルを計算した。さらにバンドパスフィルタを施すことにより、 δ , β , γ_L , γ_H の4つの周波数帯の強度からなる特徴ベクトルを生成して、線形判別分析により4クラスの判別を行った。また、判別されたクラスの出現頻度が変化することを利用して誤判別の影響が小さく安定かつリアルタイムなロボットアームの動作を決定した。本研究で得られた成果は次のようにまとめられる。

- ・4クラス判別は53–61%の精度で行うことができる
- ・ロボットアームの動作決定においては適切に閾値を設定することでロボットアームの応答速度の範囲内でかつ正しい順序で動作が行われる
- ・このときの動作開始時刻の差は -0.16 [s] から 0.15 [s] であった判別率は過去の研究と比べて特に高いとは言えないが、これは連続的な運動を離散的に区切ってクラスを定義したことにより状態の境界付近で起こる誤判別が原因と考えられる。しかしながら本研究は捕食運動のフェーズにおける各クラスの判別結果の出現頻度の変化を考慮することで、誤判別の影響が小さい適切なロボットアームの動作決定を実現している。またロボットアームの動作開始時刻とサルの状態が切り替わる時刻の差は人間の単純反応時間と比べて75%程度と十分に小さく、捕食運動に代表される目の前の物体を把持し移動するタスクにおいては十分な応答速度であると考えられる。以上の成果により、代替装置の制御をリアルタイムかつタイミングを良く行えるようになり、上肢支援のためのBMIの実現可能性が示された。

今後の展望としては、判別精度の向上とそれに合わせたロボットアームの動作決定手法の検討や、把持力決定のための上腕筋活動群の推定、捕食運動を途中で止めてしまうなどの不規則な動作の検出、本手法による他のタスクや個体への適用実験等が挙げられる。これらを達成することにより、ロボットアームによる多様な把持動作の制御を硬膜下電位に基づいて行うことが可能になる。

謝 辞 本研究は、文部科学省脳科学研究戦略推進プログラムにより実施された「ブレイン・マシン・インターフェースの開発」の成果である。

参 考 文 献

- [1] 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.
- [2] K. Tanaka, K. Matsunaga and H.O. Wang: “Electroencephalogram-Based Control of an Electric Wheelchair,” IEEE Trans. Robotics, vol.21, no.4, pp.762–766, 2005.
- [3] M.A. Lebedev and M.A.L. Nicolelis: “Brain-machine interfaces: past, present and future,” Trends in Neurosciences, vol.29, issue 9, pp.536–546, 2009.
- [4] M. Velliste, S. Perel, M.C. Spalding, A.S. Whitford and A.B. Schwartz: “Cortical control of a prosthetic arm for self-feeding,” Nature, vol.453, pp.1098–1101, 2008.
- [5] R. Biran, D.C. Martin and P.A. Tresco: “Neuronal cell loss accompanies the brain tissue response to chronically implanted silicon microelectrode arrays,” Experimental Neurology, vol.195, pp.115–126, 2005.
- [6] D.H. Szarowski, M.D. Andersen, S. Retterer, A.J. Spence, M. Isaacson, H.G. Craighead, J.N. Turner and W. Shain: “Brain responses to micro-machined silicon devices,” Brain Research, vol.983, issues 1-2, pp.23–35, 2003.
- [7] Z.C. Chao, Y. Nagasaka and N. Fujii: “Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys,” Frontiers in Neuroengineering, vol.3, article 3, pp.1–10, 2010.
- [8] T. Yanagisawa, M. Hirata, Y. Saitoh, A. Kato, D. Shibuya, Y. Kamitani and T. Yoshimine: “Neural decoding using gyral and intrasulcal electrocorticogram,” Neuroimage, vol.45, issue 4, pp.1099–1106, 2009.
- [9] G. Schalk, J. Kubanek, K. Miller, N. Anderson, E. Leuthart, J. Ojemann, D. Limbrick, D. Moran, L. Gerhardt and J. Wolpaw: “Decoding two-dimensional movement trajectories using electrocorticographic signal in humans,” Journal of Neural Engineering, vol.4, no.3, pp.264–275, 2007.
- [10] T. Pistohl, T. Ball, A. Schulze-Bonhage, A. Aertsen and C. Mehring: “Prediction of arm movement trajectories from ecogrecordings in humans,” Journal of Neuroscience Methods, vol.167, no.1, pp.105–114, 2008.
- [11] J. Zhuang, W. Truccolo, C. Vargas-Irwin and J.P. Donoghue: “Decoding 3-D Reach and Grasp Kinematics from High-Frequency Local Field Potentials in Primate Primary Motor Cortex,” Biomedical Engineering, vol.57, issue 7, pp.1774–1784, 2010.
- [12] 石井健一郎, 上田修功, 前田英作, 村瀬洋: 分かりやすいパターン認識. 株式会社オーム社, 1998.

佐藤 圭太 (Keita Sato)

2009 年電気通信大学電気通信学部知能機械工学科卒業。同年より電気通信大学大学院情報理工学研究科知能機械工学専攻在学中。ブレインマシンインターフェースの研究に従事。

(日本ロボット学会学生会員)

渡辺 秀典 (Hidenori Watanabe)

2002 年東京大学工学系研究科修了。博士 (工学)。玉川大学学術研究所研究員。日本学術振興会特別研究員 (PD)。玉川大学学術研究所 COE 助手を経て、2008 年より自然科学研究機構生理学研究所発達生理学系認知行動発達機構研究部門研究員。

加藤 龍 (Ryu Kato)

2008 年東京大学工学系研究科博士課程修了。博士 (工学)。同年より東京大学大学院工学系研究科精密工学専攻特任助教。2009 年より電気通信大学大学院情報理工学研究科知能機械工学専攻助教。

(日本ロボット学会正会員)

横井 浩史 (Hiroshi Yokoi)

1993 年北海道大学工学研究科博士課程修了。博士 (工学)。同年より通商産業工学技術院生命研究所研究員。1995 年より北海道大学大学院工学研究科助教授。2004 年から東京大学大学院工学系研究科准教授。2009 年より電気通信大学情報理工学研究科教授。サイボーグ技術に興味を持ち、ヒト・機械適

応系に関する研究に従事。

(日本ロボット学会正会員)

森下 壮一郎 (Soichiro Morishita)

2009 年埼玉大学大学院理工学研究科にて博士 (工学) を取得。2010 年より東京大学大学院情報学環特任研究員。2012 年より電気通信大学大学院情報理工学研究科産学官連携研究員。パターン認識と、その応用としてのブレインマシンインターフェースの研究に従事。

西村 幸男 (Yukio Nishimura)

2003 年千葉大学医学研究科修了。博士 (医学)。同年より自然科学研究機構生理学研究所非常勤研究員。2004 年より科学技術振興機構戦略的創造研究推進事業 CRES 研究員。2007 年よりワシントン大学医学部訪問研究員。2009 年より科学技術振興機構戦略的創造研究推進事業さきがけ研究員 (兼任)。

2011 年より自然科学研究機構生理学研究所発達生理学系認知行動発達機構研究部門准教授。

伊佐 正 (Tadashi Isa)

1989 年東京大学医学部にて医学博士号取得。1993 年より群馬大学医学部生理学第二講座講師。1995 年より群馬大学医学部生理学第二講座助教授。1996 年より岡崎国立共同研究機構生理学研究所統合生理研究施設教授。1994 年より大学共同利用機関法人自然科学研究機構生理学研究所発達生理学系

教授。