

修士論文

fNIRS データにおけるチャンネルの  
最適選択による関心領域の検討

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 1043番

吉田 倫也

指導教授 廣安 知之教授

2015年1月23日

## Abstract

We have proposed a method for extracting optimal regions of interest (ROI) through the selection of optimized channels, using machine learning classifiers and genetic algorithms in relation to functional near-infrared spectroscopy (fNIRS) data. Classifiers in machine learning have been used for determining labels belonging to test data. By using classifiers in the proposed method when determining object functions through optimization of existing discriminant functions, identifying the brain function area related to a particular subject is possible. In feature extraction, dynamic time warping (DTW) is used to extract any similarity in fNIRS data, and brain function areas are identified for a certain subject through classification by the support vector machine (SVM) and feature extraction using the genetic algorithm (GA). We confirmed the extraction of the areas related to working memory (WM) and results related to the brain function network by applying the proposed method to a time series of cerebral blood flow during a reading span test (RST).

# 目次

<b>1</b>	<b>序論</b>	<b>1</b>
<b>2</b>	<b>SVM による識別と GA を用いた特徴選択</b>	<b>2</b>
2.1	パターン認識とは . . . . .	2
2.2	Support Vector Machine . . . . .	2
2.3	パターン認識と特徴選択 . . . . .	5
2.4	Genetic Algorithm を用いた特徴選択 . . . . .	5
<b>3</b>	<b>fNIRS 時系列データと DTW</b>	<b>7</b>
3.1	神経血管カップリングと fNIRS 時系列データ . . . . .	7
3.2	Dynamic Time Warpping . . . . .	7
3.3	DTW による特徴抽出 . . . . .	7
<b>4</b>	<b>fNIRS 時系列データの類似度を特徴量とする関心領域の検討</b>	<b>9</b>
4.1	提案手法の流れ . . . . .	9
<b>5</b>	<b>実験</b>	<b>11</b>
5.1	実験目的と実験方法 . . . . .	11
5.2	実験結果と実験考察 . . . . .	11
<b>6</b>	<b>結論</b>	<b>13</b>

# 1 序論

近年, fMRI (functional magnetic resonance imaging)<sup>1,2)</sup> や fNIRS(functional Near-Infrared Spectroscopy) 装置<sup>3)</sup> といった非侵襲脳機能イメージング装置の利用が進んでいる。特に fNIRS については, その取り扱いの容易さから臨床への応用だけでなく, 心理学的, 工学的な分野での応用も進んでいる<sup>4-6)</sup>。fMRI においては, 得られた信号の汎用的な処理方法が確立されており, SPM といった汎用のアプリケーションも広く利用されている<sup>7-9)</sup>。一方で, fNIRS においては, その歴史が短いことから, 汎用的なデータ処理方法が確立されておらず, 特に fNIRS の特性をうまく利用した解析方法は今後の課題である<sup>10)</sup>。

本研究では, あるタスクを行った際に fNIRS 装置から得られる脳機能情報に対して, 機械学習の識別器と進化計算による最適化を利用することにより, そのタスクに重要な脳部位を特定する手法を提案する。support vector machine (SVM)<sup>11)</sup> を代表とする機械学習の識別器の利用は広い範囲で行われ, 大きな成果をあげている。機械学習の識別器の利用については, ラベルのついた教師データの特徴量を入力として, そのラベル識別が可能となるような識別器を構築し, 未学習データに対してそのラベルを推測するというのが一般的である。それに対して, 本研究では, fNIRS 装置の各チャンネルに関連した特徴量を持つラベル付けが行われている教師データを用意する。cross-validation による識別器の精度が最も高くなるような特徴量の選択(チャンネルの選択)を進化計算を利用して行う。これは, 脳機能に起因したラベル付けの識別の精度が最も高くなるような特徴量の組み合わせは, その脳機能の変化を引き起こしたタスクに対してもっとも重要な特徴量であるといえることを仮定としている。実際に, 特徴選択によっては, 識別器の精度は異なる。識別を最大にするような適切な特徴選択は, 対象とする課題の関連する脳機能の中でもラベル分割するために最も重要な特徴量であるといえ, この特徴量と深く関連する部位を決定することで, この課題における脳機能の関心領域の特定を行うことができる。

本手法で重要なのは, 識別の際に利用する特徴量の決定, 識別器の選択およびチャンネル選択の方法である。本手法では, 各ラベルは被験者に付随し, 各被験者の持つ特徴量に対して識別を行う問題を対象としている。特徴量は, 各チャンネル間の類似度とした。類似度の値には, dynamic time warping (DTW)<sup>12)</sup> を利用している。また, 識別器には多くの問題で成果をあげている SVM<sup>11)13)</sup> を使用している。特徴選択(チャンネル選択)は全組み合わせを検討する必要があるが, 組み合わせが膨大であり実時間内に解を得ることが難しい。選択は離散的であり, 進化計算の親和性が高いため, genetic algorithm(GA)<sup>14)</sup> を用いた<sup>15)</sup>。これらの詳しい手法については, 次章以降で述べる。

本論文では, 第2章に識別と GA を用いた特徴選択に関して述べる。第3章では, fNIRS 時系列波形において, 如何に DTW を用いて特徴量を抽出するのかを示した。第4章で, 提案手法である脳機能の推定のための解析手法に関して示し, 第5章ではそれを確認するための検証実験を示した。

## 2 SVMによる識別とGAを用いた特徴選択

### 2.1 パターン認識とは

パターン認識とは、認識対象がいくつかの概念に分類できるとき、観測された認識対象をそれらの概念に対応させる処理をすることである。例えば、数字などのパターン認識であれば、観測された認識対象を0, 1, ..., 9の10種類の数字のいずれかのパターンに対応させることである。これらを機械によって実現したものを機械学習という。

パターン認識を機械学習上で実現するためには、認識対象から何らかの特徴を数値として計測、抽出することを考えなければならない。この数値を特徴量と呼ぶ。一般的には、ある認識対象に対して複数の特徴量を計測または抽出することによってパターン認識する場合が多い。例えば、数字の認識においては、文字の傾きや面積、エッジなどを利用することでパターン認識を行う。このような、複数の特徴量はまとめて特徴ベクトル  $x = (x_1, \dots, x_n)$  として表される。ここで、 $n$  は特徴量数を表す。この特徴ベクトルによって実現される  $n$  次元の空間を特徴量空間という。この時、認識対象のクラスの総数を  $k$  としたとき各クラスを  $C_1, \dots, C_k$  と表す。特徴ベクトルつまり特徴量の選び方が適切であった場合、特徴量空間において、各クラスにデータは分布しクラスタをつくることになる<sup>16)</sup>。

パターン認識または機械学習において基本的な課題は、未知の認識対象のデータが得られた時に、その対象がどのクラスに属するのか判定する識別方法を開発することである。そのために、クラスが既知であるデータの特徴ベクトルとクラスの対応を学習することが必要となる。このクラスが既知であるデータを学習データと呼ぶ。また、あるクラスが提示された上での学習を教師あり学習と呼ぶ。

学習する際、学習された特徴ベクトルとクラスとの対応関係に関する確率的知識を利用し、与えられた未知のデータの特徴ベクトルからそのデータがどのクラスに分布するかを推定する方法が必要となる。その際、間違った識別をする確率(誤識別率)を小さくすることが望まれる。このような識別問題においては、ベイズ識別理論として研究され様々な手法が考えられている。その中でも、教師あり学習の中でも優秀とされるSVMについて次項で述べることにする<sup>17)</sup>。

### 2.2 Support Vector Machine

SVMとは教師あり学習の一種で、識別器のことである。SVMは教師あり学習において優秀なモデルとされる<sup>18)</sup>。

SVMの学習手法は、学習データからマージン最大化という基準で線形しきい素子のパラメータを学習する。線形しきい素子は、ニューロンを単純化したモデルで表される。入力である特徴ベクトルに対し、線形識別関数式(2.1)により2値の出力値を計算する。

$$y = \text{sign}(w^T x - h) = \begin{cases} 1 & (w^T x - h > 0) \\ 0 & (w^T x - h = 0) \\ -1 & (w^T x - h < 0) \end{cases} \quad (2.1)$$

ここで、 $w$  は重みベクトルであり、 $h$  はバイアスパラメータである。

式 (2.1) の関数は入力ベクトルである特徴ベクトルと重みベクトルの内積がしきい値を超えれば 1 を出力し、超えなければ -1 を出力する関数である。これは、幾何学的には識別超平面により入力特徴空間を 2 つに分けることに相当する。次に学習方法の概略を示す。

2 つのクラスを  $C_1, C_2$  とし、各クラスのラベルを 1 と -1 に数値化しておくとする。また、学習データ集合として、 $n$  個の特徴ベクトル  $x_1, \dots, x_n$  と、それぞれの学習データ集合の各要素に、正解のクラスラベル  $t_1, \dots, t_n$  が与えられているとする。簡単のために、この学習データ集合は、線形分離可能であると仮定する。すなわち、パラメータを調整することで、学習データ集合は誤りなく分けることができるとする。しかし、学習データ集合が線形分離可能であるとしても、学習データ集合を誤りなく分けるパラメータは一意には決まらない。そこで、SVM では、マージンが最大となるような識別平面を求める。もし、訓練データ集合が線形分離可能なら、式 (2.2) を満たすパラメータ  $w, h$  が存在する。

$$t_i(w^T x_i - h) \geq 1, \quad i = 1, \dots, n \quad (2.2)$$

式 (2.2) は  $H1: w^T x - h = 1$  と  $H2: w^T x - h = -1$  の 2 枚の超平面によって学習データが完全に分離され、 $H1$  と  $H2$  の超平面の間にはデータがひとつも存在しないことを示している。Fig. 1 にその概略図を示す。

このとき、識別超平面 (Hyperplane) と超平面 ( $H1$  または  $H2$ ) との距離は、 $\frac{1}{\|w\|}$  となる。したがって、マージンを最大とするパラメータ  $w$  と  $h$  を求める問題は、制約条件式 (2.2) の下で、目的関数式 (2.3) を最小化とするパラメータを求める問題と等価である。この問題は、二次計画問題として解を得ることが可能である。ここではこの問題を双対問題<sup>1</sup>に帰着することで解いていくことにする。

$$L(w) = \frac{1}{2} \|w\|^2 \quad (2.3)$$

Lagrange 乗数  $\alpha_i (\geq 0), i=1, \dots, n$  を導入することで、目的関数を式 (2.4) と書き換える。

$$L(w, h, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i \{t_i(w^T x_i - h) - 1\} \quad (2.4)$$

パラメータ  $w$  および  $h$  に関する偏微分より停留点では、式 (2.5)、式 (2.6) が成り立つ。

$$w = \sum_{i=1}^N \alpha_i t_i x_i \quad (2.5)$$

<sup>1</sup>線型計画問題における主問題の補問題を指す。どちらか一方の解法が主問題と補問題の両方の問題の解法となる。

$$0 = \sum_{i=1}^N \alpha_i t_i \quad (2.6)$$

これらを目的関数に代入することで，制約条件である式 (2.6) かつ  $0 \leq \alpha_i, i=1, \dots, n$  の下で目的関数式 (2.7) を最大とする双対問題が得られる．

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j t_i t_j x_i^T x_j \quad (2.7)$$

これは，Lagrange 乗数  $\alpha_i^*, i=1, \dots, n$  に関する最適化問題となる．その解で  $\alpha_i^*$  が 0 でない，すなわち， $\alpha_i^* > 0$  となる学習データ  $x_i$  は，先の 2 つの超平面  $w^T x - h = 1$  か  $w^T x - h = -1$  のどちらか上にある．このことから， $\alpha_i^*$  が 0 でない学習データのことを Support Vector (SV) と呼んでいる．一般的に，SV は学習データに比べデータ数が少ない．つまり，学習データの中から小数の SV を選び，それらの SV のみを用いて識別関数が決定される．これらの方法により，SVM はマージン最大化という基準によって，学習データを選択することで学習器の自由度を抑制するようなモデル選択がなされていると解釈できる．

ここまででは，完全に線形分離可能な学習を見てきた．しかし，学習において線形分離が不可能な場合が出てくる．そこで，利用されるのがカーネルトリックである．

カーネルトリックとは，線形分離できない問題に対しても線形しきい素子のパラメータを求めることが可能となる．これは，本質的に非線形で複雑な識別課題に対して，特徴ベクトルを非線形に変換することによって線形識別を可能とするものである．この方法を用いることによって SVM の性能は飛躍的に向上した．以下に，カーネルトリックに関して概説する．

ここで，特徴ベクトル  $x$  を非線形の写像  $\phi(x)$  によって変換し，その空間で線形識別を行うことを考える．例えば，写像  $\phi$  として，入力特徴を 2 次の多項式に変換する写像を用いるとすると，写像した先で線形識別を行うことは，もとの空間で 2 次の識別関数を構成することに対応する．一般には，こうした非線形の写像によって変換した特徴量空間の次元は非常に大きくなりやすい．しかし，SVM の場合には，目的関数  $L_D$  や識別関数が入力パターンの内積のみに依存した形となっており，内積が計算できれば最適な識別関数を構成することが可能である．つまり，非線形に写像した空間での 2 つの要素  $(x_1)$  と  $(x_2)$  の内積が式 (2.8) のように，入力  $x_1$  と  $x_2$  のみから計算可能であれば，非線形写像によって変換された特徴空間での特徴  $\phi(x_1)$  や  $\phi(x_2)$  を陽に計算する代わりに， $K(x_1, x_2)$  から最適な非線形写像された特徴ベクトルを構成することが可能である．

$$\phi(x_1)^T \phi(x_2) = K(x_1, x_2) \quad (2.8)$$

このような  $K$  の事をカーネルと呼ぶ．このように高次元に写像しながら，実際には写像された空間での特徴計算を避け，カーネルの計算のみで最適な識別関数を構成する技術のことをカーネルトリックと呼んでいる．代表的なカーネル  $K$  は例えば式 (2.9) の多項式

カーネル，式 (2.10) の Gauss カーネル，式 (2.11) のシグモイドカーネルなどが利用されている。

$$K(x_1, x_2) = (1 + x_1^T x_2)^p \quad (2.9)$$

$$K(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right) \quad (2.10)$$

$$K(x_1, x_2) = \tanh(ax_1^T x_2 - b) \quad (2.11)$$

$$y = \text{sign}\left(\sum_i \alpha_i^* t_i K(x_i, x) - h^*\right) \quad (2.12)$$

ここで示す， $h^*$  は最適解を示す。式 (2.12) では，内積をカーネルで書き換えた形に書ける。カーネルトリックを用いた非線形に拡張された SVM では，入力層から出力層に適応的学習により求めない代わりに，中間層に非常に多くのユニットを置くことで複雑な線形写像を実現している。

### 2.3 パターン認識と特徴選択

特徴選択とは， $k$  個の特徴ベクトルで記述されている特徴すべてを利用せず，有用な特徴量の部分集合のみを選択する手法の事である。

パターン認識において特徴選択は重要になる。その理由としては，目的変数と無関係な特徴量を使わないことで予測精度を向上させること，学習された識別関数を定性的に解釈しやすくすることである。本論文で重要となるのは，後者である。それらを利用することによって，識別されたデータのクラス間の違いを良く表す特徴を抽出できると考える。

特徴量が  $k$  個あるとき，全部で  $2^k - 1$  個の特徴量の部分集合がある。これらすべてを計算することは計算的に困難であることから，次のアプローチがとられる。1 つは  $k$  個の特徴がある状態から不要な特徴を除いていく手法であり，もう 1 つは有用な特徴を追加していく手法があげられる。特徴の有用さを計る指標としては，情報ゲイン<sup>2</sup>が用いられる。本論文では，Genetic Algorithm(GA) を用いた特徴選択を行っている。次の項では，その GA を利用した特徴選択について述べることにする。

### 2.4 Genetic Algorithm を用いた特徴選択

特徴選択のための GA では，求めるべき特徴の部分集合を染色体に対応させなければならない。その際，識別率 (Accuracy: Acc) の高いものが環境に適応しているとして，進化計算を行う。その GA を用いた特徴選択の手順を説明する。

<sup>2</sup> 確率論と情報理論における 2 つの確率分布の差異を計る尺度である。

### Step.1 初期個体集団の適応度の計算と評価

初期集団 (世代数  $t=1$ ) の染色体の遺伝子  $g_{ij}$  の値は自然数の  $0, 1$  として乱数によって与えられる。更に、集合  $Q$  に属する  $N$  個の個体の適応度  $J$  をそれぞれ求める。この次世代への生き残りやすさのことを適合度 (Fitness) と呼ぶ。本論文では、適応度の計算を  $Acc$  とした。  $Acc$  が高いものが環境に適応している。

### Step.2 選択

この操作では、まず各個体の評価値から次世代への生き残りやすさを求め、これに基づいて次世代の母集団を形成する。各個体の評価値から次世代への適合度を求め、これに基づいて次世代の母集団を形成する。

### Step.3 交叉

集合  $M$  から重複を許さないでランダムに 2 つずつ個体を選択し、交叉率  $P_c$  で交叉を行う。交叉を行う場合は、交叉位置をランダムに決定し、1 点または多点で交叉を行う。

### Step.4 突然変異

集合  $M$  の個体  $X_i$  に対応する染色体  $G_i$  の  $j$  番目の遺伝子  $g_{ij}$  が突然変異率  $P_m$  で変更される。遺伝子に変更される場合には、自然数の  $0$  もしくは  $1$  が乱数によって与えられる。

### Step.5 適応度の計算と評価

集合  $M$  に属する  $N$  個の個体の適応度をそれぞれ求める。

### Step.6 終了判定

あらかじめ定められた終了条件に基づいて GA を終了させる。そうでなければ、Step.2 に戻り計算を繰り返す。

### 3 fNIRS 時系列データと DTW

#### 3.1 神経血管カップリングと fNIRS 時系列データ

神経血管カップリング (Neurovascular Coupling : NVC) とは、局所的脳活動の発生によりその領域の血流が増加する現象である。脳活動による局所的な血流増加がみられる要因としては、神経活動に伴って生じるさまざまな生化学的变化が血管拡張を引き起こすからであると考えられている。fNIRS 装置では、血流内の酸素化ヘモグロビン (Oxy-Hb) 濃度変化量と脱酸素化ヘモグロビン (Deoxy-Hb) 濃度変化量を fNIRS 時系列データとして得ることが可能である。酸素化ヘモグロビン濃度変化量の fNIRS 時系列データの一例を Fig. 2 に示す。脳の活性化領域では酸素化ヘモグロビン濃度変化量の増加を、脱酸素化ヘモグロビン濃度変化量の減少を引き起こす。これは神経活動時の酸素消費の増加を上回る、血流増加を反映しているためと考えられている。また、その増加は Fig. 2 のように fNIRS 時系列データに長時間の大きな波形の変化として表れる。

#### 3.2 Dynamic Time Warpping

Dynamic Time Warpping(DTW) とは、2つの時系列波形がどれくらい似ているのかを数値として示すアルゴリズムである。

長さ  $n$  の時系列データ  $X = (x_1, x_2, \dots, x_n)$  と長さ  $m$  の時系列データ  $Y = (y_1, y_2, \dots, y_m)$  の DTW 距離 (類似度)  $D = (X, Y)$  は式 (3.1) のように定義される。

$$\begin{cases} DTW(X, Y) = f(n, m) \\ f(i, j) = |x_i - y_j| + \min \begin{cases} f(i, j - 1) \\ f(i - 1, j) \\ f(i - 1, j - 1) \end{cases} & (i = 1, \dots, n; j = 1, \dots, m) \\ f(0, 0) = 0, \quad f(i, 0) = f(0, j) = \infty \end{cases} \quad (3.1)$$

ここで、 $\|x_i - y_j\|$  は2つの数値の距離を表す。簡単にはユークリッド距離の差に対応する。次に、2つの時系列波形間の DTW 距離は動的計画法を用いて計算される。動的計画法とは、最適性原理<sup>1</sup>を利用した、段階を踏んで最適解を求める多段決定法である。これにより、時系列に波形を伸縮しながら最適決定を順次行い、時系列波形  $X$  と時系列波形  $Y$  の DTW 距離が求まる。

#### 3.3 DTW による特徴抽出

fNIRS 時系列データにおいて DTW 距離の計算つまり特徴量の抽出を行なった。本論文では、あるプローブにおけるチャンネルを2つずつ選択し、そのチャンネル間の DTW 距離計算を行った。Fig. 3 に fNIRS 装置における前頭部のプローブとチャンネルの関係を示す。

<sup>1</sup> 決定の全系列にわたって最適化を行うためには、初期の状態と最初の決定がどんなものであっても、残りの決定は最初の決定から生じた状態に関して最適な政策を構成していなければならない

例えば, Fig. 3 に示すプローブにおいて DTW を用いた特徴量計算の流れを以下に示す. はじめに, CH1-CH22 の 22 個のチャンネルにおいて 2 つずつチャンネルを選択し DTW によって類似度の計算を行った. これらをすべての組み合わせに対して計算することによって, CH1 に対して CH1-CH22 の 22 次元の特徴量が CH-1CH22 に対して計算を行うことによって,  $22 \times 22$  の特徴量を得る. つまり, 各チャンネルにおいて, 22 次元 (CH1-22 までの距離) の特徴量を持つことになる.

これらの特徴量を用いて, 2.2, 2.3 で示した特徴抽出を行うことで, タスクにおけるクラス間の違いを最もよく表す特徴量つまりチャンネルを特定することが可能となる.

## 4 fNIRS 時系列データの類似度を特徴量とする関心領域の検討

本研究では、あるタスクを行った際に、脳機能に起因するラベルが被験者につくような問題を対象とする。例えば、ある環境下でタスクを行った際に、男女に有意差があるような場合や、あるタスクに対する成績の高低に有意さがあるような問題である。各被験者に対して、設計された実験を行い、fNIRS により脳機能の時系列データを取得する。また、その成績や血流量の結果から、被験者に対してラベル付けを行う。ここでは  $A$  および  $B$  とする。チャンネル数が  $n$  個であれば、各被験者  $m$  人に対して  $n$  個の時系列データが得られる。各被験者が持つ特徴量は、この  $n$  個の時系列データの類似度とした。よって、すべての  $n$  個の時系列データを利用する場合には、 $nC_2$  次元のデータとなる。本研究では、類似度を求める際に、DTW 距離を利用する。これは、各チャンネルにおける血流量変化は、刺激に対して厳密でなく、多少のずれが生じるため、これらのずれに対応するためである。しかしながら、類似度のさらなる検討は必要であり、今後の課題である。

各被験者がもつ  $nC_2$  次元の特徴量データから、いくつかの要素を抽出して、識別器を構築するための入力データとする。このデータを利用して  $m$  サンプルに対してクロスバリデーション法を用いて識別器を構築し識別率を求める。本研究では識別器に SVM を利用した。SVM は最も汎用的な手法の 1 つであることが使用の理由であるが、識別器に何を使えば良いかについても今後の課題である。この識別率を最大にするような特徴量の組み合わせを算出する。チャンネル選択においては、全探索を行うことが望ましいが、実時間で処理するために、この選択には GA を利用する。この操作により、識別率を最大にするような、特徴量の選択が行われた。特徴量には、チャンネル間の類似度を利用している。そのため、対象とするタスクによるラベル識別を行うためには、選択されたチャンネルのネットワークが重要であることがわかる。よって、本手法の結果から、重要なチャンネル（部位）がわかるだけでなく、重要なチャンネル間のネットワークも明らかになる。

### 4.1 提案手法の流れ

脳機能を活用するある課題を使って、複数の被験者に対して fNIRS 測定を行いデータを取得する。被験者群の特性や課題の成績から、2 群のラベル付けを行っておく。この後、次の手順により、この課題結果から群分けを決定すべきチャンネルを次の手順で求める。決定されたチャンネルに関連する部位が、この課題における関心領域である。

#### Step.1 着目チャンネルの決定と DTW 距離の算出

全チャンネルの中から着目するチャンネルを決定する。着目されたチャンネル間の類似度を DTW 距離を算出することで求める。着目されたチャンネルが例えば 5 つのチャンネルであれば、各被験者のデータは 10 次元のデータとなる。

#### Step.2 識別器の構築

被験者群のデータのうち、識別器構築に使うための教師データと識別器の精度を測る

ためのテストデータに分類する．教師データを利用して識別器を構築し，テストデータで精度を求める．クロスバリデーション法により，着目されたチャンネルに対する平均の精度を求める．

### Step.3 最適なチャンネルの決定

別のチャンネルの組み合わせを作り，Step.1 および Step.2 を繰り返し，識別率を最大とするチャンネルの組み合わせを算出する．ここでは GA を用いた特徴選択を行う．この時，GA の適応度の計算は SVM の識別率を用いて行う．識別率が高いほど環境に適応してるとして遺伝的操作を行う．これらによって，識別率の高い特徴量の組み合わせを知ることが可能である．

## 5 実験

実験では、提案手法の有効性を確認するために、RSTにおけるfNIRS時系列データを利用しその有効性を検証した。

### 5.1 実験目的と実験方法

実験目的は、fNIRSデータに対して提案手法を適用することによって得られるチャンネルの比較、検討することによって提案手法の有効性を検討する。実験の流れを次に示す。

RSTを用いたfNIRSデータを利用し、DTWによって類似度の抽出を行った。実験で用いたfNIRSデータはFig. 4に示す流れによって取得した。また、この実験は、被験者数19人に行われた。その後、正答数の高い高成績群10人と正答数の低い低成績群9人に分類した。Fig. 5に各被験者のRSTの成績を示す。NIRSは日立メディコ製のETG-7100の3プローブ(70チャンネル)を用いて前頭部を測定した。室温は21.3-24.5[ ]、湿度は47-52[%]である。

DTWの計算に用いたfNIRSデータはタスク区間の220-280[s]の区間を利用した。課題時間に違いがあるのは、被験者によって課題終了の時間が異なるためである。fNIRSデータには前処理を施しており、その前処理の内容をTable. 1に示した。

次に、得られた特徴量を利用しGAとSVMを用いて特徴選択を行った。SVMで利用したパラメータをTable. 3に示した。GAに用いたパラメータはTable. 4に示した。特徴量選択について、使用するチャンネル間の類似度を1、使用しないチャンネル間の類似度を0として、遺伝子型を設計している。

これらによって、得られた部位を既存研究の結果から比較、検討を行った。

### 5.2 実験結果と実験考察

各頭部における識別結果について示す。実験によって得られた、RST時における関心領域をFig. 6に示した。この時、右側頭部、左側頭部、前頭部における識別率は、84.21[%]、89.47[%]、97.73[%]であった。

ここで、脳機能部位と選択されたチャンネルに関して最も大きく識別率に影響しているチャンネルを検討する為に、選択された特徴量の一つずつ除くことによって識別率の変化をみた。大きく識別率が減少する特徴量こそ最も課題に対して影響のある脳機能部位と特定できる。Table. 5, 6, 7に各チャンネルにおける識別率の結果を示す。

右側頭部においてはチャンネル2, 4, 14が大きな因子に、左側頭部においてはチャンネル11が大きな因子に、前頭部においてはチャンネル18が大きな因子となっていることが推定された。右側頭部はチャンネル2は中側頭回付近に位置し、チャンネル4はブローカー野付近に、チャンネル14は視覚連合野、紡錘状回、ウェルニッケ野付近に位置している。左側頭部チャンネル11は紡錘状回付近に、前頭部チャンネル18は前頭前野背外側部付近に位置している。これら選択された関心領域は先行研究によりRSTにおけるワーキ

ングメモリに関与する部位であることが示されている．これらの結果から提案手法の有効性が示唆された．

DTW 値を用いたネットワークに関する検討も行った．その結果を Fig. 8, 9 に示す．先行研究<sup>19)</sup>では，高成績者においては紡錘状回との結合が弱く，低成績者においては紡錘状回との結合が強いことが報告されている．Fig. 8, 9 の結果からはすべての被験者ではないが多くの被験者にその傾向がみられた．この結果から，脳機能に関するネットワークの考察も可能であることが示唆された．

次に，前頭，両側頭部における識別結果を示す．

実験によって得られた，RST 時における関心領域を Fig. 7 に示した．この時，これら関心領域を利用した高成績と低成績の識別率は 84.21[%] であった．これらのチャンネルは，RST 時の高成績と低成績における脳機能部位に違いがみられる部位と推定できる．

ここで，脳機能部位と選択されたチャンネルに関して最も大きく識別率に影響しているチャンネルを検討する為に，選択された特徴量の一つずつ除くことによって識別率の変化をみた．大きく識別率が減少する特徴量こそ最も課題に対して影響のある脳機能部位と特定できる．Table. 8 に各チャンネルにおける識別率の結果を示す．

これらの結果をまとめると，右側頭部においてはチャンネル 5 が大きな因子に，左側頭部においてはチャンネル 15 が大きな因子に，前頭部においては微小ではあるがチャンネル 1 が因子となっていることが推定された．つまり，RST における高成績もしくは低成績に関係する部位は右側頭部チャンネル 5，左側頭部チャンネル 15，前頭部チャンネル 1 が関係してると考えられる．

以下に各部位において重要な因子となっているチャンネルの脳機能部位と Brodman Area(BA) について示す．右側頭部のチャンネル 5 は Middle Temporal gyrus(BA:21)，Superior Temporal Gyrus(BA:22) 付近に位置している．左側頭部のチャンネル 15 は Middle Temporal gyrus(BA:21)，Superior Temporal Gyrus(BA:22)，Fusiform gyrus(BA:37)，Angular gyrus, part of Wernicke's area(BA:39)，Supramarginal gyrus part of Wernicke's area(BA:40) 付近に位置している．前頭部のチャンネル 1 は Frontopolar area(BA:10) 付近に位置している．これら選択された関心領域は先行研究により RST におけるワーキングメモリに関与する部位であることが示されている．これらの結果から提案手法の有効性が示唆された．

## 6 結論

本論文では、DTW による特徴量抽出と GA による特徴選択を行うことによって関心領域の抽出の提案を行った。本提案手法では課題時の脳血流量を測定した際、脳機能の知識を必要とせず、課題における重要部位を特定することが可能になる。提案手法を用い RST を行った fNIRS データを提案手法に適応し検証実験を行った。その結果、RST に関わるワーキングメモリの部位を抽出することができることが確認され、本提案手法の有効性を示唆することが確認された。加えて、選択されたチャンネルを再度、後ろ向き特徴選択を行ったチャンネルの DTW 値を用いて、脳機能ネットワークに関する考察を行った結果、先行研究によって示された、紡錘状回付近の結合に関わる考察も示された。以上より、脳機能ネットワークに関わる考察も可能であることが示唆された。

## 謝辞

まず初めに、本研究を遂行するにあたりご指導、ご協力を頂きました同志社大学生命医科学部の廣安知之教授、山本詩子助教、田中美里特別任用助教に心より感謝の意をこの場をお借りして申し上げたいと思います。廣安知之教授には、3年間研究に関するだけでなく、学会への参加、勉強会などを通してさまざまなことをご指導、ご鞭撻頂きました。山本詩子助教、田中美里特別任用助教には月例発表会などを通して研究に関するアドバイスを頂き大変参考になりました。また、本論文の執筆に際して指導・校正に尽力してくださいました白石駿英さん、大久保祐希さん、研究の内容や発表に関して長時間にわたり真剣に議論してくださいましたデータマイニング班(埜賢哉さん、佐藤琢磨さん、田村さん、勝林さん)、fNIRS 時系列データの提供と助言いただいた眞島希実さん、皆様にお礼申し上げます。

## 参考文献

- 1) Edgar A DeYoe, Peter Bandettini, Jay Neitz, David Miller, and Paula Winans. Functional magnetic resonance imaging (fmri) of the human brain. *Journal of neuroscience methods*, Vol. 54, No. 2, pp. 171–187, 1994.
- 2) Kenneth K Kwong, John W Belliveau, David A Chesler, Inna E Goldberg, Robert M Weisskoff, Brigitte P Poncelet, David N Kennedy, Bernice E Hoppel, Mark S Cohen, and Robert Turner. Dynamic magnetic resonance imaging of human brain activity during primary sensory stimulation. *Proceedings of the National Academy of Sciences*, Vol. 89, No. 12, pp. 5675–5679, 1992.
- 3) Eiju Watanabe, Yuichi Yamashita, Atsushi Maki, Yoshitoshi Ito, and Hideaki Koizumi. Non-invasive functional mapping with multi-channel near infra-red spectroscopic topography in humans. *Neuroscience letters*, Vol. 205, No. 1, pp. 41–44, 1996.
- 4) 平野大輔, 谷口敬道, 武田湖太郎. 機能的近赤外分光法 (fnirs) による重症心身障害児・者の評価. 脈管学: 日本脈管学会機関誌: the journal of Japanese College of Angiology, Vol. 51, No. 2, pp. 241–246, 2011.
- 5) Koji Matsuo, Tadafumi Kato, Masato Fukuda, and Nobumasa Kato. Alteration of hemoglobin oxygenation in the frontal region in elderly depressed patients as measured by near-infrared spectroscopy. *The Journal of neuropsychiatry and clinical neurosciences*, Vol. 12, No. 4, pp. 465–471, 2000.
- 6) K MATSUO, N Kato, and T Kato. Decreased cerebral haemodynamic response to cognitive and physiological tasks in mood disorders as shown by near-infrared spectroscopy. *Psychological medicine*, Vol. 32, No. 06, pp. 1029–1037, 2002.
- 7) William D Penny, Karl J Friston, John T Ashburner, Stefan J Kiebel, and Thomas E Nichols. *Statistical Parametric Mapping: The Analysis of Functional Brain Images: The Analysis of Functional Brain Images*. Academic Press, 2011.
- 8) Karl J Friston, CD Frith, PF Liddle, and RSJ Frackowiak. Comparing functional (pet) images: the assessment of significant change. *Journal of Cerebral Blood Flow & Metabolism*, Vol. 11, No. 4, pp. 690–699, 1991.
- 9) Yoko Hoshi. Functional near-infrared spectroscopy: Limitations and potential. *THE JOURNAL of JAPANESE COLLEGE of ANGIOLOGY*, Vol. 45, No. 2, pp. 61–67, 2005.

- 10) Marco Ferrari and Valentina Quaresima. A brief review on the history of human functional near-infrared spectroscopy (fnirs) development and fields of application. *Neuroimage*, Vol. 63, No. 2, pp. 921–935, 2012.
- 11) Vladimir Naumovich Vapnik and Vladimir Vapnik. *Statistical learning theory*, Vol. 2. Wiley New York, 1998.
- 12) Hiroaki Sakoe and Seibi Chiba. Dynamic programming algorithm optimization for spoken word recognition. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, Vol. 26, No. 1, pp. 43–49, 1978.
- 13) Nello Cristianini and John Shawe-Taylor. *An introduction to support vector machines and other kernel-based learning methods*. Cambridge university press, 2000.
- 14) Lawrence Davis, et al. *Handbook of genetic algorithms*, Vol. 115. Van Nostrand Reinhold New York, 1991.
- 15) Yoshihiko Hamamoto, Mari Furusato, Chiyo Kaneyama, and Shingo Tomita. A feature selection method using genetic algorithms. *IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences*, Vol. 78, No. 10, pp. 1385–1389, 1995.
- 16) Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
- 17) C.K. Chow. An optimum character recognition system using decision functions. *Electronic Computers, IRE Transactions on*, Vol. EC-6, No. 4, pp. 247–254, Dec 1957.
- 18) 人工知能学会. サポートベクターマシン. 知の科学. オーム社, 2007.
- 19) Takehiro Minamoto, Mariko Osaka, and Naoyuki Osaka. Individual differences in working memory capacity and distractor processing: Possible contribution of top-down inhibitory control. *Brain Research*, Vol. 1335, pp. 63–73, 2010.

## 付 図

1	SVM . . . . .	2
2	Waveform of time series of cerebral blood flow obtained through fNIRS . . . . .	2
3	Arrangement of fNIRS device (left) and each probe and channel (right) . . . . .	2
4	Experimental flow with fNIRS data . . . . .	3
5	RST score of each test subject . . . . .	3
6	Feature selection results 1 . . . . .	3
7	Feature selection results 2 . . . . .	4
8	Net work(High score) . . . . .	4
9	Net work(Low score) . . . . .	5

## 付 表

1	Preparation of fNIRS time series data . . . . .	1
2	Preparation of fNIRS time series data . . . . .	1
3	SVM Parameters . . . . .	1
4	GA Parameters . . . . .	1
5	Accuracy of left temporal region . . . . .	6
6	Accuracy of forehead . . . . .	6
7	Accuracy of right temporal region . . . . .	6
8	Extracted Channels and Accuracy . . . . .	7

Table 1 Preparation of fNIRS time series data

Preparation	Value
Moving Average[s]	10
High Pass Filter[Hz]	0.001
Low Pass Filter[Hz]	0.5

Table 2 Preparation of fNIRS time series data

Moving Average[s]	10
High Pass Filter[Hz]	0.001
Low Pass Filter[Hz]	0.5

Table 3 SVM Parameters

SVM parameter	Value
Cost parameter	1
Kernel	Polynomial kernel
Dimension	3

Table 4 GA Parameters

Parameter	Value
Population number	1000
Generation number	50
Crossover rate	0.7
Mutation rate	0.3
Gene number	70
Crossover method	2 point crossover
Selection method	Tournament selection (tournament number:7)

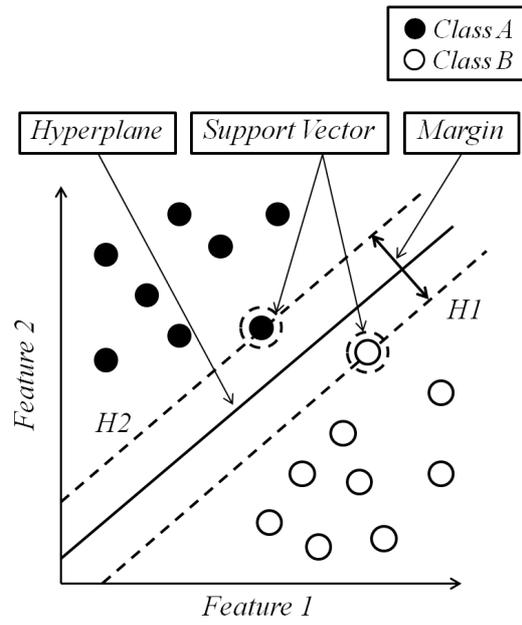


Fig. 1 SVM

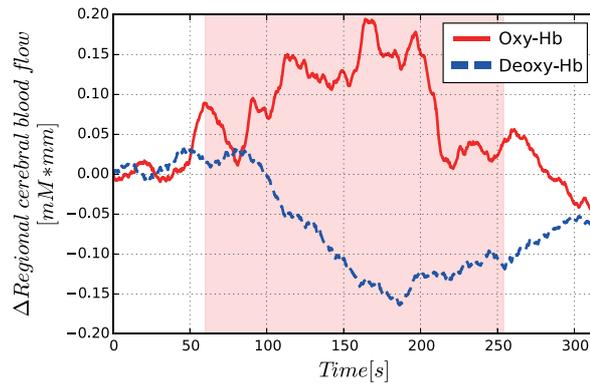


Fig. 2 Waveform of time series of cerebral blood flow obtained through fNIRS

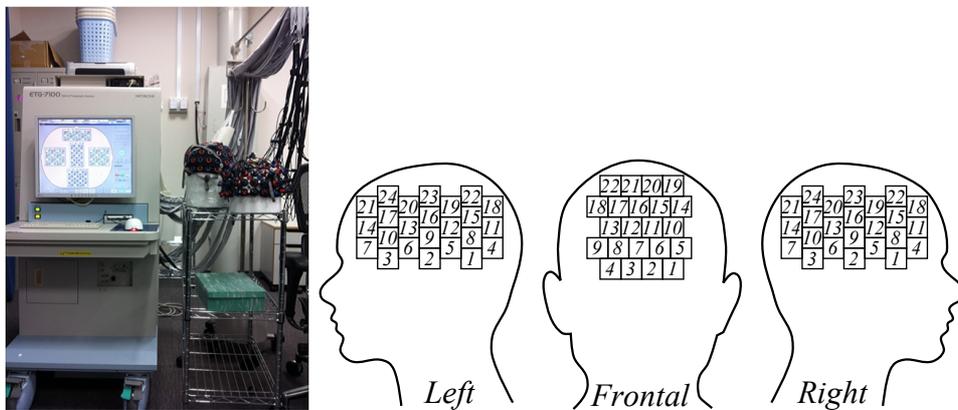


Fig. 3 Arrangement of fNIRS device (left) and each probe and channel (right)

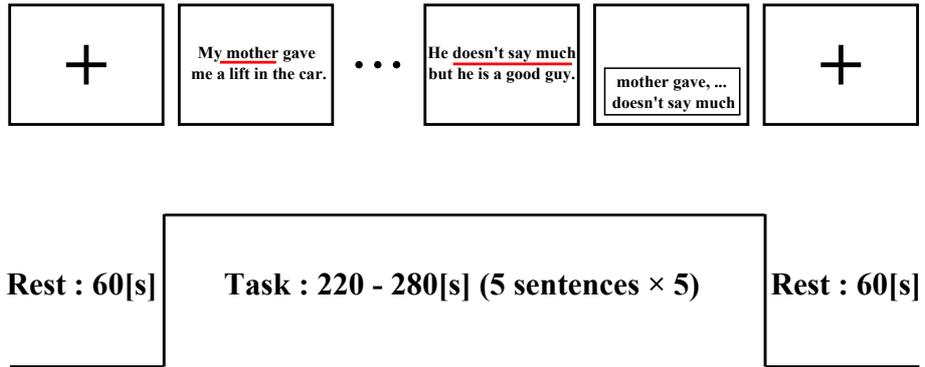


Fig. 4 Experimental flow with fNIRS data

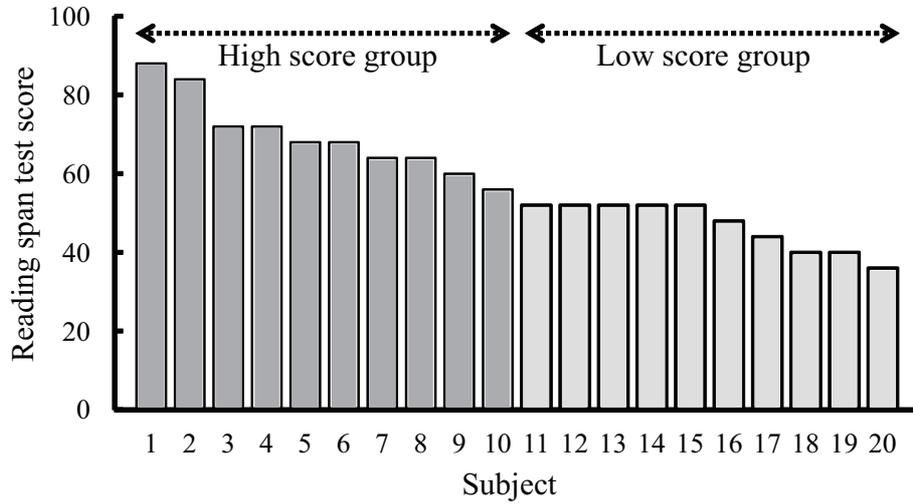


Fig. 5 RST score of each test subject

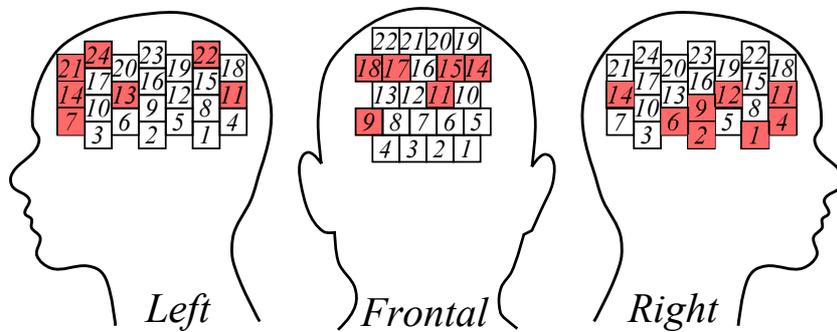


Fig. 6 Feature selection results 1

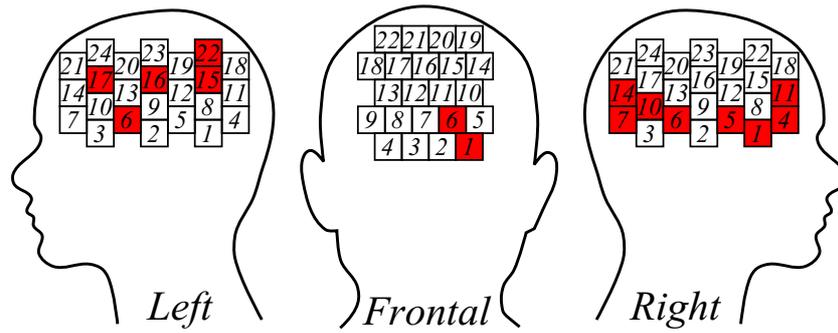


Fig. 7 Feature selection results 2

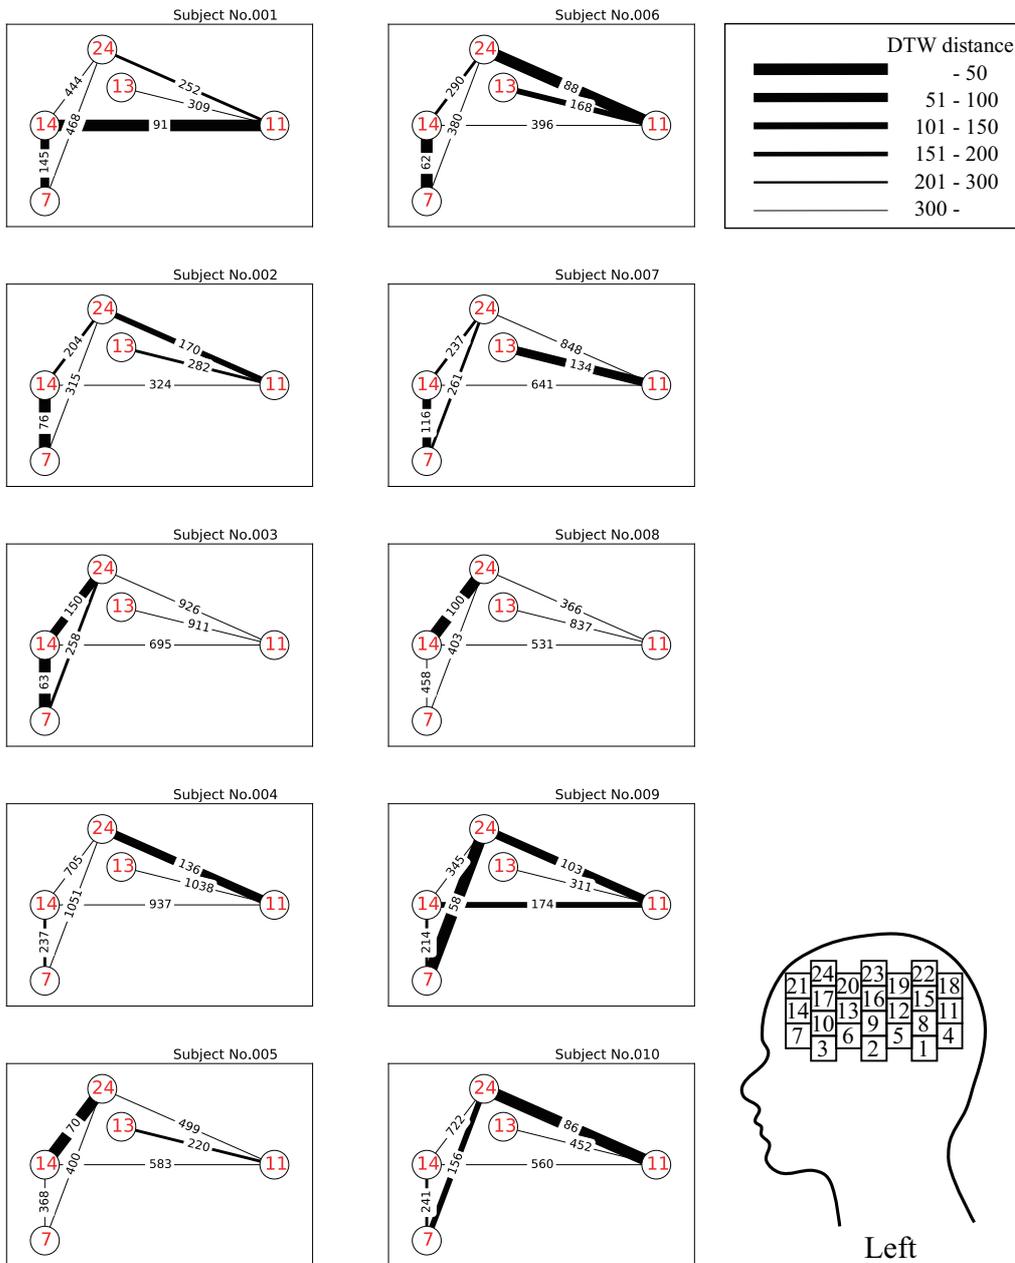


Fig. 8 Net work(High score)

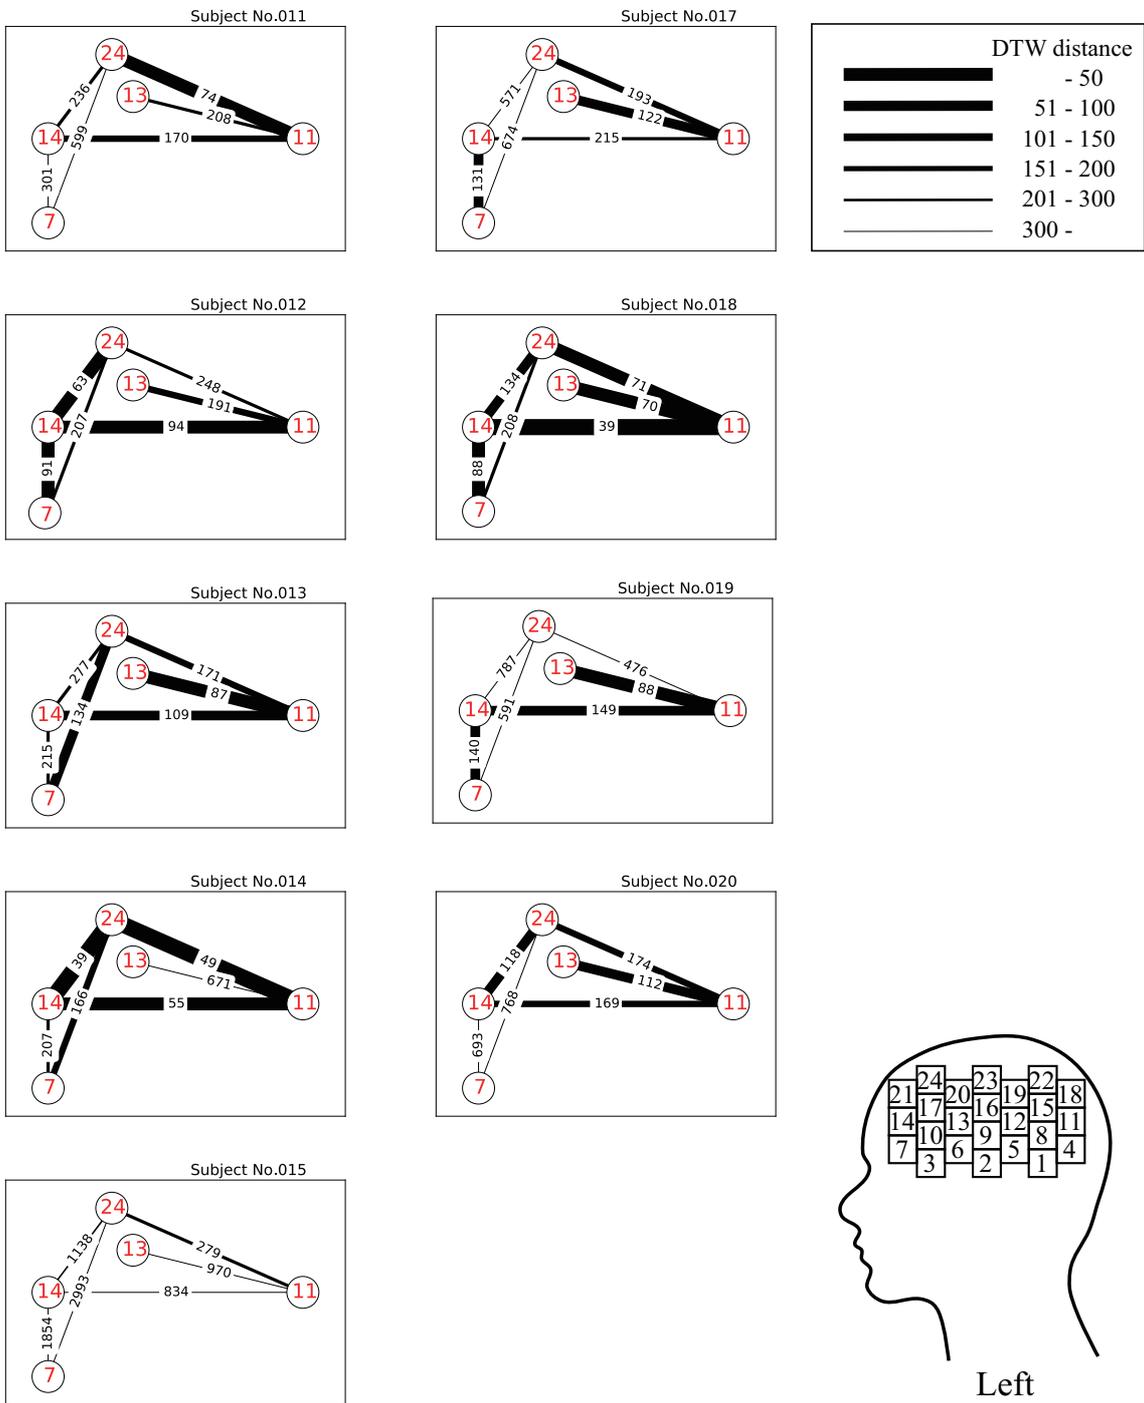


Fig. 9 Net work(Low score)

Table 5 Accuracy of left temporal region

channel	Accuracy[%]
7, 11, 13, 14, 21, 22, 24	89.47
11, 13, 14, 21, 22, 24	73.68
7, 13, 14, 21, 22, 24	52.63
7, 11, 14, 21, 22, 24	63.16
7, 11, 13, 21, 22, 24	68.42
7, 11, 13, 14, 22, 24	89.47
7, 11, 13, 14, 21, 24	84.21
7, 11, 13, 14, 21, 22	89.47

Table 6 Accuracy of forehead

channel	Accuracy[%]
9, 11, 14, 15, 17, 18	97.73
11, 14, 15, 17, 18	68.42
9, 14, 15, 17, 18	89.47
9, 11, 15, 17, 18	84.21
9, 11, 14, 17, 18	78.95
9, 11, 14, 15, 18	84.21
9, 11, 14, 15, 17	57.89

Table 7 Accuracy of right temporal region

channel	Accuracy[%]
1, 2, 4, 6, 9, 11, 12, 14	84.21
2, 4, 6, 9, 11, 12, 14	68.42
1, 4, 6, 9, 11, 12, 14	57.89
1, 2, 6, 9, 11, 12, 14	57.89
1, 2, 4, 9, 11, 12, 14	63.16
1, 2, 4, 6, 11, 12, 14	78.95
1, 2, 4, 6, 9, 12, 14	68.42
1, 2, 4, 6, 9, 11, 14	73.68
1, 2, 4, 6, 9, 11, 12	57.89

Table 8 Extracted Channels and Accuracy

Extracted channel	Accuracy [%]
base line	89.47
Right: 1	73.68
Right: 4	84.21
Right: 5	68.42
Right: 6	73.68
Right: 7	84.21
Right: 10	84.21
Right: 11	78.95
Right: 14	84.21
Left: 6	78.95
Left: 15	73.68
Left: 16	84.21
Left: 17	84.21
Left: 22	84.21
Front: 1	78.95
Front: 6	84.21