

偏KL情報量に基づくクラス選択法の提案と EMG 識別のための動作選定問題への応用

芝 軒 太 郎*・島 圭 介**・高 木 健*・栗 田 雄 一*
大 塚 彰***・陳 隆 明****・辻 敏 夫*

A Novel Class Selection Method Based on a Partial Kullback-Leibler Information Measure and Its
Application to Motion Classification Problem for EMG Signal Discrimination

Taro SHIBANOKI*, Keisuke SHIMA**, Takeshi TAKAKI*, Yuichi KURITA*,
Akira OTSUKA***, Takaaki CHIN**** and Toshio TSUJI*

When a user has no experience of controlling devices using bioelectric signals, for instance controlling a prosthetic hand using EMG signals, it is well known that voluntary generation of such signals might be difficult, so that the classification issue of multiple motions thus becomes problematic as the number of motions increases. This paper proposes a novel class selection method based on the Kullback-Leibler (KL) information measure and outlines its application to optimal motion selection for accurate bioelectric signal classification. In the proposed method, the probability density functions (pdfs) of recorded data are estimated through a multidimensional probabilistic neural network (PNN) trained based on the KL information theory. A partial KL information measure is then defined to evaluate the contribution of each class for classification. Effective classes can be selected by eliminating ineffective ones based on the partial KL information one by one. In the experiments performed, the proposed method was applied to motion selection with four subjects (including an amputee), and effective classes were selected from all motions measured in advance. The average classification rate for selected motions under the proposed method was $93.03 \pm 1.25\%$. These outcomes indicate that the proposed method can be used to select appropriate motions for accurate classification.

Key Words: Kullback-Leibler (KL) information, class selection method, motion selection, pattern classification, electromyogram (EMG)

1. はじめに

肢体不自由者の失われた機能を補うためのヒューマン・マシン・インタフェース (Human Machine Interface: HMI) に

関する研究は古くから数多く行なわれており、筋電位 (Electromyogram: EMG) や脳波 (Electroencephalogram: EEG) などの生体信号を用いるものが注目を集めている^{1)~3)}。

生体信号をインタフェースとして使用するためには、被験者が随意的に発生させた生体信号のパターンと、被験者の意図する動作の対応関係をモデル化・識別する必要がある。生体信号のパターンから被験者の動作を識別する方法には、AR モデルやニューラルネット (Neural Network: NN) が広く用いられている^{4)~6)}。特に Tsuji らは混合正規分布モデルを内包した Log-Linearized Gaussian Mixture Network (LLGMN) を提案し^{7),8)}、生体信号識別への有効性を確認している^{7)~14)}。

生体信号のパターン識別においては、各被験者に適切な信号計測位置を決定するとともに¹⁵⁾、識別可能な動作 (動作に伴って発生する生体信号パターン) を選定する必要がある。たとえば筋電義手として広く普及している MYOBOCK¹⁶⁾ のユーザーは、義手の開閉動作に対応した2種類の EMG パターン (たとえば、伸筋と屈筋の収縮時のパターン) を随意的に発生することで義手を制御している。このとき、筋電義手

* 広島大学大学院工学研究院 東広島市鏡山 1-4-1

** 広島大学大学院医歯薬保健学研究院 広島市南区霞 1-2-3

*** 県立広島大学保健福祉学部 三原市学園町 1-1

**** 兵庫県立リハビリテーション中央病院
神戸市西区曙町 1070

* Graduate School of Engineering, Hiroshima University,
1-4-1 Kagamiyama, Higashihiroshima

** Graduate School of Biomedical & Health Sciences,
Hiroshima University, 1-2-3 Kasumi, Minami-ku,
Hiroshima

*** Faculty of Health and Welfare, Prefectural University
of Hiroshima, 1-1 Gakuencho, Mihara

**** Hyogo Rehabilitation Center, 1070 Akebonocho, Nishi-
ku, Kobe

(Received December 19, 2011)

(Revised May 30, 2012)

の処方の際にまず被験者ごとに適した電極位置と随意的に発生可能な EMG パターンを作業療法士が経験的に決定しなければならない¹⁷⁾。切断者はそれぞれの切断部位や状態、手術などによって筋の位置が異なるため、筋電義手処方に際しては作業療法士が触診および電極を貼付しながら試行錯誤的に適切な位置を決定し、随意的に分離可能な動作イメージを選定している¹⁷⁾。しかしながら、熟練した作業療法士においても被験者ごとに適切な電極位置や動作を選定することは困難であり、処方に長期間を要する場合がある。このとき、随意的に分離可能な切断者の動作イメージが実際の義手の動作と一致すれば幻肢感覚が利用でき理想的であるが、実際の筋電義手処方では患者の状態によって必ずしもこの一致が実現できるとは限らず、たとえば指の開閉動作に手首の伸展・屈曲動作を割り当てる¹⁷⁾など、実際の義手の動作とは異なる動作イメージを制御に用いざるを得ないという状況が生じる場合がある。もちろん、切断者が高い精度で分離可能な動作数が多ければ多いほど、制御可能な多自由度義手の動作数を増加することができる。したがって、それぞれの切断者に対して適切な電極位置を決定し、高い識別率で随意的に制御可能な動作イメージをできるだけ多く選定するための方法論が必要である。

従来、生体信号の計測位置と識別に適した動作（識別対象のクラス）の選定に関する試みがさまざま検討されている^{15), 18)~23)}。生体信号の計測位置の選択法には、被験者が実施した動作ごとに信号の振幅が大きくなる位置を選択する方法^{18), 19)}やあらかじめ貼付したセンサからいくつかのセンサをランダムに選択し、パターン識別を繰り返すことで適切なセンサ位置を特定する試み^{15), 20), 21)}がある。また、生体信号のパターン識別が困難な場合において Kita らは、精度良い識別を実現するためにあらかじめいくつかの動作に対応する EMG と角度情報を計測し、計測したデータからベクトル量子化に基づく自己組織化クラスタリングを行なうことで、他の動作と重複しないクラスを抽出する方法を提案している²³⁾。ただし、被験者ごとに適した電極位置を発見するためにはできるだけ多くの電極を評価に用いる必要があり、センサ数の増加に伴い選択するセンサの組み合わせが膨大になってしまう場合がある。また、選定した電極や動作を用いてパターン識別を行なう際には識別器を新たに構築しなければならないため、選定後の電極や動作を用いても、識別器によって精度良くパターン識別が行なえる保証はない。さらに、これらは適切な電極または動作の選択法のための議論であり、被験者に適切な電極位置と動作を同時に選定する方法論については検討されていなかった。

そこで著者らの研究グループでは、各入力次元が識別に与える影響度を測る指標として偏 KL 情報量を定義し、筋電位計測のための電極選定法を提案した²²⁾。提案法は、偏 KL 情報量に基づいて識別に有効でない電極を逐次削除することで、すべての組み合わせを評価することなく識別に有効な電極のみを選択できる。この方法では電極の逐次削減による局所最

適性の問題は有しているものの、これまでの実験からあらかじめ貼付した電極が取りうる全組み合わせのうち最適あるいは準最適な電極対を選定できることを確認している²²⁾。また、偏 KL 情報量は KL 情報量に基づく確率ニューラルネットの学習によって算出できるため、電極の選定と同時に識別器の構築を可能としている。しかしながら、動作の選定方法については議論していなかった。

本論文では、偏 KL 情報量を動作選定問題に適用し、被験者が高い識別率で随意的に制御可能な動作を選定する方法を提案する。この方法は、まず入力データの確率密度関数を KL 情報量に基づく確率ニューラルネットの学習により推定する。そして各クラスが識別精度に与える影響度を表わす指標としてクラス偏 KL 情報量を新たに定義し、識別精度に最も悪影響を与えているクラスを逐次削除することで識別可能クラスのみを選択する。これにより、クラスの選択と同時に識別器の構築を行なうことができ、また偏 KL 情報量という統一的な評価尺度に基づいて電極選定と動作選定の問題それぞれを解決できる可能性がある。

以下、2章では偏 KL 情報量に基づくクラス選択法について述べ、3章で提案法を用いた動作選定法を説明する。そして、4章シミュレーション実験、5章筋電位を用いた動作識別実験により、提案法の有効性を示す。

2. 偏 KL 情報量に基づくクラス選択法

計測した生体信号から識別可能な動作を選定するためには、計測信号が従う確率分布を推定し、識別困難な動作（クラス）を特定して除去する必要がある。ここでは、新たに提案する偏 KL 情報量に基づくクラス選択法について述べる。

2.1 クラス偏 KL 情報量

非線形構造を有するデータの識別問題において、各サンプルはある確率分布に従う確率変数ととらえることができる。そのため、データが従う確率分布を正確に推定できれば、精度良い識別が可能である。このとき、あらかじめ与えられたサンプルを用いて推定した分布の推定精度は KL 情報量を用いて評価できる。KL 情報量は2つのデータ分布間の差異を表わすため²⁴⁾、推定した分布と真の分布が近ければ近いほど 0 に近い値をとる。識別対象クラスが多い場合には識別が困難になる可能性があるため、以下に KL 情報量を元にしたクラス選択のための偏 KL 情報量について述べる。

まず、 K 個のクラスにそれぞれ N_k 個のサンプルがあり、各サンプルは L 次元変数ベクトルであるとする ($\mathbf{x} = [x_1, x_2, \dots, x_L]^T \in \mathbb{R}^L$)。 $\mathbf{x}_n^{(k)} \in \mathbb{R}^L$ をクラス k の n サンプル目の確率変数ベクトルとし、 $\mathbf{x}_n^{(k)}$ が真の分布および推定した分布においてクラス k に属する確率をそれぞれ P_n^k および Q_n^k とする。このとき、KL 情報量は次式を用いて算出できる。

$$I_n(P, Q) = \sum_{k=1}^K P_n^k \log \frac{P_n^k}{Q_n^k}$$

$$= \sum_{k=1}^K P_n^k \log P_n^k - \sum_{k=1}^K P_n^k \log Q_n^k \quad (1)$$

ここで $P = [P_n^1, P_n^2, \dots, P_n^K]^T$, $Q = [Q_n^1, Q_n^2, \dots, Q_n^K]^T$ である。(1)式において右辺第1項は定数となり、第2項が最小となるときのKL情報量が最小値をとる。これは推定した分布が真の分布に近いことを意味し、推定した分布が真の分布に一致すればKL情報量は0となる。

本論文では各クラスが識別可能かを評価するための指標として、偏KL情報量をクラス除去前後のKL情報量の比で新たに定義する。具体的には、KL情報量 $I_n(P, Q)$ と、あるクラス i' を除いて算出したKL情報量 $I_{n'}(P'_{[i']}, Q'_{[i']})$ を用いて次式で算出する。

$$G_{[i']} = \frac{I(P'_{[i']}, Q'_{[i']})}{I(P, Q)} = \frac{N \sum_{n'=1}^{N'} I_{n'}(P'_{[i']}, Q'_{[i']})}{N' \sum_{n=1}^N I_n(P, Q)} \quad (2)$$

$P'_{[i']} = [P_n^1, \dots, P_n^{i'-1}, P_n^{i'+1}, \dots, P_n^K]^T$, $Q'_{[i']} = [Q_n^1, \dots, Q_n^{i'-1}, Q_n^{i'+1}, \dots, Q_n^K]^T$ であり、 N は全サンプル数、 N' はあるクラス i' を除いた場合の全サンプル数を表わす。本論文では、文献22)の電極選定のための偏KL情報量と区別するため、(2)式の $G_{[i']}$ をクラス偏KL情報量と呼ぶ。分布の推定精度が高いほどKL情報量は小さい値をとるため、識別困難なクラスを除くことで識別精度は向上すればクラス偏KL情報量 $G_{[i']}$ は0に近づく。そのため、 $G_{[i]}$ が最小のクラス i' から順に1クラスずつ削除することができる。なお、 $I_{n'}(P'_{[i']}, Q'_{[i']}) = 0$ の場合は、識別対象のクラスすべての分布を正しく推定できることを意味するため、 $G_{[i]} = 0$ とし、以降のクラスの削減は行なわない。

2.2 NNを用いたクラス選択法

本論文では、KL情報量の最小化に基づく確率NNの学習により、あらかじめ与えられたサンプルデータ x^* が従う確率密度関数を推定する。そして、サンプルデータの i' クラスを除いたデータ $x^*_{[i']}$ を用いて同様にNNの学習を行なうことで、学習と同時にクラス偏KL情報量を算出してクラスの選択を行なう。なお、クラスの選択は、Cross-Validation法²⁵⁾に基づき以下の手順で行なう。

- (I) ベクトル集合 $x^* \in \mathbb{R}^L$ ($|x^*| = N$) を要素数がほぼ等しい M 個の部分集合に分割し、 m 番目の部分集合を y_m^* 、それ以外を \bar{y}_m^* とする ($m = 1, 2, \dots, M, |y_m^*| = S_m, |\bar{y}_m^*| = N - S_m, y_m^* \cup \bar{y}_m^* = x^*$)。 $m = 1$ として初期化し、 M -fold Cross-Validation²⁵⁾に基づき以下の処理を繰り返す。
- (II) 削除した動作数 $r_m = 0$ 、削除後の全動作数 $R_m = K$ とし、ベクトル集合 y_m^* 、 \bar{y}_m^* から i' 番目のクラスのデータを除いた $R_m - 1$ クラスのベクトル集合をそれぞれ、 $y'_{[i']m}, \bar{y}'_{[i']m} \in \mathbb{R}^L$ と定義する。
- (III) \bar{y}_m^* 、 $\bar{y}'_{[i']m}$ それぞれを用いて計算したKL情報量

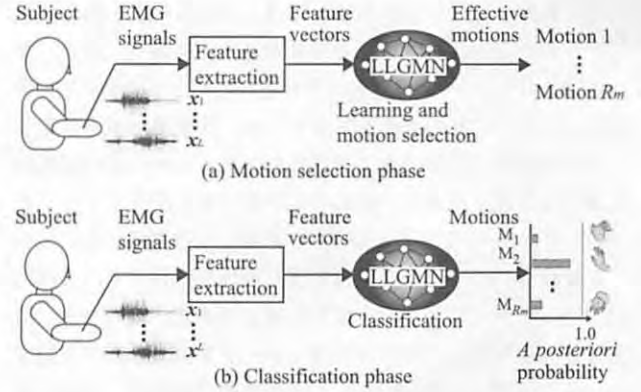


Fig. 1 Structure of the proposed motion selection method

$I(P, Q|\bar{y}_m^*)$ および $I(P'_{[i']}, Q'_{[i']}|\bar{y}'_{[i']m})$ からクラス偏KL情報量 $G_{[i']m}$ ((2)式)を算出する ($i' = 1, 2, \dots, R_m$)。また、 $x^*_{[i']} = \bar{y}'_{[i']m} \cup y^*_{[i']m} \in \mathbb{R}^L$ ($i' = 1, 2, \dots, R_m$) を識別した際の識別率をモデルの推定精度 $D_{[i']m}$ とする。

- (IV) 算出した各 $G_{[i']m}$ から、(2)式を最小にするクラス j (分布の推定が最も困難であると考えられるクラス、 $j = \operatorname{argmax}(G_{[i']m})$) を求める。
- (V) あらかじめ設定した限界値 D_θ と $D_{[j]m}$ を比較し、 $D_{[j]m} < D_\theta$ であれば j 番目のクラスのデータを入力ベクトルから削除する。そして、 $\bar{y}_m^* = \bar{y}'_{[j]m}, y_m^* = y^*_{[j]m}, r_m = r_m + 1, R_m = K - r_m$ (ただし、 $r_m \leq K - 1$) として (III) に戻る。一方、 $D_{[j]m} \geq D_\theta$ であれば、削除は行わずに (VI) へ移動する。
- (VI) $m < M$ の場合は $m = m + 1$ として (II) より繰り返す。 $m = M$ の場合は選定を終了し、 r_m が最小で $D_{[j]m}$ が最大のモデルのうち $I(P'_{[j]}, Q'_{[j]}|\bar{y}'_{[j]m})$ が最小となるものを最良のモデルとして決定する。

以上の手順に基づき、識別困難なクラスを削除していくことで、最終的に精度良い識別 (R_m クラス) を可能とする。

3. EMG 識別のための動作選定法

生体信号を用いて義手、車椅子、環境制御装置などの機器を随意的に制御するためには、精度良いパターン識別が必要である。ここで、識別対象動作が増加すると識別問題が複雑化し、識別精度が低下する可能性がある。精度良いパターン識別の実現には、各被験者に適切な動作(被験者が安定して生体信号を発生可能な動作)を選定する必要がある。しかしながら、これまでに提案されている動作の選定方法では²³⁾、動作選定後に識別器を新たに構築しなければならず、また、電極と動作を同時に選定することはできない。

ここでは、提案するクラス選択法をEMG識別における動作選定問題へ応用し、識別に適した動作のみを選択する方法について説明する。Fig. 1にその概要を示す。動作選定では、被験者の動作をTsujiらによって提案されたLog-Linearized

Gaussian Mixture Network (LLGMN)⁷⁾を用いて学習し、同時に識別に有効な動作のみを選択する。動作識別の際は選択された動作のみを識別対象とすることで、被験者が行なった動作を精度良く識別することができる。これにより、動作の選定と同時に識別器の構築が可能となり、また、クラス偏KL情報量に基づいて電極と動作の選定を統一に行なうことができる。

3.1 特徴抽出

まず、 L 対の双極表面電極を用いてEMGを計測する。計測したEMGはサンプリング周波数1kHzでA/D変換し、各チャンネルごとに全波整流、2次のデジタルバタワースフィルタ(カットオフ周波数1Hz)に通す。得られた n 番目のサンプルを $EMG_l(n)$ ($l=1, \dots, L$)とする。つぎに、チャンネルごとの筋電位の大きさの割合を評価するために各チャンネルの最大値で正規化した $e_l(n)$ を次式のように定義する。

$$e_l(n) = \frac{EMG_l(n) - \overline{EMG_l^{st}}}{EMG_l^{max} - \overline{EMG_l^{st}}} \quad (3)$$

ただし、 $\overline{EMG_l^{st}}$ は安静時に取得した $EMG_l(n)$ の平均値、 EMG_l^{max} は事前に計測した各チャンネルの最大随意筋収縮時の値を表す。その後、 $EMG_l(n)$ の全チャンネル和が1となるように正規化を行ない、動作推定に用いる特徴パターンベクトル $\mathbf{x}(n) = [x_1(n), x_2(n), \dots, x_L(n)]^T \in \mathbb{R}^L$ の各要素 $x_l(n)$ ($l=1, \dots, L$)を求める。

$$x_l(n) = \frac{e_l(n)}{\sum_{l'=1}^L (e_{l'}(n))} \quad (4)$$

また、動作発生判定に用いる筋力情報 $F_{EMG}(n)$ を以下の式で定義する。

$$F_{EMG}(n) = \frac{1}{L} \sum_{l=1}^L e_l(n) \quad (5)$$

3.2 学習・動作選定

算出した特徴ベクトルを入力とし、LLGMNで学習を行なう。LLGMNはTsujiらによって提案されたフィードフォワード型のNNであり、GMMを対数線形化してネットワーク構造に展開している。そのため、サンプルデータが従う統計分布をGMMに従って学習的に推定し、入力 $\mathbf{x}(n)$ の各クラスに対する事後確率 $\mathbf{Y}(n) = [Y_1(n), Y_2(n), \dots, Y_K(n)]^T$ を算出できる⁷⁾。これまでに、EMG信号やEEG信号をLLGMNを用いて識別し高い精度で動作識別可能なことが示されている⁷⁾⁻¹⁴⁾。LLGMNの高い学習能力により、個人差によるEMG信号の違いや電極のずれなどによるEMG信号の変化に対応可能である。

LLGMNの学習には誤差逆伝播に基づく最尤学習を用いている。いま、 n 番目の入力ベクトルに対して、教師信号ベクトル $\mathbf{T}(n) = [T_1(n), \dots, T_k(n), \dots, T_K(n)]^T$ が与えられた場合を考える。LLGMNでは N 個のサンプルデータ $\mathbf{x}(n)$




Fig. 2 Examples of artificial data for experiments

($n=1, \dots, N_{\text{learning}}; N_{\text{learning}} < N$)を用いて、対数尤度を最大化するように学習を行なう。LLGMNの評価関数は従来、対数尤度関数に基づいていたが⁷⁾、本論文では(1)式のKL情報量を新たに使用する。出力値 $Y_k(n)$ が事後確率 $P(k|\mathbf{x}(n))$ に対応することを考えると、評価関数 J には、

$$J(\mathbf{x}^*) = I(\mathbf{T}, \mathbf{Y}|\mathbf{x}^*) \\ = \frac{1}{N_{\text{learning}}} \sum_{n=1}^{N_{\text{learning}}} \sum_{k=1}^K T_k(n) \log \frac{T_k(n)}{Y_k(n)} \quad (6)$$

を用い、これを最小化するように学習を進める。(6)式を最小化するように学習を進めることで、LLGMNの学習によってKL情報量が最小化でき、学習後のネットワークはデータ分布を良く推定できることを意味する。そのため、LLGMNの評価関数を用いて学習と同時に識別可能なクラス(動作)を選択することができる。

動作選定では、計測したEMG信号から算出した特徴パターンベクトル $\mathbf{x}(n)$ ($n=1, \dots, N$)を初期ベクトル集合 \mathbf{x}^* として、2.2節で述べたクラス選択法に基づき、識別困難な動作を順に削除していく。モデルの推定精度 $D_{[i']m}$ は $\mathbf{y}_{[i']m}^*$ および $\overline{\mathbf{y}}_{[i']m}^*$ ($\mathbf{y}_{[i']m}^* \cup \overline{\mathbf{y}}_{[i']m}^* = \mathbf{x}_{[i']m}^*$)を識別した際の平均識別率とする。動作選定終了後、最終的に r_m は削除した動作数、 R_m は選定された動作数となる。

3.3 動作識別

EMG識別の際は、ネットワークの第3層の出力値が各クラスに対する事後確率であることから、最も確率が高くなるクラス k を識別結果とするベイズ識別を行なう。ここで、あいまいな識別結果による誤識別を防ぐために、LLGMNの出力に関するエントロピーを次式を用いて算出し、識別判定処理を行なう。

$$H(n) = - \sum_{k=1}^{R_m} Y_k(n) \log Y_k(n) \quad (7)$$

エントロピーは情報のあいまいさを表す評価値である。識別判定時には、あらかじめ設定した閾値 H_d と $H(n)$ を比較し、 $H(n) < H_d$ であれば出力 $Y_k(n)$ ($k=1, \dots, R_m$)が最大となるクラスに対応する動作を識別結果とし、 $H(n) \geq H_d$ であれば、あいまいな識別として識別を保留する。

Table 1 Parameters of the artificial data used in the simulation experiments

class	μ_{x_1}	μ_{x_2}	σ_{x_1}	σ_{x_2}	$\sigma_{x_1 x_2}$
C ₁	0.4	0.2	0.08	0.05	-0.8
C ₂	0.3	0.7	0.07	0.08	0
C ₃	0.7	0.7	0.05	0.06	0
C ₄	0.7	0.8	0.08	0.05	0
C ₅	0.8	0.8	0.04	0.04	0
C ₆	0.6	0.2	0.08	0.05	0.8
C ₇	0.1	0.2	0.01	0.06	-0.1
C ₈	0.5	0.4	0.04	0.01	0

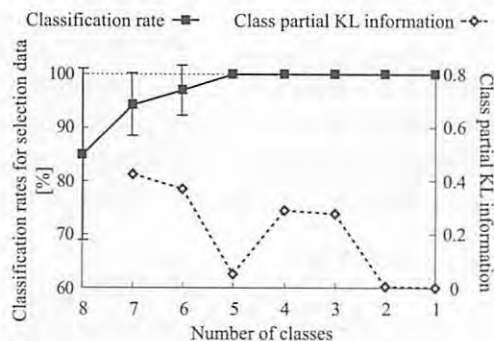


Fig. 3 Relationships between average classification rates for selection data, class partial KL information and number of classes in the simulation experiments. Classes are eliminated one-by-one using the proposed method

4. シミュレーション実験

提案するクラス選択法の有効性を検証するために、人工データを用いたクラス選択を行なった。

4.1 実験条件

Fig. 2 に実験で用いた人工データを示す。提案法を用いて識別可能なクラスを選定可能かを評価するために、人工データは分布の重なりあう多クラスのデータを想定して生成した。データは 2 次元空間上に分布する 8 つのクラスから構成され、各クラスのデータは正規分布に従う。Table 1 に各クラスのパラメータを示す。このような分布から生成されたデータを 2.2 節で述べたクラス選定の初期集合として用い、クラスの選択を行なった。クラス選定のデータ x^* は、各クラス 100 サンプルを LLGMN の学習用 (\bar{y}_m^*)、各クラス 20 サンプルをテスト用 (y_m^*) に用いて実験を行なった。提案法におけるクラス選択の終了条件は $D_\theta = 100$ とした。

4.2 結果と考察

Fig. 2 に示すように、作成した人工データは各クラスのデータ間 (たとえば C₁ と C₆) の重なりが大きく、通常は高精度な識別が困難である。ここで、全データから重なりあうクラスを検出し、そのいずれかを削除することで各クラスのデータは分離可能となる。提案法により、識別困難なクラスを特定し除去することができれば、精度良いパターン識別を実現できる。

Fig. 3 に提案法を用いて識別対象クラスを順に削除した場合のクラス偏 KL 情報量と全識別対象クラスに対する識別率




Fig. 4 Classes selected using the proposed method

Table 2 The number of selected classes and the average classification rates for evaluation data in the simulation experiments. Data consist of Gaussian random number of eight classes

	All classes	Proposed method
Number of classes	8	5
Classification rate for evaluation data [%]	86.9	99.8

の変化を示す。横軸はクラス選択により、8 クラスから一つずつ削減した際のクラス数である。なお、図中の破線はクラス選定終了のしきい値 ($D_\theta = 100$) を表わしている。図より、提案法を用いて識別困難なクラスを逐次削除することで識別率が向上し、ばらつきも小さくなっていることがわかる。また、識別対象クラスを 6 クラスから 5 クラスに削減した場合において、選定用データの識別率が 100% となった。このとき、KL 情報量が 0 に近くなるためクラス偏 KL 情報量が大幅に減少していることが確認できる。全識別対象クラス (5 クラス) を精度良く識別できることから、提案法を用いて 5 つのクラスが適切な識別対象クラスとして選択された。Fig. 4 (a) に選択したクラスのデータをプロットしたものを示す。図より、提案するクラス選択法によって重なりあうクラス (C₁, C₃, C₄) が除去されており、各識別対象クラスを精度良く識別できることがわかる。

つぎに、提案法を用いて選択したクラスのデータを精度良く識別可能かを確認するために識別実験を行なった。識別に用いたデータは未学習の検証用データ各クラス 180 サンプルとした。Table 2 は提案法を用いて選択したクラス数およびクラス選択前後の識別率である。表より、全クラスを識別対象とした場合と比較して、クラス選択後の識別率が向上し、高い精度で識別が行なえていることがわかる。以上の結果より、提案法を用いて識別困難なクラスを削除することで識別に適した多くの識別対象クラスを選択でき、精度良い識別が可能であることを明らかにした。提案法はこのようにクラス間の重なりが大きく境界があいまいなデータに対して、識別可能なクラスのみを選定することができる。

5. EMG 識別実験

5.1 実験条件

被験者は健常男子大学生 3 名 (A-C) および上肢切断者 1




Fig. 5 Overview of the sheet electrode



Fig. 6 Forearm motions for classification

名 (D: 49歳男性) とした。なお、被験者 B-D は EMG を用いた機器の操作に熟練している。実験では、マルチテレメータ (NEC 三栄 MT-11, ヘッドアンプ MT-32, ゲイン: 60 db) を用いて EMG 信号の計測を行なった。被験者 A-C はユニークメディカル社製硬膜下電極をもとに作成したシート型電極 (Fig. 5 参照) を右前腕に 2 対貼付しこれを計測に用いた。なお、ヘッドアンプには最大 26 極 (13 対) の EMG 電極を接続可能であるため、シート電極上に配置されている 64 極の電極からあらかじめ 13 対の電極を手動で選択した ($L = 13$)。被験者 D は切断部に 2 対 ($L = 2$) の電極 (GE Marquette 製 SEB 120) を貼付して信号を計測した。

本実験では多自由度前腕義手を想定して、被験者 A-C には Fig. 6 に示す手首および指に関連する 16 動作 (開き, 握り, 掌屈, 背屈, 尺屈, 撓屈, 各指の屈曲および伸展動作, $K = 16$) を各 5 秒間ずつ順に行なうよう指示した。これを 1 試行として 15 試行分のデータを計測した。被験者 D は切断者のためイメージが容易な任意の 11 動作を行なわせた。EMG 信号計測のサンプリング周波数は 1 kHz とし、各動作 1 秒間のほぼ定常状態のデータ (1000 サンプル) を電極選定²²⁾と動作選定, および精度検証用のデータとして用いた。また, 15 試行のデータのうち 6 試行のデータを選定用データとし, その他の試行を精度検証用データとした (各動作 1000 サンプル)。選定用のデータは 6000 サンプルからランダムに 120 サンプルを抽出しこれを用いた ($N_k = 120$)。




Fig. 7 An example of measured EMG signals using a pair of sheet electrodes in the motion selection experiment (subject A). The subject performed each of the 16 motions for five seconds

実験では、識別器の純粋な識別能力を測るために識別判定しきい値 $H_d = 1.0$ とし、識別保留は行なわないこととした。

5.2 結果と考察

Fig. 7 は被験者 A から計測した信号の一例を示している。図は上から各チャンネルの EMG 信号, 筋力情報を表わしており, 筋力情報があらかじめ設定したしきい値 $F_{EMG}^{th} = 0.15$ を超えている部分を白抜きで表示している。実験では, まず電極選定法²²⁾に基づいて動作識別に適した電極を選択した。このとき, 全電極を用いた場合の識別率を D とし, ある電極 i を除去した場合の識別率 $D_{[i]}$ が $D < D_{[i]}$ となる直前まで電極の削減を行なった。Table 3 は全被験者において選択された電極および電極選択前後の選定用データの識別率を示している。結果より, 被験者 A-C において電極選択前後で識別率がわずかに向上していることがわかる。これは電極選定法により, 冗長な電極 (識別に影響を与えない次元) が削減されたためだと考えられる。また, 切断者である被験者 D においては, あらかじめ貼付した電極が 2 対と少ないためすべての電極 (2 対) が選択された。

Fig. 8 に提案法を用いて動作を削除した際の識別率の一例を示す ($m = 4$)。図の横軸は全 16 動作から提案法を用いて

Table 3 Channel combinations selected using the channel selection method ²²⁾ and the average classification rates for selection data using all channels and the selected channels

	Sub. A	Sub. B	Sub. C	Sub. D
Selected channels	2, 3, 5, 9, 10	1, 2, 3, 4, 5, 6, 8, 9, 10, 11, 12, 13	2, 3, 5, 8, 9, 10, 13	1, 2
CR _A [%]	73.9	97.4	97.0	43.9
CR _S [%]	78.3	99.4	97.3	43.9

CR_A: Classification rate using all channels CR_S: Classification rate using selected channels

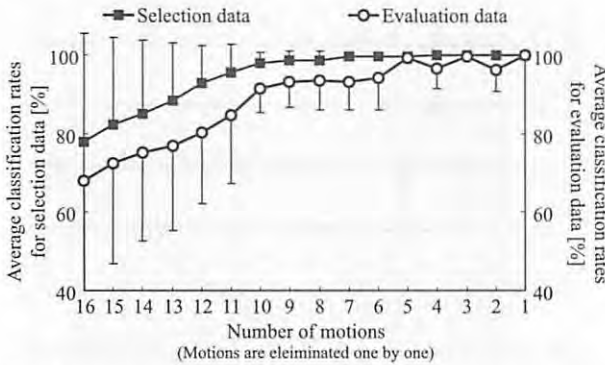


Fig. 8 Relationships between classification rates and the number of selected motions (subject A). Note that motions for classification are eliminated one-by-one using the proposed method

一つずつ削除した際の動作数である。図より、被験者 A は 11 動作から 10 動作に減少させた場合において識別率が向上し、ばらつきが小さくなっている。そこで、提案するクラス選択法の打ち切り条件を識別率 95% 以上、変動係数 0.05 以下と設定して動作の選定を行なった。Table 4 に全被験者において提案法により選定した動作と動作選定前後の選定用データの平均識別率を示す。表より、被験者 B, C は全動作が選定されている。これは、被験者 B, C が EMG を用いた機器操作に熟練しているため、多数の動作を識別対象とした場合においても識別率が高くなったと考えられる。上肢切断者である被験者 D においては 4 動作が選定された。2 対の電極を用いて、選定した 4 動作を 97.5% の精度で識別できていることから、適切な動作が選定できていることが示された。以上より、動作を選定することで識別率が向上し、提案法を用いた動作の削減が識別に適した動作の選定に有効であることを確認した。今後はさまざまな被験者を対象に実験を行ない、提案法の効果をより詳しく検討する予定である。

つぎに、提案法が未学習のデータ識別に有効であることを検証するために精度検証用データを用いて実験を行なった。Fig. 9 は全被験者について全動作を識別対象とした場合の識別率と提案法を用いて動作を選定した場合の識別率である。結果より、動作選定前後で識別率が向上していることがわかる (平均識別率 $93.03 \pm 1.25\%$)。異分散 *t* 検定による比較を行なったところ、被験者 A, D において有意水準 0.5% で有意差が得られたことから、提案法によって選定した動作を用いて、未学習データに対しても高い識別精度が得られることを確認

Table 4 Motions selected using the proposed method and average classification rates for selection data using all motions and the selected motions

	Sub. A	Sub. B	Sub. C	Sub. D
Number of channels	5	12	7	2
Selected motions	1, 3, 4, 5, 6, 9, 12, 13, 14, 15	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16	5, 6, 7, 10
CR _{AM} [%]	78.3	99.4	97.3	43.9
CR _{SM} [%]	98.4	99.4	97.3	97.5

CR_{AM}: Classification rate for all motions CR_{SM}: Classification rate for selected motions

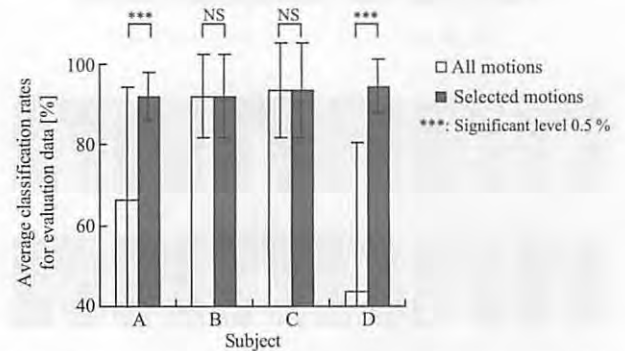


Fig. 9 Comparison of classification rates for evaluation data using all motions and the selected motions

した。

以上の結果より、提案する偏 KL 情報量に基づいて被験者に適した電極を選定できること、また識別困難な動作を逐次削除することで、適切な動作を選定できることを明らかにした。ただし、選定した動作によっては疲労などの影響により長時間の実行が困難な場合や、選定に成功した動作数以上の動作が必要となる場合がある。そこで、今後は筋電義手のためのトレーニングシステムと提案法を統合し、識別対象動作数の増加や被験者にとって実行が容易な動作の獲得が可能なシステムの開発を行ないたいと考えている。

6. おわりに

本論文では、識別に適したクラスを選択するために偏 KL 情報量に基づくクラス選択法を提案した。また、提案法の有効性を示すために人工データおよび筋電位を用いた識別実験を行なった。結果より、提案法を用いて精度よく識別可能な多くのクラスを選択できることを明らかにした。また EMG 識別実験の結果から、提案法を用いて電極と動作を選択することで識別率が向上し (平均識別率: $93.03 \pm 1.25\%$)、被験者の熟練度に応じて適切な電極と動作を選定できることを示した。

今後は被験者がイメージしやすい動作 (クラス) を選定できるアルゴリズムの構築を行なうとともに、被験者の筋電位制御能力に応じて電極と動作を交互に選定することで適切な電極・動作を同時に選定する方法を確立する。最終的には EMG を用いた機器操作のためのトレーニングシステムと統合することでより効果的に動作と電極を選択する方法を検討してい

く予定である。

謝辞 本論文の執筆にあたり、データ収集にご協力いただきました藤田和幸氏に深く感謝の意を示します。また、本研究の一部は日本学術振興会特別研究員奨励費(23-522)および文部科学省科学研究費補助金(22591634)の助成によるものであり、ここに改めて謝意を表します。

参考文献

- 1) L.A. Farwell and E. Donchin: Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials, *Electromyography and Clinical Neurophysiology*, **70-6**, 510/523 (1988)
- 2) M.F. Kelly, P.A. Parker and R.N. Scott: Neural network classification of myoelectric signal for prosthesis control, *Journal of Electromyography and Kinesiology*, **1-4**, 229/236 (1991)
- 3) L.M. Bergasa, M. Mazo, A. Gardel, M.A. Sotelo and J.C. Garcia: Guidance of a wheelchair for handicapped people by headmovements, *Proceedings of the International Conference on Field and Service Robotics*, 150/155 (1999)
- 4) D. Graupe, J. Salahi and D. Zhang: Stochastic analysis of myoelectric temporal signatures for multifunctional single-site activation of prostheses and orthoses, *Journal of Biomedical Engineering*, **7-1**, 18/29 (1985)
- 5) J. Cao and D.B. Sanders: Multivariate discriminant analysis of the electromyographic interference pattern: Statistical approach to discrimination among controls, myopathies and neuropathies, *Medical and Biological Engineering and Computing*, **34-5**, 369/374 (1996)
- 6) A. Subasi: EEG signal classification using wavelet feature extraction and a mixture of expert model, *Expert Systems with Applications*, **32-4**, 1084/1093 (2007)
- 7) T. Tsuji, O. Fukuda, H. Ichinobe and M. Kaneko: A log-linearized Gaussian mixture network and its application to EEG pattern classification, *IEEE Transactions on Systems, Man, and Cybernetics Part C*, **29-1**, 60/72 (1999)
- 8) T. Tsuji, N. Bu, M. Kaneko and O. Fukuda: A recurrent log-linearized Gaussian mixture network, *IEEE Transactions on Neural Networks*, **14-2**, 304/316 (2003)
- 9) T. Tsuji, O. Fukuda, M. Kaneko and K. Ito: Pattern classification of time-series EMG signals using neural networks, *International Journal of Adaptive Control and Signal Processing*, **14-8**, 829/848 (2000)
- 10) O. Fukuda, T. Tsuji, M. Kaneko and A. Otsuka: A human-assisting manipulator teleoperated by EMG signals and arm motions, *IEEE Transactions on Robotics and Automation*, **19-2**, 210/222 (2003)
- 11) K. Shima, M. Okamoto, N. Bu and T. Tsuji: Novel human interface for game control using voluntarily generated biological signals, *Journal of Robotics and Mechatronics*, **18-5**, 626/633 (2006)
- 12) M. Okamoto, K. Shima and T. Tsuji: Pattern discrimination method with a boosting approach using hierarchical neural trees, *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, **222-7**, 701/710 (2008)
- 13) N. Bu, M. Okamoto and T. Tsuji: A hybrid motion classification approach for EMG-based human-robot interfaces using Bayesian and neural networks, *IEEE Transactions on Robotics and Automation*, **25-3**, 502/511 (2009)
- 14) K. Shima, T. Tsuji, A. Kandori, M. Yokoe and S. Sakoda: Measurement and evaluation of finger tapping movements using log-linearized Gaussian mixture networks, *Sensors*, **9-3**, 2187/2201 (2009)
- 15) 永田, 安藤, 山田, 曲谷: チャネル選択にモンテカルロ法を用いた多チャンネル EMG による手の動作認識, *生体医工学*, **44-1**, 138/147 (2006)
- 16) Otto bock web page: <http://www.ottobock.com/>
- 17) 陳隆明編: 筋電義手訓練マニュアル, 全日本病院出版会 (2006)
- 18) 中谷, 西川, 吉田: 筋電義手処方支援システムの開発, *電子情報通信学会技術研究報告*, **105-655**, 25/28 (2006)
- 19) S.H. Walbran, E.P. Calius, G. Dunlop and I.A. Anderson: A technique for optimizing electrode placement for electromyographic control of prostheses., *Proceedings of the 31st IEEE/EMBS Annual International Conference*, 1331/1334 (2009)
- 20) X. Zhang, X. Chen, Z. Zhao, Y. Tu, J. Yang, V. Lantz and K. Wang: Research on gesture definition and electrode placement in pattern recognition of hand gesture action SEMG, **33/40** (2007)
- 21) A. Andrews, E. Morin and L. McLean: Optimal electrode configurations for finger movement classification using EMG, *Proceedings of the 31st IEEE/EMBS Annual International Conference*, 2987/2990 (2009)
- 22) 芝軒, 島, 辻, 高木, 大塚, 陳: 偏 KL 情報量に基づく変数選択法と生体電極選定への応用, *計測自動制御学会論文集*, **45-12**, 724/730 (2009)
- 23) K. Kita, R. Kato and H. Yokoi: Self-organized clustering approach for motion discrimination using EMG signal, *Proceedings of the 31st IEEE/EMBS Annual International Conference*, 5044/5047 (2009)
- 24) S. Kullback and R.A. Leibler: On information and sufficiency, *The Annals of Mathematical Statistics*, **22-1**, 79/86 (1951)
- 25) R. Kohavi: A study of cross-validation and bootstrap for accuracy estimation and model selection, **1137/1143** (1995)

[著者紹介]

芝軒 太郎



2008年徳島大学工学部知能情報工学科卒業。2010年広島大学大学院工学研究科博士課程前期修了。現在、同大学院博士課程後期在学中。日本学術振興会特別研究員(DC2)。生体信号解析、次元削減、マン・マシン・インタフェースなどの研究に従事。日本ロボット学会、IEEE 学生会員。

島 圭介(正会員)



2005年広島大学工学部第二類卒業。2007年同大学院工学研究科博士課程前期修了。2009年同博士課程後期修了。2007~2008年日本学術振興会特別研究員(DC1)。現在、同特別研究員(PD)。博士(工学)、生体信号解析、ニューラルネット、ヒューマンインタフェースなどの研究に従事。IEEE、機械学会などの会員。

高木 健 (正会員)



2006年東京工業大学大学院総合理工学研究科博士後期課程修了。博士(工学)。2006~2007年同大学研究員。2007年広島大学大学院工学研究科特任助教。2008年同大学助教。2011年同大学工学研究院准教授となり現在に至る。計測自動制御学会システムインテグレーション部門若手奨励賞(2007)、学術奨励賞(2009)、計測部門論文賞(2011)、日本ロボット学会論文賞(2005)、日本機械学会 ROBOMECH 表彰(2008, 2010)などを受賞。ロボットハンド、力可視化メカニズム、機構設計などの研究に従事。日本ロボット学会、日本機械学会、日本 IFToMM 会議、日本コンピュータ外科学会、IEEE の会員。

辻 敏夫 (正会員)



1985年広島大学大学院工学研究科博士課程前期修了。同大学工学部助手、助教を経て、2002年より同大学大学院工学研究科教授、現在に至る。工学博士。計測自動制御学会学術奨励賞(86)、論文賞(2002, 2008)、バイオメカニズム学会論文賞(90)、日本義肢装具学会論文賞(2000)、The K.S. Fu Memorial Best Transactions Paper Award of the IEEE Robotics in 2003、日本機械学会ロボティクス・メカトロニクス部門学術業績賞(2004)などを受賞。人間とロボットの運動制御、生体信号解析、ニューラルネット、ヒューマン・マシンシステムなどの研究に従事。IEEE、日本人間工学会、バイオメカニズム学会、日本機械学会、電気学会などの会員。

栗田 雄一 (正会員)



2004年奈良先端科学技術大学院大学情報科学研究科博士後期課程修了。博士(工学)。奈良先端科学技術大学院大学助教を経て、2011年より広島大学大学院工学研究院准教授。同年より科学技術振興機構さきがけ研究員を兼任。IEEE、日本ロボット学会、VR学会などの会員。

大塚 彰



1972年高知リハビリテーション学院卒業。2002年広島大学大学院工学研究科博士課程後期修了。博士(工学)。徳島大学医学部附属病院、愛媛大学医学部附属病院などを経て、95年広島県立保健福祉短期大学教授。2000年広島県立保健福祉大学教授。2005年県立広島大学保健福祉学部教授。現在に至る。日本義肢装具学会土屋和夫論文賞(2000)、日本義肢装具学会飯田賞本賞(2003)、医科器械学論文賞(2003)などを受賞。義手を含む福祉用具の開発研究に従事。日本義肢装具学会、日本リハビリテーション医学会、日本理学療法士協会などの会員。

陳 隆明



1986年徳島大学医学部卒業。神戸大学整形外科科学講座入局。87~91年神戸大学医学部大学院博士課程修了。神戸大学大学院医学博士。90~92年マックギル大学(カナダ)客員研究員。92年から兵庫県立総合リハビリテーションセンター整形外科医長兼リハビリテーション科医長を経て2006年より部長。2007年から神戸大学大学院客員准教授。国際義肢装具協会(International Society for Prosthetics and Orthotics)日本支部会長、国際義肢装具協会本部理事、フェロー、日本義肢装具学会副会長、日本義肢装具学会理事、日本義肢装具学会評議員、日本リハビリテーション学会評議員、日本脊髄障害医学会評議員、日本整形外科学会専門医、日本リハビリテーション学会専門医・指導責任者。2001年飯田賞奨励賞(日本義肢装具学会)、2006年飯田賞本賞(日本義肢装具学会)。