

### 生体信号収集ヘッドセットを用いた電動車いす制御システムの操作性改善

松澤, 海良 / MATSUZAWA, Kaira

---

(出版者 / Publisher)

法政大学大学院理工学・工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学・工学研究科編 / 法政大学大学院紀要. 理工学・工学研究科編

(巻 / Volume)

58

(開始ページ / Start Page)

1

(終了ページ / End Page)

8

(発行年 / Year)

2017-03-31

(URL)

<https://doi.org/10.15002/00014123>

# 生体信号収集ヘッドセットを用いた電動車いす 制御システムの操作性改善 -ニューラルネットワークと周波数解析による表情識別-

IMPROVEMENT OF THE OPERABILITY OF AN ELECTRIC WHEELCHAIR CONTROL SYSTEM  
WITH A BIOSIGNAL COLLECTING HEADSET  
- DISTINCTION OF FACIAL EXPRESSION VIA NEURAL NETWORK AND FREQUENCY ANALYSIS -

松澤海良

Kaira MATSUZAWA

指導教員 石井千春 教授

法政大学大学院理工学研究科機械工学専攻修士課程

In our previous study, an electric wheelchair was controlled by the user's facial expression and head movement using the control system based on a brain-computer interface (BCI) headset having 14 measuring electrodes and a 2-axis gyroscope sensor. However, the operability issue caused by the time lag between the input of the command and the beginning of the movement of the electric wheelchair was observed. In this paper, the control system based on the BCI headset is improved to solve this issue. In the improved control system, the user's facial expression is distinguished via a neural network and frequency analysis with biosignals detected by electrodes of the BCI headset. Three kinds of methods to distinguish the facial expression were newly proposed. On the other hand, the user's head movement is recognized based on threshold criteria for angular velocity and displacement detected by the gyroscope sensor. With the aim of evaluating the improved control system, an experiment to measure the distinction rate for operation commands and a video analysis to measure the time lag were conducted, and the experimental results were compared between the proposed three distinction methods and the previous method.

**Key Words** : *biosignal, Brain-Computer Interface (BCI), electric wheelchair, neural network, Fourier transform, wavelet transform*

## 1. 結論

近年、筋電位 (Electromyogram: EMG) や脳波 (Electroencephalogram: EEG) といった生体信号から人間の意図を識別し、その結果を用いてロボットや福祉機器を制御する研究が注目されている。生体信号は人間の見た目では分からない微小な変化を計測することが出来、特に EEG は、人間の意識や感情の変化をも観察することが可能である。また、EEG に関連して、人間の脳と機械やコンピュータを繋ぐ機器—ブレイン・マシン・インターフェース (Brain-Machine Interface: BCI)、ブレイン・コンピュータ・インターフェース (Brain-Computer Interface: BCI) の研究が行われている。Petranonakis ら [1] は、多重比較 (higher order crossings: HOC) 解析を用い、6 種類の感情を約 60% の確率で識別し、Carroll ら [2] は、EEG 測定とアイトラッキング技術を組み合わせ、航空機パイロットの訓練とその評価を行うシステムを開発した。

こうした生体信号の研究、開発は、医療や福祉の現場で高齢者や身体の不自由な人を支援することを目的とした装置が多い。しかし、そのような先進技術を使った装置は、非常に高価であり、さらに大掛かりであるため装着や操作が困難であるものが多く、実用化されているシステムは少ない。

一方最近では、BCI がコミュニケーションツールやゲームコントローラなどの娯楽用・ゲーム用デバイスとして広まりつつある [3][4]。それらは装着が容易で、一般消費者が手に届く価格で販売されている。そして、そうした低価格の BCI デバイスを用いたシステムの研究も進められており、例えば、佐伯ら [5] は、簡易脳波計を用いて、ネットワーク経由でコンピュータアプリケーションを操作するシステムを提案している。

また、そうした研究の一つとして、ゲーム用として発売されている Emotiv Systems 社のヘッドセット型 BCI デ

バイス Emotiv EPOC を使用して、電動車いすを制御する試みがある。例えば茨木ら[6]は搭乗者の3種類の意識から、Ericck ら[7]は搭乗者の頭部の動きから、電動車いすを制御するシステムをそれぞれ開発している。また、Thaer ら[8]は EEG とアイトラッキングを組み合わせた電動車いす制御のシミュレーションを行っている。

しかし、それらのシステムでは電動車いすの4方向の移動(前進、後退、右旋回、左旋回)と停止の5操作までに留まっている。そこで、著者は先行研究[9]において、電動車いすのジョイスティックを腕で操作することが困難な人を対象とし、搭乗者の顔の表情および頭部の動きにより、電動車いすの操作を後退、後右旋回、後左旋回まで拡張した、より多様な操作が可能なシステムを開発した。

しかし、このシステムにおいていくつかの課題が残った。主な課題として、表情の操縦コマンドを入力してから実際に車いすが動作を始める間のタイムラグが挙げられる。この表情コマンドは BCI ヘッドセットに付属する既存のソフトウェアを用いて識別を行ったが、このソフトウェアのコマンド識別に時間を要することからタイムラグが生じた。これにより、電動車いす操縦時の即応性が懸念された。

そこで本研究では、表情コマンドの識別方法を独自に考案し、表情コマンド入力時のタイムラグを減らすことで、電動車いすの操作性を改善したシステムを開発した。

## 2. 数学的背景

### (1) ニューラルネットワーク

ニューラルネットワーク(Neural Network: NN)とは、人間の脳におけるニューロンの活動を模した数学モデルであり、現在多くの分野で応用され、パターン認識やデータマイニングなどに利用されている。

NN はヒトの脳と同様に、多数のノード(人口ニューロン)が連結して構成される。まず、図1に示される一つのノードにおいて、次式に示す重み付け演算と閾値演算が行われる。ここで、 $x_i$ は入力、 $w_i$ は各入力に対する重み係数、 $u$ はネット値、 $\theta$ はノードごとに設けられた閾値、 $y$ は出力、 $f$ はノードの伝達関数でステップ関数やシグモイド関数などが用いられる。また、(1)式において  $w_0 = -\theta$ 、 $x_0 = 1$  とし、閾値  $\theta$  を重み係数の一つとして扱う。

$$u = \sum_{i=1}^n x_i w_i \quad (1)$$

$$y = f(u) \quad (2)$$

このノードが階層状に結合し、ネットワークに入った信号が入力層から中間層(隠れ層)、出力層と一方通行で流れる NN は階層結合型ニューラルネットワークと呼ばれ、NN の最も古典的な構造である。階層結合型ニューラルネ

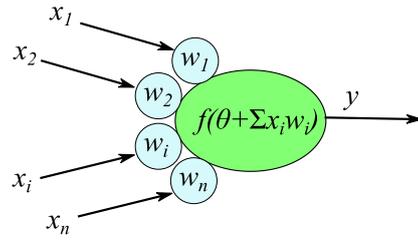


Fig.1 Single neuron

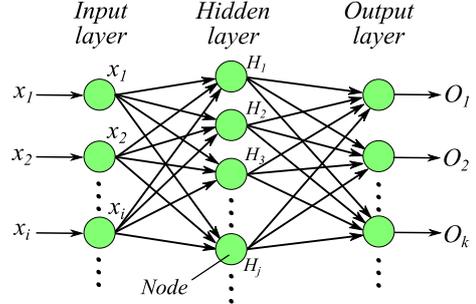


Fig.2 Multi-layer neural network

ットワークを図2に示す。

NN は、出力信号と教師信号を比較して、各ノードの重み係数  $w_i$  を更新することが可能であり、これを学習という。階層結合型ニューラルネットワークの学習則の一つに、誤差逆伝播法(Back-propagation: BP)がある。BP は、入力から出力を計算する前向き演算と、外部から与えられる教師信号を基に学習を行う後ろ向き演算の2つの過程で構成される。

まず、前向き演算は NN に入力を与え、結果を出力させる過程である。中間層の  $j$  番目のニューロンにおける入力  $x_i$  に対する重み係数を  $w_{ji}$ 、出力層の  $k$  番目のニューロンにおける  $j$  番目のニューロンの出力に対する重み係数を  $w_{kj}$  とすると、中間層、出力層のニューロンの出力  $H_j, O_k$  はそれぞれ次式で表される。

$$T_j = \sum_{i=1}^n x_i w_{ji} \quad (3)$$

$$H_j = f(T_j) \quad (4)$$

$$U_k = \sum_{j=1}^n H_j w_{kj} \quad (5)$$

$$O_k = f(U_k) \quad (6)$$

ここで、伝達関数  $f$  には次式のシグモイド関数が一般によく用いられる。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

次に、後ろ向き演算は出力が教師信号に等しくなるよう重み係数を修正する学習の過程である。出力  $O_k$  と教師

信号  $t_k$  の二乗誤差  $E$  を次式により定義する.

$$E = \sum_{k=1}^n (t_k - O_k)^2 \quad (8)$$

この誤差  $E$  が小さくなるように、重み係数  $w_{kj}$  および  $w_{ji}$  を修正量  $\Delta w_{kj}$ ,  $\Delta w_{ji}$  により修正する. ここで、 $\Delta w_{kj}$ ,  $\Delta w_{ji}$  に前回の修正量も考慮し、モメンタム係数  $\alpha$  を用いて更新式に慣性を持たせた、モーメント法(慣性率法)という学習則による重み更新式を以下に示す.

$$\begin{aligned} \Delta w_{kj}(n+1) &= -\eta \frac{\partial E}{\partial w_{kj}} + \alpha \Delta w_{kj}(n) \\ &= \eta(t_k - O_k)O_k(1 - O_k)H_j + \alpha \Delta w_{kj}(n) \end{aligned} \quad (9)$$

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (10)$$

$$\begin{aligned} \Delta w_{ji}(n+1) &= \eta x_i H_j (1 - H_j) \sum_{k=1}^n w_{kj} \delta_k + \alpha \Delta w_{ji}(n) \\ & \quad (11) \end{aligned}$$

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (12)$$

ここで、 $\eta$  は学習率、 $n$  は回数指標であり、 $\Delta w_{kj}(0) = \Delta w_{ji}(0) = 0$  とする.

以上の前向き演算と後ろ向き演算を繰り返し、誤差  $E$  が許容できる範囲に収まるまで、あるいはあらかじめ設定した学習回数になるまで学習を行う.

## (2) ウェーブレット変換

ウェーブレット変換は時間一周波数解析手法の一つである. 同じく時間一周波数解析手法である短時間フーリエ変換(Short Time Fourier Transform: STFT)では三角関数を基底関数として解析するのに対して、ウェーブレット変換ではさざ波状のウェーブレット関数を基底関数とする. この基底関数として用いられるウェーブレット関数はマザーウェーブレットと呼ばれ、様々な関数が用いられるが、いずれの関数も有限の長さの波を持ち、スケールファクタ  $a$  により時間軸方向に拡大・縮小、時間シフト  $b$  により時間軸方向に平行移動する. これによって、STFT における基底関数と窓関数の役割を同時に果たし、STFT よりも広い周波数領域での解析が可能となっている.

ウェーブレット変換のうち、連続ウェーブレット変換(Continuous Wavelet Transform: CWT)と、CWT に用いられるマザーウェーブレットの一つであるメキシカンハット関数を以下に示す.

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (13)$$

$$\psi(t) = (1 - 2t^2) \exp(-t^2) \quad (14)$$

## 3. 電動車いす操縦システム

### (1) 対象者

本研究では、車いすの利用が必要であり、麻痺や四肢の欠損などにより腕で電動車いすのジョイスティックを操作できないが、首より上の頭部や顔を動かすことが出来る人を対象とした電動車いす操縦システムを開発した. この場合、EEG やアイトラッキングの利用が車いす操作の候補として考えられるが、残存機能の利用の観点から、本研究では使用者の顔の表情と頭部の動きを使用した.

### (2) ハードウェア

本研究では、Emotiv Systems 社の BCI デバイス、Emotiv EPOC ヘッドセットを使用した. このヘッドセットには 14 個の測定電極と 2 個の基準電極が付いている. これらの電極の位置は、世界基準とされる国際 10-20 法の一つである 10%法(拡張国際 10-20 法)に従っており、図 3 において、測定電極の位置は赤色 (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) で、基準電極の位置は緑色 (P3, P4) でそれぞれ示されている. 加えて、2 軸ジャイロスコープも搭載されており、使用者の頭の動きをヨー、ピッチの 2 方向で検出することができる. このヘッドセットからの情報は専用の dongle を介して、無線によってサンプリング周波数 128Hz でコンピュータに送信される. このデバイスはゲーム用であるため、ノイズを受けやすく、信頼度の高い脳波信号を検出することは難しい. しかし、使用者の意図を読み取る装置としては十分に使用することができる.

また、スズキ株式会社製電動車いす(モーターチェア MC3000P)を使用した. この電動車いすは、2 軸ジョイスティックにより操縦することができ、モータに直結した後方二輪によって前後へ駆動、後方二輪の回転差と前輪二輪の補助によって方向制御を行うものである. 本研究では小西ら[10]が開発した、2つのモータの駆動によりジョイスティックを全方向に傾斜させる操縦装置をジョイスティック部に装着し、電動車いすを操作した. 以上で説明した装置を図 4 に示す.

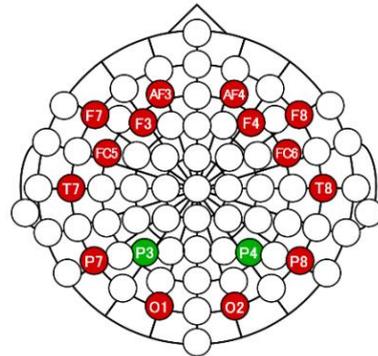


Fig. 3 Schematic of the 10-20 electrode system

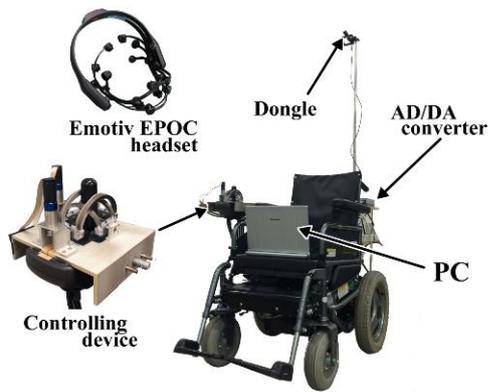


Fig. 4 Equipment used in this study

### (3) ソフトウェア

本研究では「Emokey」, 「MATLAB/Simulink」, 「Simulink EEG Importer」の3つの既存ソフトウェアを使用した。

Emokey は Emotiv EPOC ヘッドセットに付属するソフトウェアで、ユーザーの表情、感情、意識により、コンピュータ上にキーボードを使用せずにテキスト入力を行うことが出来るソフトウェアである。

MATLAB/Simulink は MathWorks 社の数値計算ソフトであり、このソフトウェアを使用して操縦コマンドの識別および操縦装置のモータの制御を行う。

ヘッドセットの電極とジャイロスコープからの情報は、Emotiv systems 社の Simulink EEG Importer を使用して、MATLAB/Simulink にインポートされる。

## 4. 制御方法

生体信号収集ヘッドセットにより検出される顔の表情と頭部の動きを電動車いすの操縦コマンドとして使用する。以下に、顔の表情および頭部の動きの操縦コマンドへの割り当てを示す。また、操縦コマンドの識別方法として4種類のコマンド識別方法を提案した。これらについて述べる。

### (1) 操縦コマンド

電動車いすの操縦コマンドには、使用者の2種類の顔の表情「Raise eyebrows (眉上げ: RE)」および「Clench(食いしばり: CL)」と、3種類の頭部の動き「Turn to the right (頭部を右に向ける: TR)」, 「Turn to the left (頭部を左に向ける: TL)」, 「Nod(うなずく)」を割り当てた。電動車いすの各操作に対応させた顔の表情と頭部の動きを図5に示す。RE は電動車いすの前進(または後進), TR は右旋回(または後右旋回), TL は左旋回(または後左旋回), CL は停止のコマンドとした。Nod は自動車のリバースギアのように、前後の進行方向を切り替えるコマンドであり、Nod を行う度に前進と後進が切り替わる。

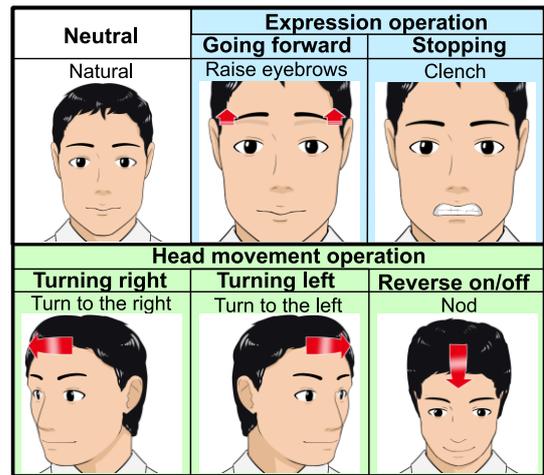


Fig. 5 Operation methods for moving electric wheelchair

### (2) 識別方法

操縦コマンドは、ヘッドセットで検出した電極信号(生体信号)とジャイロスコープ信号(角速度および角度変位)を基に識別される。本研究では先行研究[9]で提案された操縦コマンドの識別方法に加え、新たにニューラルネットワーク、および短時間フーリエ変換とウェーブレット

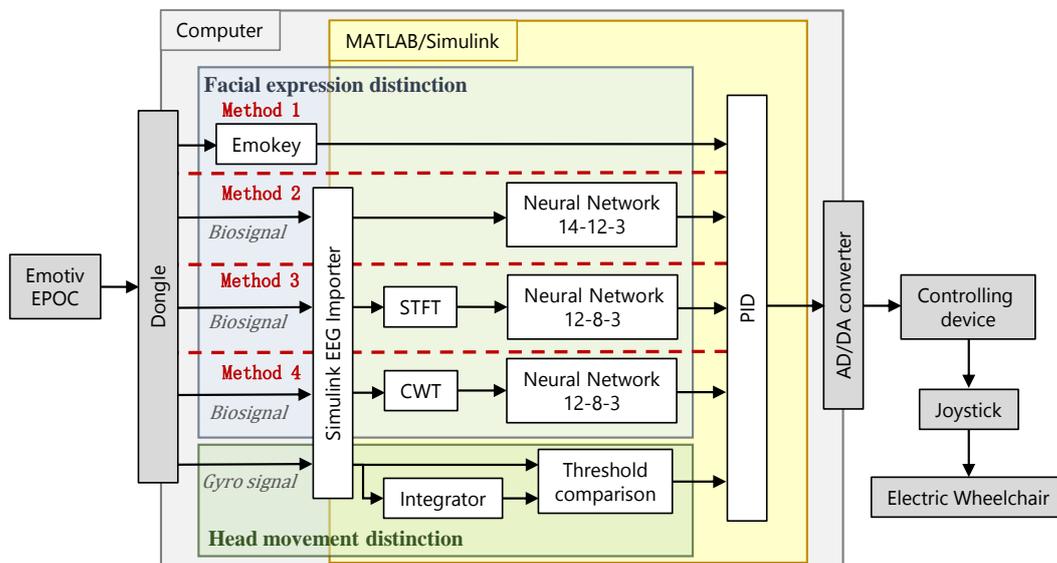


Fig. 6 System flow of Method 1 to 4

変換による周波数解析を用いた 3 種類の識別方法を提案した。以下に、これら 4 種類のコマンド識別方法を示す。また、これらのシステムフローを図 6 に示す。

a) Method 1

Method 1 は、先行研究[9]において提案された識別方法である。使用者の表情は、ヘッドセットの各電極から検出された生体信号を基に、Emokey によって 2 種類の表情「RE」および「CL」に識別される。Emokey は識別した表情を基に、コマンドとなるテキストをコンピュータに打ち込み、MATLAB/Simulink がそれを受け取る。

使用者の頭部の動作の識別は、ヘッドセットのジャイロスコープから検出された角速度および角度変位に閾値を設け、随意的に頭を右に向ける動作(TR)、左に向ける動作(TL)、不随意的に頭を動かした動作、そしてうなづく動作(Nod)に識別される。閾値は、被験者が 30° だと思ふ方向に頭を随意的に動かしたとき、うなずいたときに、角速度を測定する簡単な実験を行い、角速度とそれを積分して算出した角度変位の値を試行錯誤的に調整し、表 1 に示すように設定した。なお、表中の値において、ジャイロスコープから検出された角速度および角度変位は、使用者から見てヨー方向は左方向、ピッチ方向は下方向をそれぞれ正としている。

Table 1 Corresponding head movement and threshold value

Evaluation item	TR	TL	Nod
The longitudinally angular velocity $\omega_x$ [rad/s]	$\omega_x < -2.4$	$\omega_x > 2.4$	-
The longitudinally angular displacement $\theta_x$ [rad]	$\theta_x < -0.08$	$\theta_x > 0.08$	-
The laterally angular velocity $\omega_y$ [rad/s]	-	-	$\omega_y > 2.0$
The laterally angular displacement $\theta_y$ [rad]	-	-	$\theta_y > 0.16$

TR: Turn to the right, TL: Turn to the left

b) Method 2

Method 2 は、Emokey により生じた識別によるタイムラグを減らすために提案された識別方法である。ヘッドセットの各電極から検出された生体信号を基に、階層結合型 NN によって、使用者の表情を「RE」、「CL」および「Natural(無表情)」の 3 種類に識別する。

14 個の電極で測定した電圧値のいずれかが、試行錯誤的に定めた閾値(600 $\mu$ V)を超えた瞬間に表情が入力されたと判断し、その瞬間に 14 個の測定電極で検出した電圧値を並べたベクトルを NN への入力とした。電動車いすを操縦する前に、使用者はこの 3 種類の表情を 15 回ずつ行い、学習用の教師信号を作成した。NN は MATLAB/Neural network toolbox を使用して、表 2 に示す諸パラメータで設計し、学習則に可変学習率モーメント

法を用いて学習を行った。NN の入力層、中間層、出力層のノード数はそれぞれ 14, 12, 3 とした。出力層のノードは各表情に対応しており、出力値が 0.8 を超えたとき、そのノードに対応する表情が識別されたとした。

Table 2 Parameters of NN for Method 2

Network topology		14 - 12 - 3
Transfer function		Standard sigmoid function
Learning rate		0.1
Increase coefficient of learning rate		1.03
Decrease coefficient of learning rate		0.9
Momentum		0.6
Termination condition	The number of times of leaning	3000
	Tolerance	0.0001

使用する生体信号収集ヘッドセットは本来ゲーム用として使用されるものであるため、電極で検出される信号は EEG や顔面とその付近の EMG、体動によるノイズなどが含まれる複合信号である。本研究では、この複合信号を、ノイズ除去等の特別な処理は行わず、生体信号としてそのまま使用した。この複合信号をそのまま使用した NN を利用することにより、複合信号から操縦コマンドの識別を行うことが可能になることが期待される。

頭部の動作の識別方法は Method 1 と同じである。

c) Method 3

Method 2 では、検出された信号を、ノイズ除去等を実施することなく、そのまま識別に使用しているため、NN を使用しても身体や車いすの動作によるノイズの影響を受けることになる。そこで、Method 3 では周波数解析により生体信号の周波数帯域のみを抽出し、その周波数帯域以外のノイズを除去することで、ノイズの影響を軽減させることを試みた。

ヘッドセットの特定の電極から検出された生体信号に STFT を適用して抽出した特定の周波数スペクトルを NN の入力として使用する。周波数スペクトルを抽出する特定の電極は、顔面とその付近の EMG およびそれらの運動野の EEG が取得できると予想される電極位置 F7, F8, FC5, FC6, T7, T8 とし、抽出する特定の周波数は、予備的な測定により EMG と EEG の周波数帯域で表情コマンド入力時と非入力時のスペクトルの強さの差異がよく観察できた 8Hz と 10Hz とした。これらのスペクトル値 12 成分を並べたベクトルを NN への入力とした。表 3 に示すパラメータで階層結合型 NN を設計し、Method 2 と同様の方法で学習を行った。NN の入力層、中間層、出力層のノード数はそれぞれ 12, 8, 3 とした。Method 2 と同様に、出力層のノードは各表情に対応しており、出力が 0.5 以上のとき、そのノードに対応する表情が識別されたとした。

また、比較のため、STFT の窓幅は 32, 64, 256sample の 3 種類を用意し、それぞれ Method 3-32, Method 3-64, Method 3-256 とした。

頭部の動作の識別方法は Method 1 と同じである。

Table 3 Parameters of NN for Method 3 and 4

Network topology		12 - 8 - 3
Transfer function		Standard sigmoid function
Learning rate		0.1
Increase coefficient of learning rate		1.03
Decrease coefficient of learning rate		0.9
Momentum		0.6
Termination condition	The number of times of leaning	6000
	Tolerance	0.0001

d) Method 4

Method 4 は, Method 3 とは別の周波数解析手法により, 身体や車いすの動作によるノイズの影響の軽減を試みた識別方法である。

ヘッドセットの特定の電極から検出された生体信号に CWT を適用して抽出した特定の周波数スペクトルを NN の入力として使用して, 表情の識別を行う。周波数スペクトルを抽出する特定の電極位置は Method 3 と同じとし, 抽出する周波数も 8Hz と 10Hz に相当するスケール係数とした。これらのスペクトル値 12 成分を並べたベクトルを階層結合型 NN への入力とし, この NN のパラメータ, 学習方法, 識別条件等も Method 3 と同じとした。

STFT の場合, 時間分解能と周波数分解能は, サンプル数, 即ち窓幅に依存するため, 窓幅が小さいと周波数の分解精度が落ち, 逆に窓幅が大きいと信号の入力と解析結果の出力に時間遅れが生じる。一方で, CWT の分解能はサンプリング周波数に依存するため, 小さい窓幅でも高精度の周波数分解能を保つことが出来ると期待される。

しかしながら, 通常の CWT は計算回数が多く, 処理に時間を要する。そこで本研究では, 窓関数として矩形窓

を用いて信号を切り取ったうえで, ある特定の値の係数  $a, b$  に対する  $W(a,b)$  のみを計算するプログラムを構築し, 使用した。なお, 窓関数の幅は 8Hz と 10Hz に相当するスケール係数のウェーブレットに焦点を定め, 32sample とした。

頭部の動作の識別方法は Method 1 と同じである。

(3) 操縦装置の制御

操縦装置のモータは, 識別された操縦コマンドに対応する動きをするように制御される。各操縦コマンドに対して設定した操縦装置の各モータの目標値を表 4 に示す。この目標値に追従するように各モータに対して PID 制御系を構成した。

Table 4 Corresponding action and target value of motors

Operation Command	Action	Front-back motor target value (rad)	Right-left motor target value (rad)
CL	Stopping	0.00	0.00
RE	Going forward	0.55	0.23
TR	Going back	-0.49	0.25
	Turning right	0.25	-0.31
TL	Turning rear right	-0.25	-0.31
	Turning left	0.25	0.53
Nod	Reverse	-	-

RE: Raise eyebrows, CL: Clench,  
TR: Turn to the right, TL: Turn to the left

5. 実験

(1) 操縦コマンド識別

Method 1~4 の各識別方法において, 操縦コマンドの識別精度を検証する実験を行った。実験では, 各操縦コマンドを 40 回ずつ入力し, システムが正しく操縦コマンド

Table 5 Accuracy of recognition rate for each operation command

Environment	Method	RE	CL	TR	TL	Nod	Average
Static	Method 1	94.4%	96.3%	95.0%	98.1%	96.9%	96.3%
	Method 2	93.0%	92.0%	95.5%	94.5%	97.0%	94.4%
	Method 3-32	89.0%	85.0%	93.0%	90.0%	99.0%	91.2%
	Method 3-64	84.5%	93.0%	95.5%	93.0%	95.5%	92.3%
	Method 3-256	94.5%	91.5%	94.5%	95.0%	97.5%	94.6%
	Method 4	89.5%	91.0%	97.5%	95.5%	97.5%	94.6%
Dynamic	Method 1	72.5%	92.5%	60.8%	70.8%	71.7%	73.7%
	Method 2	74.2%	85.8%	95.0%	92.5%	93.3%	88.2%
	Method 3-32	89.2%	70.8%	82.5%	86.6%	100.0%	85.8%
	Method 3-64	87.5%	80.8%	88.3%	82.5%	96.7%	87.2%
	Method 3-256	98.3%	81.7%	89.2%	89.2%	94.2%	90.5%
	Method 4	82.5%	91.7%	85.8%	85.8%	93.3%	87.8%

RE: Raise eyebrows, CL: Clench, TR: Turn to the right, TL: Turn to the left

を識別できれば識別成功，入力したコマンドと異なるコマンドと判別した場合や，コマンドを認識しなかった場合は識別失敗として，それぞれの回数をカウントし，識別率を算出した．実験は，固定椅子に座った安静な状態 (static) では健康な 20 代男性 5 人に対して行い，平坦なアスファルト上を電動車いすに座り一定速度で移動している状態(dynamic)では健康な 20 代男性 3 人に対して行った．なお，いずれの状態においても，顔の表情および頭部の動きによる操縦コマンドを識別するプログラムのみを実行して識別を行った．実験結果から得られた各操縦コマンドの識別率を表 5 に示す．

安静な状態での実験では，いずれの識別方法も平均で 90%以上の識別精度となった．これに対して移動している状態では，いずれの識別方法においても安静な状態に比べて識別率の低下がみられたが，Method 1 と比べると Method 2 の識別率の低下は少なく，平均の識別率も高かった．したがって，NN による識別は，外乱に対してある程度頑健性があると考えられる．

Method 3-256 および Method 4 は，Method 2 に比べて表情識別の識別率低下が小さくなった一方で，頭部の動きの識別率が低くなり，全体として同程度の識別率となった．また，Method 3-32 において，特に表情コマンドの識別率は他の識別方法に比べて低い結果となった．これは STFT の窓幅の大きい Method 3-256 や，周波数分解能が窓幅に左右されない CWT を用いた Method 4 が高い識別率を保っていることから，窓幅が小さい Method 3-32 では解析信号に対する周波数分解能が低かったためだと考えられる．

## (2) タイムラグ計測

各識別方法により電動車いすを操縦した際に，操縦コマンドを入力してから電動車いすが動き出すまでのタイムラグを計測するために動画解析を行った．各識別方法を用いて電動車いすを操縦する様子をフレームレート 30fps で撮影し，その後動画解析によって，操縦コマンド入力の瞬間から電動車いすがそのコマンド通りに動き出す瞬間までのフレーム数を，表情コマンドおよび頭部動作コマンド毎にカウントした．

動画解析により得られた，操縦コマンドの入力から電動車いすが動き出すまでの平均フレーム数を表 6 に示す．

表情コマンドに関しては，解析の結果，Method 2 における表情コマンドを入力した際のフレーム数は Method 1 のそれより約 40%減少したことが分かった．これは，NN による識別により，表情コマンド入力時のタイムラグが改善されたことを意味し，これにより電動車いすの操作性の改善が期待される．

Method 2~4 を比較すると，Method 3-32, 3-64 では Method 2 と比べて同程度か僅かにフレーム数が多いが，Method 1 と比較するとタイムラグは改善された．しかしながら，CWT を用いた Method 4 は最もフレーム数が多く，Method 1 の 3.7 倍となり，次に，窓幅が大きい STFT を

用いた Method 3-256 が Method 1 の 1.8 倍と続いた．操縦コマンド識別実験では，大きなタイムラグを観察できなかったが，Method 3-256, 4 の識別方法における周波数解析では，処理に大きな負荷がかかるため，操縦コマンドを識別するプログラムと操縦装置制御のための PID 制御プログラムを同時に実行したことにより，コンピュータが処理に時間を要し，このような大きなタイムラグが生じたものと考えられる．

また，頭部動作コマンドに関しては，Method 2~4 では，いずれも Method 1 のフレーム数より多く，これはコマンド識別に用いているソフトウェアの処理速度の低下が主な原因として考えられる．Method 1 において，表情および頭部動作コマンドはそれぞれ別のソフトウェアで識別されている．一方，Method 2~4 では，両コマンドは同一のソフトウェアを用いて識別されている．したがって，一つのソフトウェアに負荷が集中し，処理速度が低下したものと推測される．周波数解析における処理速度の低下も含め，この問題はよりハイスペックのコンピュータを使用することで解決できると考えられる．

現状のシステム環境では，コマンド入力に対して電動車いす動作の遅延が大きい Method 3-256 および Method 4 は操縦には適していないと考えられる．

Table 6 Average number of the video frames and time lag

Operation command	Facial expression	Head movement
Method 1 [-] ([sec])	40.5 (1.35)	19.2 (0.64)
Method 2 [-] ([sec])	24.9 (0.83)	25.7 (0.86)
Method 3-32 [-] ([sec])	26.2 (0.87)	23.3 (0.78)
Method 3-64 [-] ([sec])	33.4 (1.11)	26.8 (0.89)
Method 3-256 [-] ([sec])	73.2 (2.44)	47.0 (1.57)
Method 4 [-] ([sec])	149.6 (4.99)	154.0 (5.13)

## (3) 識別方法の評価

本研究における実験で得られた結果から，各識別方法に対して，数値による定量的評価を行った．国土交通省の公共建築工事総合評価落札方式適用マニュアルの数値方式[11]に倣い，最高の性能等の数値  $M$  に満点を，最低限の要求要件を満たす性能等の数値  $m$  に 0 点を付与し，中間位には数値に応じ案分した点数を付与した．配点  $q$  の評価項目の評価点  $p$  の算定式を，その評価項目における評価対象の持つ数値を  $s$  とし次式により定める．

$$p = q \times \frac{s - m}{M - m} \quad (15)$$

評価項目と満点の数値，最低限の数値および配点は次の通りである．まず，操縦コマンド識別実験 Static 環境の

満点数値は 100%, 最低限の数値は 80% とし, 配点は RE, TR, TL が 20 点, CL および平均が 30 点, Nod が 10 点とした. 次に, 同実験 Dynamic 環境の満点数値は 100%, 最低限の数値は 70% とし, RE, TR, TL が 30 点, CL および平均が 40 点, Nod が 20 点とした. そして, タイムラグ計測実験の満点数値は 10 フレーム, 最低限の数値は 60 フレームとし, 表情コマンドにおけるタイムラグが 50 点, 頭部動作コマンドにおけるタイムラグが 40 点とし, 合計 410 点満とした. ここで, 電動車いす操縦において重要な項目の配点は大きく, 逆に比較的重要ではないと考えられる項目の配点は小さくした.

この配点を基に算定された評価点の合計と評価順位を表 7 に示す.

評価点を比べると, NN の利用により, Method 2 は Method 1 から大きく改善されたことが分かる. この NN による改善の効果は大きく, 周波数解析を加えた識別方法よりも順位が高い結果となった.

STFT を加えた Method 3 の中では, Method 3-64 が識別率とタイムラグの改善が両立されており, 評価が高かった. しかしながら, 識別率だけをみると Method 3-256 の方が Method 3-64 より優れた結果が得られているため, システム環境等の改善により操縦コマンド識別時のタイムラグが改善された場合, Method 3-256 の評価が Method 2, Method 3-64 より良くなる可能性がある. Method 3-32 は, Method 3-64 よりコマンド識別が若干早かったものの, 識別率が一番低かったため, 総合評価も低くなったと考えられる.

Method 4 は, コマンドの識別率は高かったものの, CWT による処理の負荷が大きく, 識別時のタイムラグが著しく大きくなってしまったことにより, 低い評価となった. Method 3-256 と同様に, システム環境等の改善により評価が良くなる可能性はある.

Table 7 Total score and rank

Distinction method	Total score	Rank
Method 1	196	6
Method 2	266	1
Method 3-32	219	4
Method 3-64	235	2
Method 3-256	228	3
Method 4	202	5

## 6. 結論

本研究では, 生体信号収集ヘッドセットにより検出した生体信号から, ニューラルネットワークおよび周波数解析を用い, 搭乗者の顔の表情と頭の動きを識別し, 電動車いすを制御するシステムを構築した. これにより, 従来の制御方法である Method 1 において確認された表情コマンド入力時のタイムラグを減少させ, 且つ電動車いす操作時の操縦コマンドの識別率の低下を抑えることで, 電動車いすの操作性を改善することが出来た.

一方, 課題としてタイムラグと識別率を両立して改善

するためには, 高速な情報処理が可能な環境が必要であることが挙げられる. また, Method 1 から続く課題である, 操縦装置がジョイスティックを傾斜させる角度が一定であることも改善の余地がある.

今後は更なる操作性の向上のために, NN の最適なパラメータの探求, 使用するセンサー数の削減, 周波数解析のプログラム, およびシステム環境の改善による処理速度の向上, 操縦装置によりジョイスティックを傾斜させる角度を多様化させ, 搭乗者が望む速さ, 旋回半径で電動車いすを操縦できるようにすることが必要である.

## 参考文献

- 1) P. C. Petrantonakis, and L. J. Hadjileontiadis : Emotion Recognition From EEG Using Higher Order Crossings, IEEE Trans. Inf. Technol. Biomed., Vol.14, No.2, pp.186-197, 2010
- 2) M. Carroll, G. Surpris, S. Strally, M. Archer, F. Hannigan, K. Hale, and W. Bennett : Enhancing HMD-Based F-35 Training through Integration of Eye Tracking and Electroencephalography Technology, Lecture Notes in Computer Science, Vol.8027, pp.21-30, 2013
- 3) Emotiv Systems, <http://www.emotiv.com>.
- 4) NeuroSky, <http://www.neurosky.com>.
- 5) 佐伯俊一, 堀江亮太 : 簡易脳波計とスマートデバイスを用いたブレイン-コンピュータ・インターフェースシステムの考案および実施, 生活生命支援医療福祉工学系学会連合大会 2014 講演要旨集, GS7-4, 2014
- 6) 茨木仁希, 中村恭之 : 脳信号収集ワイヤレスヘッドセットを用いた電動車椅子ロボットの制御, ロボティクス・メカトロニクス講演会 2013 講演論文集, No13-2, 2A1-C06, 2013
- 7) E. J. Rechy-Ramirez, H. Hu, and K. McDonald-Maier : Head movements based control of an intelligent wheelchair in an indoor environment, Proc. of 2012 IEEE Int. Conf. on ROBOTICS, pp.1494-1469, 2012
- 8) F. B. Taher, N. B. Amor, M. Jallouli : A multimodal wheelchair control system based on EEG signals and Eye tracking fusion, Proc of 2015 International Symposium on Innovations in Intelligent Systems and Applications, 2015
- 9) 松澤海良, 小西遼一, 石井千春 : 生体信号収集ヘッドセット Emotiv EPOC を用いた電動車いすの制御, ロボティクス・メカトロニクス講演会 2015 講演論文集, No15-2, 2A1-I01, 2015
- 10) 小西遼一, 石井千春 : 生体信号により電動車いすを操縦するためのデバイスの開発, 生活生命支援医療福祉工学系学会連合大会 2014 講演要旨集, GS3-3, 2014
- 11) 中央省庁官繕担当課長連絡調整会議幹事会 : 公共建築工事総合評価落札方式適用マニュアル・事例集(第1版), pp.8, 2007, <http://www.mlit.go.jp/gobuild/hinkaku/sougou1.pdf>.