学術・技術論文

習熟度を考慮した自己組織的動作識別法の構築

北 佳 保 里[*1] 加 藤 龍[*2] 横 井 浩 史[*1*2]

EMG-to-Motion Classification for Prosthetic Applications — A Self-Organizing Approach with Level of Proficiency —

Kahori Kita[*1], Ryu Kato[*2] *and* Hiroshi Yokoi[*1*2]

The purpose of this research is to discriminate many motions using EMG signal for prosthetic application's control. The basic idea of this study is that, the current degree of proficiency, i.e., how well the application is operated by a user is to be analyzed from bio-signal closely related to human motor process, and control rule is generated depending on the proficiency level. Thus, our proposed system consists of two parts: estimation of user's proficiency level using EMG signal, and motion classification using self-organized clustering. In the experiment, users trained to discriminate motions using our proposed system, and then they all were able to discriminate seven forearm motions with approximately 90% accuracy. In addition, one of the users was able to discriminate nine motions with 21% higher accuracy than before training. The results indicated the effectiveness of proposed system.

Key Words: Prosthetic Applications, Myoelectric Hand, Pattern Recognition, Self-organized Clustering, Proficiency Level

1. は じ め に

現在，肢体不自由者の数は日本国内で約 180 万人にのぼり，その数は増加傾向にある．これに対して，筋電位から人の動作意図を読み取り，補助器の操作を行う能動的な補助方法が注目されており，機械学習を用いた様々な動作識別方法が提案されている．しかしながら，信号の非定常性から動作との関係が一意には定まらない，時間経過に伴って信号特性が変化するといった筋電位と動作との対応関係の複雑さから，安定して動作を識別することは難しい．

一方，筋電位で制御する補助器（筋電制御機器）を自在に取り扱うことができるかは個人によって大きく異なる．すなわち，習熟の程度（習熟度）が機器の使い方の巧みさと強く関連しているため，習熟状態に応じて機器の特性を変更しなければ各個人にとって使いやすいシステムは構築されない．

以上より，機器側が筋電位と動作との対応関係の複雑さに影響されない動作識別を構築し，かつ人が筋電制御機器の操作運動に習熟すれば，より多くの動作を識別することが可能になると考えられる．そこで，本研究では日常生活に必要なより多くの動作を識別することを目的として，習熟度を考慮した自己組織的動作識別法を提案し，動作識別トレーニングシステムを構築した．提案システムの対象範囲は切断や欠損などによる肢体不自由者とする．これは，断端部の神経・筋肉は残存しているため筋電位が計測可能であり，機器の制御信号として利用できるためである．本稿では筋電義手に提案システムを適用して動作識別トレーニングを行い，識別可能な動作数や識別率により，システムの有効性を検証した．

原稿受付 2009 年 12 月 18 日
[*1]東京大学
[*2]電気通信大学
[*1]The University of Tokyo
[*2]The University of Electro-Communications
■ 本論文は学術性で評価されました．

2. 従 来 研 究

筋電制御機器で多くの動作を実現する際に生じる課題は，筋電位と動作との対応関係の複雑さへの適応（課題 1），人の機器操作への習熟評価（課題 2）に大別される．そこで，表面筋電位を用いた機器の一般的な制御方法を示し，おのおのの課題に関する従来研究と，残された問題を以下に示す．

2.1 表面筋電位からの動作識別

筋電位からの動作識別は **Fig. 1** に示すようなパターン認識問題に帰着されることが多い．識別フェーズでは，時刻 t において表面筋電位 $\mathbf{EMG}_{\mathrm{t}}$ を計測し，特徴抽出関数 $\mathrm{G_{FE}}$ により動作固有の特徴量を並べた特徴ベクトル $\mathbf{X}_{\mathrm{t}}$ を生成する．識別関数パラメータ $\mathbf{W}$ を有する識別関数 $\mathrm{G_{PR}}$ により，入力パターン $\mathbf{X}_{\mathrm{t}}$ から動作 y_k（$\in \mathbf{Y} \equiv \{y_1, y_2, \cdots, y_M\}$，$\mathbf{Y}$：動作の全集合）を識別し，実際の機器の動作として出力する．また，$\mathbf{W}$ は実際に識別を行う前に学習フェーズにおいて決定される．まず，訓練データ生成関数 $\mathrm{G_{IS}}$ が特徴ベクトル $\mathbf{X}$ とそれに対応する動作 $\mathbf{Y}$ の組（訓練データ $\mathbf{\Psi}$ と呼称）を生成し，学習関数 $\mathrm{G_{LU}}$

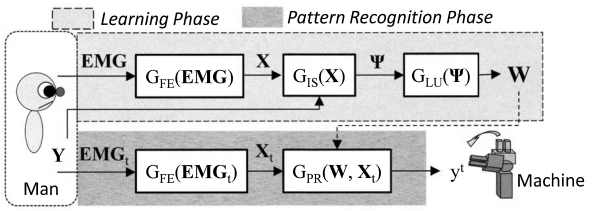

Fig. 1 A Framework of motion classification using EMG. In the learning phase, a feature extraction function G_{FE} generates a feature vector $\mathbf{X}$ from **EMG**. G_{IS} combines $\mathbf{X}$ and user's intended motion $\mathbf{Y}$ to generate training data $\mathbf{\Psi}$. G_{LU} generates a parameter $\mathbf{W}$ which determined the control rules for the classifier, and sends it to the pattern recognition phase. A discriminant function G_{PR} discriminates a motion y_k from $\mathbf{X}$

がこの対応関係を満足するように $\mathbf{W}$ を決定する．本稿ではこの識別法を “従来法” と呼称する．

パターン認識問題では，表面筋電位から運動に関するどのような情報を抽出するか（特徴抽出）と，その特徴を機器のどの動作出力カテゴリに分類するか（パターン識別）が重要となる．表面筋電位から抽出される特徴量は，信号の振幅情報に関するもの [1]〜[3] と周波数情報 [4] [5] に関するものの二つに大別される．振幅情報は時間変動に対して安定的だが情報量が少なく，周波数情報は情報量は多いが時間変動の影響を受けやすいという特徴がある．一方，パターン識別を行う際の識別関数は，閾値 [1] [2]，線形判別 [6] [7] などの線形関数，ニューラルネットワーク [8] [9] や Fuzzy 推論 [10] などの非線形関数に大別される．線形関数は計算コストは少ないが識別能力が不十分，非線形関数は識別能力が高く，多くの動作を識別可能であるが，パターンの学習時間が増大するという特徴がある．

筋電位と動作との対応関係の複雑さには，動作と筋電位との対応関係が 1 対 1 ではないという “曖昧さ” と対応関係が時間的に変化するという “時変性” が存在する．従来，曖昧さに対しては，時間変動に対して安定的な振幅情報を採用することで対応してきたが，情報量が少ないため，少数の電極で多くの動作を識別するのが困難である．時変性に対しては，訓練データをオンラインで更新する方法が提案されているが [11]，学習コストが大きい，劇的な変化に未対応といった課題が残されており，曖昧さ，時変性の両方を解決する方法論は提案されていない．

2.2 筋電制御機器の操作運動に対する習熟評価

筋電制御機器に対する習熟評価においては，動作識別率などのパフォーマンス評価を利用することが一般的である [9] [11]．しかしながら，このような外部座標からの評価のみでは，習熟過程において生じる人の内部状態の変化を把握することは難しい．また，筋電制御機器として最も一般に普及している筋電義手では，臨床現場において医療スタッフが「できる動作の個数はいくつか」や「ある動作が巧くできたかどうか」などで評価しているのが現状である [12] [13]．しかしながら，「ある動作が巧くできたかどうか」などはスタッフにより評価が異なり，客観的な評価とは言い難い．

一方，運動中に人間内部において生じる変化をより詳細に捉えるため，表面筋電位を用いて習熟を評価する方法が提案されている．加藤らは，動作の特徴空間における重複度合いを条件付き情報エントロピーにより評価し，筋電義手の習熟度指標として用いている [11]．しかしながら，全動作からエントロピーを算出しているため，どの動作間の特徴空間に重複があるかなど，より詳細な情報を得ることは難しい．また，原らは筋電義手に対する習熟度を筋電位制御能力と定義し，各動作における主動筋の整流化平均値（ARV）を説明変数，拮抗筋群の ARV を目的変数とした切片が 0 である回帰直線の傾きで評価している [14]．しかしながら，これは主動筋と拮抗筋の働きがはっきりと区別できる開閉 2 動作の筋電義手を対象としており，多動作を実施するときの習熟を評価することは難しい．このように，表面筋電位から筋電制御機器の操作運動に対する習熟を評価する方法論は確立されていない．

3. 習熟度を考慮した自己組織的動作識別法

本研究では，課題 1 に対して，筋電位が変動しても他の動作と重複しない代表的なパターンを抽出し，その対応関係を学習することで安定的な動作識別を行う方法論（**Fig. 2** 中の G_{TR} に相当，3.1 節で詳述），課題 2 に対して，筋電位から得られる運動パターンの精度と再現度で習熟を評価する方法論（Fig. 2 中の G_{TP} に相当，3.2 節で詳述）を提案する．

さらに，これらを統合し習熟度に基づいた動作識別トレーニングを可能にするシステムを構築する（Fig. 2）．提案システムは訓練フェーズ，学習フェーズ，識別フェーズの三つから成る．加えて，訓練フェーズにある習熟度推定器（Proficiency Level Estimator）は人の操作能力が現状どの程度であるかを推定する機能と，習熟度が向上した場合に識別対象となる動作を追加する機能を有しており，提案システムを用いた動作識別トレーニングの流れも，1）現状における識別可能な動作集合の特定，2）トレーニングによる識別可能な動作数の向上となる．提案システムにおいては，習熟度により人の操作能力を定量的に評価し，最初に他の動作と混同しやすい動作を除外してゆき，その後，少ない動作で習熟したと判定された場合に，混同しづらい動作から追加することで，効率的にトレーニングを行い，最大限識別できる動作数を増加させることができると考える．以下に，1），2）における処理の流れを詳述する．

1）では，まず，システム使用開始時に $\mathbf{Y}_{\mathrm{all}}$ に対する訓練データ $\mathbf{\Psi}$ を生成しておく．$\mathbf{Y}_{\mathrm{all}}$ は人が実現可能な N_a 個（$> M$）の有限動作記号集合とする．

$$\mathbf{Y}_{\mathrm{all}} = \{y_1, \cdots, y_k, \cdots, y_{N_a}\} \tag{1}$$

次に訓練フェーズにおいて，人に $\mathbf{Y}_{\mathrm{all}}$ を実施してもらい，動作中に計測される筋電位の特徴ベクトル $\mathbf{X}$ から習熟度 $\mathbf{\Pi}$ を算出する．$\mathbf{\Pi}$ を算出する際には，訓練データ $\mathbf{\Psi}$ の特徴パターンと自身の筋パターンを一致させるように動作を行うよう指示される．算出された習熟度 $\mathbf{\Pi}$ がある閾値 $\mathbf{\Pi}^*$ 以下だった場合，操作者が動作群 $\mathbf{Y}_{\mathrm{all}}$ を識別することに習熟していないと判断し，動作の除外を行う．本研究においては，習熟度を精度 d と再現度 σ_e の 2 項組として算出する．動作識別における精度とは特徴空間上における重複度を表しており（3.2.2 項で詳述），「重複度が高い動作を除外すれば全体の習熟度が向上する」と仮定し，

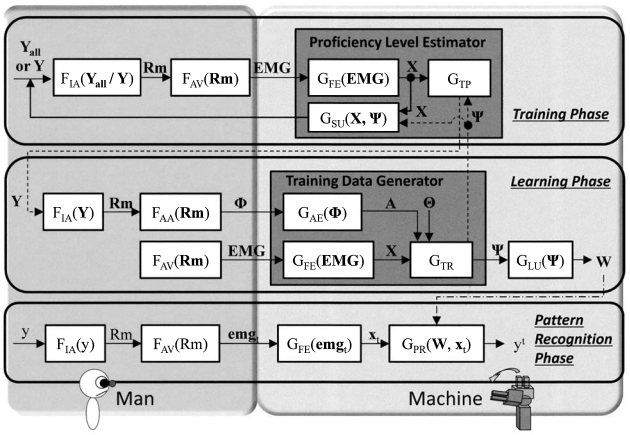

Symbol	Meaning
y	A intended motion of a user
Y	Set of y
$\mathbf{Y}_{all}$	Set of all motions human can generate
y^t	Discriminated motion at time *t*
Rm	A motion generated with y
Rm	Set of Rm
$\mathbf{emg}_t$	EMG signals measured during a motion y at time *t*
EMG	EMG signals measured during all motions of $\mathbf{Y}_{all}$ or **Y**
$\mathbf{x}_t$	Feature vector extracted from $\mathbf{emg}_t$
X	Feature vector extracted from **EMG**
Φ	Joint angles measured during all motions of $\mathbf{Y}_{all}$ or **Y**
A	Joint angle vector extracted from **Φ**
Θ	Joint angle set of standard motion
Ψ	Set of training data

Symbol	Meaning
W	Parameter of discriminant function
Π	Level of proficiency
Rec	Storage of deleted motion
F_{IA}	Move a body with motion intention
F_{AV}	Output EMG signals
G_{FE}	Feature extraction function of EMG signals
F_{AA}	Output joint angles
G_{AE}	Feature extraction function of joint angles
G_{TR}	Generate training data
G_{LU}	Learning function
G_{PR}	Discriminant Function
G_{SU}	Show feature vectors to a user
G_{TP}	Calculate level of proficiency and determine motions for discrimination

Fig. 2 The overview of proposed system. It consists of three phases: training phase, learning phase, and pattern recognition phase

精度が最も低い動作 y_{c_i}（$i=1$）を $\mathbf{Y}_{\rm all}$ から除外し，除外履歴 **Rec** に保存する．

$$\mathbf{Y}_{\rm all} \cap \overline{\{y_{c_1}\}} \rightarrow \mathbf{Y}_{\rm all} \qquad (2)$$

$$\mathbf{Rec} \cup \{y_{c_1}\} \rightarrow \mathbf{Rec} \qquad (3)$$

1 動作除外された $\mathbf{Y}_{\rm all}$ で再び習熟度を算出し，習熟度が閾値 $\mathbf{\Pi}^*$ 以下の場合，精度が最も低い動作 y_{c_i}（$i=2$）を除外する．習熟度がある一定以上となるまで習熟度の算出と動作の除外を繰り返す．習熟度がある一定以上となったときの動作集合 $\mathbf{Y}_{\rm all}$ を現状における識別可能な動作の集合 $\mathbf{Y}_{\rm c}$ とする．

2）では，1）において特定した動作集合 $\mathbf{Y}_{\rm c}$ を学習フェーズへと渡し，G_{TR} により訓練データ **Ψ** を生成する．生成された **Ψ** は訓練フェーズへ渡され，人は **Ψ** が示す筋電位の特徴パターンに自身の筋活動パターンを一致させるようにトレーニングを行う（Fig. 2 中の G_{SU}，3.1.3 項で詳述）．また，**Ψ** を学習（Fig. 2，G_{LU}）することにより生成された識別関数パラメータ **W** は識別フェーズに渡され，動作の識別が行われる（Fig. 2，G_{PR}）．トレーニング中は常に動作識別も実施されており，人は出力される機器の動作を確認することができる．一定時間のトレーニング後，訓練フェーズにおいて再び習熟度 **Π**（精度 d，再現度 σ_e）を算出する．これがある閾値 $\mathbf{\Pi}^*$ 以上だった場合，操作者が集合 $\mathbf{Y}_{\rm c}$ に属する全動作の識別に習熟していると判断して，動作の追加を行い，新たに識別対象動作の集合 **Y** とする．追加する動作 y_{c_i} の順番は，除外履歴 **Rec** を参照して最後に除外した動作，すなわち除外した動作の中でも最も精度が高いものから順に加える．生成された集合 **Y** は学習フェーズに渡され，1 動作増えた状態で改めて訓練データ **Ψ** を生成し（Fig. 2，G_{TR}），識別関数パラメータ **W** を更新する（Fig. 2，G_{LU}）．同時に，生成された訓練データは訓練フェーズにおいて，操作者に提示され（Fig. 2，G_{SU}），再び **Y** に属する全動作の識別トレーニングを行う．以上のように，習熟度算出，動作の追加，トレーニングを繰り返し動作数の向上を目指す．

3.1 自己組織的動作識別法

2.1 節で述べたように，識別関数パラメータ **W** は訓練データ **Ψ** から決定されるため，あらかじめ生成した訓練データと実際

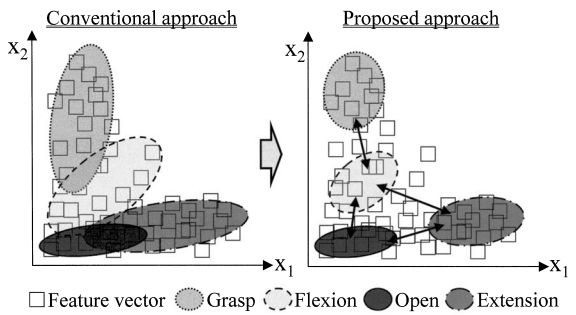

Fig. 3 Training data generated with a conventional and the proposed approach (two-dimensional conceptual diagram)

に動作識別を行う際に計測される特徴ベクトルとのずれが小さく，かつ他動作の特徴ベクトル間の距離が大きければ誤識別される可能性は減少すると考えられる．**Fig. 3** に表面筋電位からの特徴抽出処理によって得られる各動作の特徴ベクトルが存在する二次元の特徴空間を例として示す．各楕円は各動作を実施時に得られる特徴ベクトルが特徴空間において占める領域を模式的に示したものである．従来の動作識別においては，人が動作を行ったときの特徴ベクトルをそのまま動作の訓練データとして採用しているものがほとんどである．この場合，人は動作間の特徴空間の重なりを考慮せずに動作を実施するため，Fig. 3 の左図に示すように，動作の特徴空間に重複が生じる．その結果，空間の分離性が低下し，識別精度が低下すると考えられる．

そこで，本研究では，Fig. 3 に右図に示すように，自己組織化クラスタリングを用いて人が各動作を行った際の特徴ベクトルの中から他の動作と重複しないような代表的な特徴パターンを抽出し，それに対して動作を対応付け訓練データを生成することで安定的な動作識別の実現を目指す．提案手法は，ベクトル量子化を用いた分離性の高い特徴ベクトルの生成と動作姿勢に基づく動作意図の割り当てから成り立つ（**Fig. 4**）．加えて，訓練データと実際に動作識別を行う際に計測される特徴ベクトルとのずれを小さくし識別精度の向上を図るため，訓練データを目標パターンとして人に提示し（**Fig. 5**），トレーニングを行う．以下に各プロセスを詳述する．

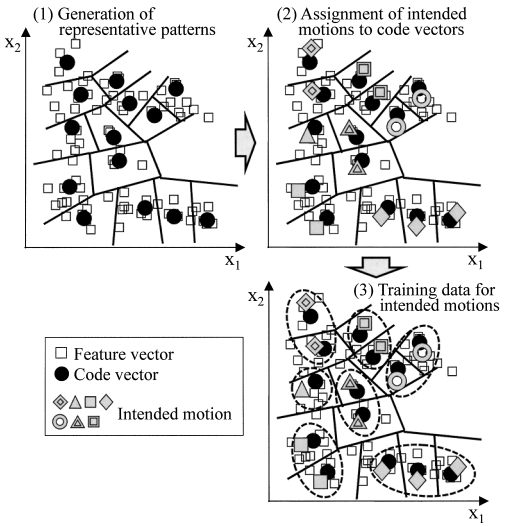

Fig. 4 A process of generating training data (two-dimensional conceptual diagram)

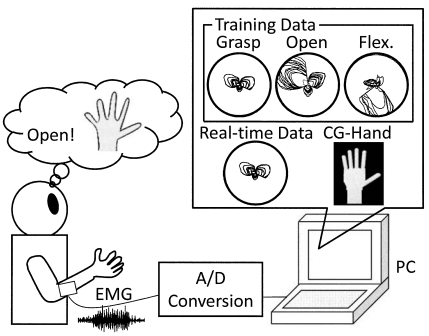

Fig. 5 Motion discrimination training with proposed system. Training data are shown to users as target patterns, and users try to fit their feature pattern (Real-time Data) to the training data

3.1.1 自己組織化クラスタリングを用いた代表的な特徴ベクトルの生成

人は握り，開きなど義手に出力させたい動作を行い，安静から動作の定常状態までの筋電位と手指の関節角度を計測する．関節角度は 3.1.2 項で使用する．特徴抽出関数 $\mathrm{G_{FE}}$ を用いて，計測された全筋電位 **EMG** に対して n 回特徴抽出して得られるベクトルを $\mathbf{X}$ とする．

$$\mathbf{X} = (\mathbf{x}_1, \cdots, \mathbf{x}_i, \cdots, \mathbf{x}_n) \tag{4}$$

$$\mathbf{x}_i = (x_1, x_2, \cdots, x_D) \tag{5}$$

本稿では，筋電位の振幅値と短時間フーリエ変換で得られる 20〜400 [Hz] の周波数情報を特徴ベクトル $\mathbf{x}_i$ として用いる．D は特徴ベクトルの次元数を表す．$\mathbf{X}$ が表現する特徴ベクトル空間を，ベクトル量子化関数により有限個 n^* の部分空間に分割する [15]．まず，コードベクトル $\boldsymbol{\xi}_j (j = 1, 2, 3)$ をランダムに空間に配置する．$\boldsymbol{\xi}_j$ の次元数は $\mathbf{x}_i$ と等しい．次に，特徴ベクトル $\mathbf{x}_i$ とのユークリッド距離が最も小さくなるコードベクトルを式（6）より算出し，$\mathbf{x}_i$ に接近するようにその値を式（7）を用いて更新する．距離が最小となるコードベクトル以外の値は更新されない．

$$c_k = \arg\min_j \{\|\mathbf{x}_i - \boldsymbol{\xi}_j\|\} \tag{6}$$

$$\boldsymbol{\xi}_j = \begin{cases} \boldsymbol{\xi}_j + \alpha \cdot (\mathbf{x}_i - \boldsymbol{\xi}_j) \ , & j = c_k \\ \boldsymbol{\xi}_j \ , & j \neq c_k \end{cases} \tag{7}$$

c_k はユークリッド距離が最小となるコードベクトルの番号，α は学習係数を示す．また，すべての特徴ベクトル $\mathbf{x}_i (i = 1, \cdots, n)$ に対して，式（6），（7）を反復計算し，コードベクトルの位置を更新する．ここで，コードベクトル $\boldsymbol{\xi}_j$ が代表する部分空間に属する特徴ベクトル $\mathbf{x}^k (\in \mathbf{X})$ の集合 $\boldsymbol{\Omega}$ は次のように定義される．

$$\boldsymbol{\Omega} \equiv \{\mathbf{x}^k \,|\, k = 1, \cdots, n_{cv}\} \tag{8}$$

n_{cv} はコードベクトル $\boldsymbol{\xi}_j$ に属する特徴ベクトル数である．すべての特徴ベクトル $\mathbf{x}_i$ と比較して $\boldsymbol{\xi}_j$ を更新したあと，$\boldsymbol{\xi}_j$ と $\boldsymbol{\xi}_j$ が代表する部分空間に属する特徴ベクトル $\mathbf{x}^k$ とのユークリッド距離の総和 $E_j (j = 1, 2, 3)$ を算出し，1 番目，2 番目に総和が大きいコードベクトルを決定する．

$$E_j = \sum_{k=1}^{n_{cv}} \left\| \boldsymbol{\xi}_j - \mathbf{x}^k \right\| \tag{9}$$

式（9）で抽出された部分空間内の分散が大きい二つのコードベクトルの中間に新たなコードベクトル $\boldsymbol{\xi}_j (j = 4)$ を追加する．コードベクトル数が設定値 n^* に達するまで式（6）〜（9）の処理を繰り返す．その結果，各部分空間にはその空間を代表するコードベクトルが配置される（Fig. 4，(1)）．

このコードベクトル集合 $\boldsymbol{\Xi} (\equiv \{\boldsymbol{\xi}_j \,|\, j = 1, \cdots, n^*\})$ が，すべての識別対象動作の特徴ベクトルが生成する特徴空間における代表的な特徴パターンと等価であり，訓練データの候補となる．また，コードベクトルは特徴ベクトルが存在している領域にのみ配置される，すなわち一度は人が出したことのある筋活動パターン上に発生するため，人は訓練データが示すパターンに自身の筋活動パターンを一致させることができる．

3.1.2 コードベクトルと動作との対応付け

3.1.1 項までにおいては，筋電位の特徴空間を分割したにすぎず，コードベクトルがどの動作に対応しているのかを決定する必要がある．人の運動意図を反映するものの一つとして動作姿勢があり，これを用いて動作との対応付けを行えば，人が自身の筋パターンを訓練データと一致させやすいと考えられる．そこで，使用者は識別対象となる動作を行い，動作姿勢が一定となるときの手指の関節角度を計測し，基準となる動作姿勢の集合 $\boldsymbol{\Theta}$ をあらかじめ作成する．

$$\boldsymbol{\Theta} \equiv \{\boldsymbol{\theta}^{y_k} \,|\, k = 1, \cdots, M\} \tag{10}$$

$$\boldsymbol{\theta}^{y_k} = \left(\theta^1_{y_k}, \cdots, \theta^i_{y_k}, \cdots, \theta^{L_a}_{y_k}\right) \tag{11}$$

$\theta^i_{y_k}$ は，動作 y_k を実施時にセンサ i で計測される関節角度，L_a は角度センサ数を示す．

一方，3.1.1 項で算出したコードベクトルに対しても角度情報

を付与する．そのため，まず，筋電位と同時に計測していた関節角度 $\mathbf{\Phi}$ から，動作姿勢ベクトル $\mathbf{A}$ を抽出する．

$$\mathbf{A} = (\mathbf{a}_1, \cdots, \mathbf{a}_i, \cdots, \mathbf{a}_n) \tag{12}$$

$$\mathbf{a}_i = (a_1, a_2, \cdots, a_{L_a}) \tag{13}$$

すなわち，$\mathbf{a}_i$ が特徴ベクトル $\mathbf{x}_i$ に対応する動作姿勢情報である．次に，$\mathbf{x}_i (i = 1, \cdots, n)$ とコードベクトル $\boldsymbol{\xi}_j (j = 1, \cdots, n^*)$ のユークリッド距離をすべての組み合わせで計算し，$\boldsymbol{\xi}_j$ の近傍 K 点の特徴ベクトルが持つ関節角度 $\mathbf{a}$ の平均値を $\boldsymbol{\xi}_j$ の動作姿勢情報 $\mathbf{a}_j^*$ とする．

以上のようにして得られたコードベクトルの動作姿勢情報 $\mathbf{a}^*$ と基準動作姿勢 $\mathbf{\Theta}$ とのユークリッド距離を順に算出し，距離が最も小さい基準動作をコードベクトルに対応付け（Fig. 4,（2））, その結果得られる組み合せにより，訓練データ集合 $\mathbf{\Psi}$ は生成される（Fig. 4,（3））.

3.1.3　識別関数と人への訓練データの提示

識別関数としては，3 層フィードフォワード型ニューラルネットワーク（ANN）を採用する．学習関数 $\mathrm{G_{LU}}$ は，誤差逆伝搬法により $\mathbf{\Psi}$ から識別関数パラメータ $\mathbf{W}$ を算出する．

提案手法においては，すべての識別対象動作を順次行い計測される筋電位から自己組織クラスタリングを用いて代表的な特徴ベクトルを生成し，動作姿勢情報を用いて動作を割り当て，訓練データの生成を行う．このため，人は意図動作に対して，どのような特徴ベクトルが対応付けられているか未知である．そこで，より高い精度で動作識別を行うため，人に訓練データを提示し（Fig. 5，Training Data），自身の筋パターン（Fig. 5, Real-time Data）を提示された訓練データに一致させるようにトレーニングを行う．このとき，人は様々に手を動かし，自身の力の入れ方の違いで特徴ベクトルが変化する様子を Real-time Data により見ることができ，自身の動作と特徴ベクトルとの対応関係を学習することができる．さらに，トレーニング時には動作識別も常に実施されており，その識別結果は CG-Hand（Fig. 5）に表示される．そのため，Training Data と Real-time Data に示されるパターンが一致した場合に意図する動作が機器に出力されることを容易に理解することができる．

本研究では，訓練データの特徴ベクトルをレーダーチャートにより表し，人に視覚的に提示する．D 次元の特徴ベクトル $\mathbf{x}(= (x_1, \cdots, x_i, \cdots, x_D))$ に関して，レーダーチャート上での i 次元目の特徴量の表示位置 P_i は，

$$P_i = (r_i,\ \rho_i) \tag{14}$$

と表される．r_i は特徴ベクトル x_i の絶対値，ρ_i は角度であり，おのおの，式（15）（16）により算出される．

$$r_i = |x_i| \tag{15}$$

$$\rho_i = \frac{i \cdot 2\pi}{D} \tag{16}$$

レーダーチャートは P_1 から P_D を結ぶ直線の集合となる．

3.2　表面筋電位を用いた習熟度評価法

筋電制御機器の操作に習熟するとは，操作者がどのような筋活動パターンを出力したら筋電制御機器がどのように動くのかという対応関係を学習し，自分が意図した動作（目標動作）と機器の出力動作とが一致することである．すなわち，これはある目標動作に対して，最適な運動パターンを生成する運動学習の問題として捉えることができる．

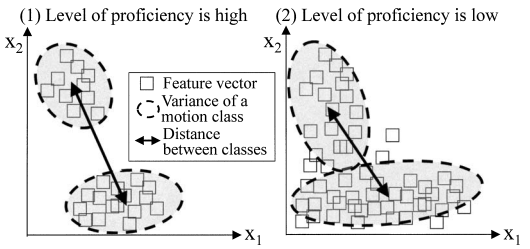

Fig. 6　Proficiency level of prosthetic application's operation (two-dimensional conceptual diagram)

運動学習の研究においては，人の運動パターンの変化とパターンの再現性が運動習熟に密接に関係していることが知られている [16]．そこで，本研究では，表面筋電位から得られる運動パターンの再現度と精度から習熟を評価する方法論を提案する．動作間の特徴分布の距離が大きく，各動作の特徴分布の分散が小さければ，多動作を識別することが可能であり，動作識別に対して習熟していると判断できることから，再現度をある動作を繰り返し行ったときの筋活動パターンのばらつき，精度を識別対象となる動作の筋活動パターンの特徴空間上での重複度として定義する（**Fig. 6**）．以下，おのおのの導出法を詳述する．

3.2.1　再現度導出法

再現度の導出過程は，表面筋電位からの特徴抽出，主成分分析を用いた特徴ベクトルの情報圧縮による運動パターンの抽出，運動パターンの分散値抽出から成る．

まず，ある動作 y_k を行ったときに計測される筋電位から特徴ベクトル $\mathbf{X}^{y_k}$ を抽出する（3.1.1 項と同様）．$\mathbf{X}^{y_k}$ に対して，主成分分析を行い，その結果得られる第 1 固有ベクトル $\boldsymbol{\nu}_1^{y_k}$ を運動パターンと定義する．固有ベクトルは，特徴ベクトルの各次元の主成分への寄与を表しており，筋活動の変化の様相を把握可能である．さらに，習熟すると安定した運動パターンへ収束すると仮定し，運動パターンの再現度の変化に着目する．動作 y_k を繰り返し行った際，N_{RE} 試行分の $\boldsymbol{\nu}_1^{y_k}$ の分散値の総和を式（17）により算出し，動作 y_k の再現度 $\sigma_e^{y_k}$ とする．

$$\sigma_e^{y_k} = \frac{1}{L \cdot N_{RE}} \sum_{i=1}^{L} \sum_{j=1}^{N_{RE}} \left\{ \nu_{1,i}^{y_k}(j) - \left(\frac{1}{N_{RE}} \sum_{k=1}^{N_{RE}} \nu_{1,i}^{y_k}(k) \right) \right\}^2 \tag{17}$$

L は筋電センサ数を表す．$\sigma_e^{y_k}$ は分散値であるため，$\sigma_e^{y_k}$ が小さいほど再現性は高い．再現度導出法の詳細は文献 [17] を参照されたい．

3.2.2　精度導出法

精度の導出過程は，表面筋電位からの特徴抽出，各動作のクラス領域の算出，クラス領域の重複度の算出から成る．特徴ベクトルは，再現度と同様のものを使用する．動作 y_k の特徴ベクトル $\mathbf{X}^{y_k}$ から，特徴空間上でクラス y_k が占める領域 Γ^{y_k} は式（18）より算出される．

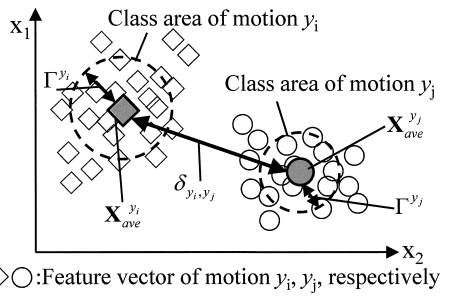

Fig. 7 A class area of motion and a relation between two motions (two-dimensional conceptual diagram)

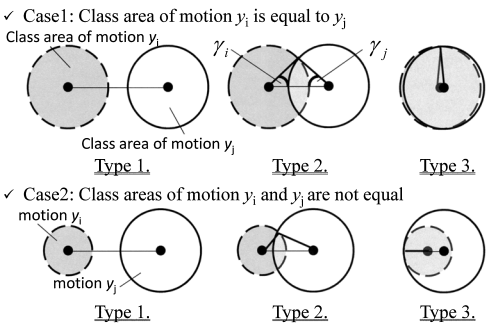

Fig. 8 Types of overlap between class areas of two motions (two-dimensional conceptual diagram)

$$\Gamma^{y_k} = \frac{1}{D}\sum_{i=1}^{D}\left\|\mathbf{x}_i^{y_k} - \mathbf{X}_{ave}^{y_k}\right\| \tag{18}$$

$\mathbf{X}_{ave}^{y_k}$ は $\mathbf{X}^{y_k}$ から算出した動作 y_k の平均特徴ベクトル，Γ^{y_k} は $\mathbf{X}_{ave}^{y_k}$ から $\mathbf{X}^{y_k}$ の構成要素である $\mathbf{x}_i^{y_k}$ までの平均ユークリッド距離，D は特徴ベクトルの次元数であり，$\mathbf{X}_{ave}^{y_k}$ を中心とする半径 Γ^{y_k} の超球を動作 y_k のクラス領域とする（**Fig. 7**）．

次に，2 種類の動作 y_i，y_j のクラス領域の重複度について考える．各動作のクラス領域を二次元で表現すると，二つの円の大きさが等しい場合と異なる場合が想定され，それぞれ，3 通りの重複が起こり得る（**Fig. 8**）．そこで，二つの円の中心を結んだ直線と，中心から二つの円の接点を結んだ直線がなす角の γ_i，γ_j に着目する．二つの円が接するとき，γ_i と γ_j の和は 0 であり，二つの円が完全に一致する，もしくは一方が他方に含まれるときには，γ_i と γ_j の和は π となる．すなわち，二つの円が重なる領域が大きくなるにつれて，γ_i と γ_j の和も大きくなる $(0 \leq \gamma_i + \gamma_j \leq \pi)$．このような関係は D 次元の超球でも同様であると考えられ，本研究では，この γ_i と γ_j の和を 2 動作間の重複度として採用する．

重複度を算出するため，まず動作 y_i と動作 y_j の平均ベクトル間の距離 δ_{y_i,y_j} を算出する．

$$\delta_{y_i,y_j} = \left\|\mathbf{X}_{ave}^{y_i} - \mathbf{X}_{ave}^{y_j}\right\| \tag{19}$$

次に，二つの動作のクラスが重なるか否か，重なる場合，一部か完全に重なるかを判定し，二つの動作の重複度を求めるため，γ_i と γ_j の余弦値を算出する．まず，

$$(\Gamma^{y_i} + \Gamma^{y_j} > \delta_{y_i,y_j}) \wedge (\delta_{y_i,y_j} = 0) \wedge (\Gamma^{y_i} = \Gamma^{y_j}) \tag{20}$$

を満たす場合，Fig. 8 の Case1・Type3 に該当し，

$$\begin{cases} \cos\gamma_i = 0 \\ \cos\gamma_j = 0 \end{cases} \tag{21}$$

となる．また，式（22）の条件を満たす場合，Fig. 8 の Case2・Type3 に該当し，かつ，動作 y_i のクラス領域に y_j のクラス領域が含まれ，余弦値は式（23）のようになる．

$$(\Gamma^{y_i} + \Gamma^{y_j} > \delta_{y_i,y_j}) \wedge (\Gamma^{y_j} + \delta_{y_i,y_j} \leq \Gamma^{y_i}) \tag{22}$$

$$\begin{cases} \cos\gamma_i = 1 \\ \cos\gamma_j = -1 \end{cases} \tag{23}$$

式（24）の条件を満たす場合も Fig. 8 の Case2・Type3 に該当し，かつ，動作 y_j のクラス領域に y_i のクラス領域が含まれ，余弦値は式（25）となる．

$$(\Gamma^{y_i} + \Gamma^{y_j} > \delta_{y_i,y_j}) \wedge (\Gamma^{y_i} + \delta_{y_i,y_j} \leq \Gamma^{y_j}) \tag{24}$$

$$\begin{cases} \cos\gamma_i = -1 \\ \cos\gamma_j = 1 \end{cases} \tag{25}$$

以上が，二つのクラス領域が完全に重なる場合である．

次に式（26）の条件を満たす場合は，二つのクラス領域が一部重なる（Fig. 8 の Case1，2・Type2）．

$$\Gamma^{y_i} + \Gamma^{y_j} > \delta_{y_i,y_j} \tag{26}$$

このとき，γ_i と γ_j の余弦値は式（27）で表される．

$$\begin{cases} \cos\gamma_i = \dfrac{D^{y_i 2} + \delta_{y_i,y_j}{}^2 - D^{y_j 2}}{2\Gamma^{y_i}\cdot\delta_{y_i,y_j}} \\ \cos\gamma_j = \dfrac{D^{y_j 2} + \delta_{y_i,y_j}{}^2 - D^{y_i 2}}{2\Gamma^{y_j}\cdot\delta_{y_i,y_j}} \end{cases} \tag{27}$$

式（20），（22），（24），（26）のいずれの条件も満たさない場合は，二つのクラス領域は重ならず（Fig. 8 の Case1，2・Type1），γ_i と γ_j の余弦値は式（28）で表される．

$$\begin{cases} \cos\gamma_i = 1 \\ \cos\gamma_j = 1 \end{cases} \tag{28}$$

以上のように求めた余弦値から式（29）を用いて算出される γ_i と γ_j の和を，2 種類の動作 y_i と y_j のクラス領域の重複度 O_{y_i,y_j} と定義する．

$$O_{y_i,y_j} = \operatorname{acos}\gamma_i + \operatorname{acos}\gamma_j \tag{29}$$

最後に，動作 y_k の精度 d^{y_k} を算出する．精度は，動作 y_k のクラス領域とその他の識別対象となる全動作のクラス領域の重複度の総和として定義される（式（30））．

$$d^{y_k} = \sum_{j=1}^{M} O_{y_k,y_j} - O_{y_k,y_k} \tag{30}$$

M は動作数を表す．d^{y_k} は重複度であるため，d^{y_k} が小さいほど精度は高い．

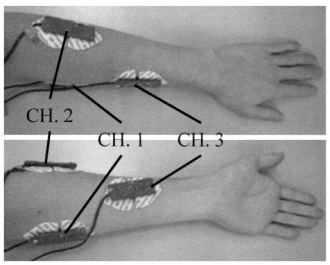

Fig. 9 Positions of EMG sensors on left forearm

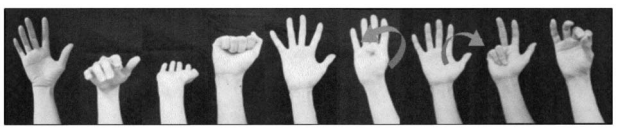

Fig. 10 Subject's nine forearm motions for discrimination

4. 実　　験

習熟度に基づく動作識別トレーニングを可能にする自己組織的動作識別法（提案システム）を用いて前腕 6〜10 動作の識別実験を行い，提案システムの性能やトレーニング効果を習熟度や動作識別率から検証した．

4.1 方法

被験者は，2.1 節で述べた従来法での動作識別に十分習熟している 20 代健常女性 1 名 A，男性 1 名 B である．まず，基準動作姿勢の集合 $\boldsymbol{\Theta}$ を作成するために，識別対象動作となる動作を順に行い，姿勢保持中の手指の関節角度（18 箇所）をデータグローブ（Immersion Corp 製，Cyber Glove）を用いて 50 [Hz] のサンプリングレートで計測した．さらに，動作時の関節角度と，筋電位を **Fig. 9** に示す左前腕 3 箇所（橈側手根屈筋，尺側手根伸筋，長母指屈筋）において 1,600 [Hz] のサンプリングレートで計測し，訓練データを生成した．識別対象動作は **Fig. 10** に示す 9 動作である．

ここで，予備実験において習熟度と動作識別率との相関性を検証した結果，精度と再現度では識別率との関係性が異なり，精度と識別率との間には中程度から強い正の相関が存在し，精度が高い場合には再現度の高さが識別率を向上させることを確認した．さらに，習熟度（精度 d 値，再現度 σ_e 値）が，$d < 5.0$, $\sigma_e < 0.005$ を満たす場合に動作識別率が 90%以上であったことから，これを習熟の判定条件とした．

提案システムを用いた実験の手順は，1）識別可能な動作の特定，2）トレーニングによる識別動作数の向上である．1）においては，まず 9 動作で訓練データを生成して被験者に提示し，各動作につき 3 回（1 回につき姿勢を 3 秒間維持）筋電位を計測し，精度を算出した．その後，識別対象とする全動作で $d < 5.0$ となるまで，精度が最も低い（d 値が最も高い）動作を順に除外し，現段階において被験者が習熟していると考えられる動作数を判定した．次に 2）では，その識別可能な動作数において，被験者は提示された訓練データに自身の運動パターンを一致させるトレーニングを行い，習熟度と達成度評価として識別率を算出した．習熟度が判定条件（$d < 5.0$ かつ $\sigma_e < 0.005$）を満たす場合，1）において最後に除外した，すなわち除外したなかでは最も精度が高かった 1 動作を追加した．全識別対象動作の習熟度が判定条件を満たさなくなるまで，動作の追加，トレーニング，習熟度算出を繰り返した．実際に提案システムを使用する際は，習熟していると判定された場合に新たな動作の追加を行うが，本実験では習熟度の変化を検証するため 15 分のトレーニングと各動作 3 回の習熟度算出を 1trial とし，5trial を実施した．

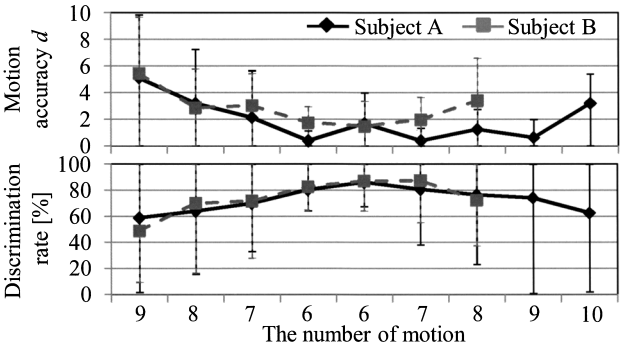

Fig. 11 The change of motion accuracy and discrimination rate through training

識別に用いる ANN のパラメータは，隠れ層を 55，出力層を 10，学習率を 0.05 とし，誤差が 0.01 を下回るか学習を 3 万回行った時点で学習終了とした．

4.2 結果と考察

4.2.1　提案システムによる識別能力の向上

Fig. 11 に実験を通した精度（上図）と識別率（下図）の変化を表す．横軸は動作数を表し，左から右に時系列順である．グラフは各動作数における全動作の平均精度，平均動作識別率と，最大・最小値を示す．全動作の d 値が 6 動作のときに 5.0 以下となり，被験者 A，B とも 9〜6 動作までが識別可能な動作の特定，6 動作以降でトレーニングを行い動作数の向上を図っており，最終的な動作数は被験者 A で 10 動作（Fig. 10 の 9 動作に尺屈を追加），B で 8 動作であった．精度は動作数が減るにつれて向上（d 値が減少）しており，また，識別可能な動作の特定中とトレーニング後を比較すると，同じ動作数でも後者の平均精度が向上（d 値が減少）し，分散が小さい．平均動作識別率も同じ動作数ではトレーニング後のほうが高く，被験者 A では 9 動作の識別率が 53.52%から 74.56%，B では 7 動作で 66.90%から 88.18%に向上した．これより，提案システムを用いて動作識別トレーニングを行った結果，動作識別に対して十分習熟し，識別率が安定した熟練操作者においても，トレーニング前後で識別率が向上し，提案システムの有効性が示唆された．そこで，識別可能な動作の特定を行う期間，トレーニングにより識別可能な動作数を増やす期間における習熟度と識別率の様相の変化を以下に示す．

4.2.2　識別可能動作数の探索

Table 1 に示すように被験者 A では，ID03，ID07，ID04 の順に除外し，6 動作としたところですべての動作の精度 d 値が 5.0 以下となったため，動作の除外を停止した．また，被験者

Table 1 The change of motion accuracy d of subject A. The values indicated by boldface mean the highest value of d among each number of motions. And these were deleted in the next step. IDs in the section of "Motion" are as same as those in Fig. 10

Motion	Motion accuracy d			
	9 motion	8 motion	7 motion	6 motion
ID00	0.00	0.00	0.00	0.00
ID01	3.88	3.52	1.35	0.00
ID02	1.76	0.76	1.18	0.00
ID03	**9.85**	**Deleted**	**Deleted**	**Deleted**
ID04	8.22	3.32	**5.65**	**Deleted**
ID05	1.96	0.00	1.41	0.00
ID06	5.69	3.94	2.27	**1.11**
ID07	6.89	**7.25**	**Deleted**	**Deleted**
ID08	7.51	6.56	2.89	**1.11**

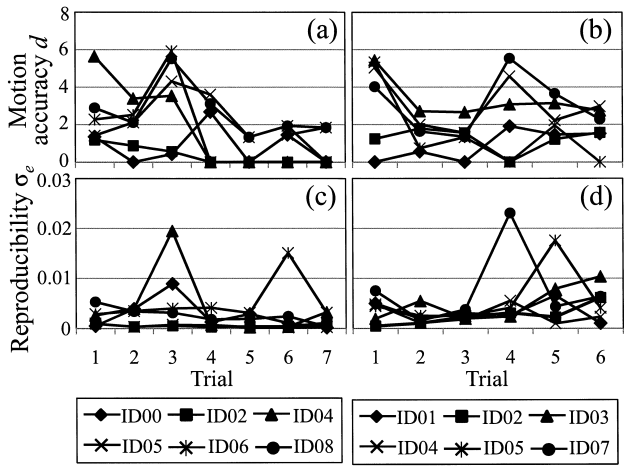

Fig. 12 The change of reproducibility and motion accuracy during training of seven motion's classification. IDs are as same as those in Fig. 10. (a) (b) Motion accuracy of subject A, B. (c) (d) Rebroducibility of subject A, B.

B では，ID06，ID08，ID03 の順に除外し（データ掲載なし），被験者 A と同様に，6 動作のときにすべての動作の精度 d 値が 5.0 以下となったため，動作の除外を停止した．このことから，被験者 A，B とも識別可能な動作数は 6 動作であったため，6 動作からトレーニングを開始した．

4.2.3 トレーニングによる識別可能な動作数の向上

被験者 A には ID04，被験者 B には ID03 を追加して 7 動作の訓練データを生成し，トレーニングと習熟度算出を実施した結果を **Fig. 12** に示す．被験者 A に関しては，6trial 目の再現度が低かったため，7trial 目を実施した．グラフの横軸は習熟度算出の回数を示すが，1 回目は識別可能動作の特定時における 7 動作の再現度，精度を示している．被験者 A では，トレーニングをするにつれて，すべての動作の精度が向上（d 値が減少）していることが分かる（Fig. 12 (a)）．一方，再現度は，ID08 のように単調に向上（σ_e 値が単調減少）していくもの，ID02，ID05 のように初めから高い（σ_e 値が一定）もの，ID04，ID06 のように極大値が存在するものと，動作により異なる傾向が見られた（Fig. 12 (c)）．習熟度算出時には各動作を 3 回実施するが，極大値部分では毎回異なる運動パターンで動作を行い，分散が大きくなったと考えられる．すなわち，動作を行う運動パターンの探索を行っていると考えられる．また，被験者 B においては，3trial までに精度，再現度ともに向上（d 値，σ_e 値が減少）するが，4trial 目に再びどちらも低下（d 値，σ_e 値が増加）し，その後向上した（Fig. 12 (b)，(d)）．これは，運動への習熟が生じたあとに，再び運動パターンの探索を行っているのではないかと考えられる．

さらに，被験者 A，B ともに d 値が 5.0 以下，σ_e 値が 0.005 以下となる場合が生じ，7 動作の識別について習熟したと考えられる．すなわち，トレーニングをするにつれて，毎回同じ運動パターンで動作を実施することができるようになり，各動作の特徴ベクトルが占める領域内の分散が減少し，また，他動作の特徴ベクトルの領域間の距離が大きくなると考えられる．その結果，全識別対象動作の特徴ベクトルが構成する特徴空間において，特徴ベクトルが存在しない空いた領域が生まれ，新たな動作を追加可能となり，動作数向上につながると考えられる．

5. おわりに

本研究では，日常生活に必要なより多くの動作を識別することを目的として，筋電位と動作との対応関係の複雑さに適応可能な自己組織的動作識別法と，表面筋電位からの習熟度評価法を提案し，習熟度に基づくトレーニングを可能にする動作識別システムを構築した．さらに，提案システムを用いて動作識別トレーニングを行った結果，動作識別に対して熟練した操作者においても識別可能な動作数が最大 9 動作まで向上し，動作識別率もトレーニング前後において約 21%向上したことから，動作識別に対して習熟したと考えられる．これより提案システムを用いた動作識別トレーニングの有効性が示された．本稿では，短期間のトレーニングしか実施しなかったが，今後は，長期間のトレーニングをした際に最大何動作まで増やすことができるか，また初心者に提案システムと従来の動作識別法を適用した場合にトレーニング効果に差異が生じるか等の検証を行う．

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] R.F. ff Weir: "Development of a New Partial Hand Prosthesis," Communicating the Science of Prosthetics and Orthotics, vol.10, no.2, pp.2–3, 2001.
[2] M.C. Carrozza, G. Cappiello, S. Micera, B.B. Edin, L. Beccai and C. Cipriani: "Design of a cybernetic hand for perception and action," Biol. Cybern., vol.95, no.6, pp.629–644, 2006.
[3] P.J. Kyberd and P.H. Chappell: "The Southampton Hand: An intelligent myoelectric prosthesis," J. Rehabil. Res. Dev., vol.31, no.4, pp.326–334, 1994.
[4] K. Englehart, B. Hudgins, P.A. Parker and M. Stevenson: "Classification of the myoelectric signal using time-frequency based representations," Med. Eng. Phys., vol.21, pp.431–438, 1999.
[5] 辻敏夫，伊藤宏司，長町三生："義手制御を目的とした多チャンネル

EMG 動作識別法”，信学論，vol.J70-D, no.1, pp.207–215, 1987.
[6] P. Herberts, C. Almström, R. Kadefors and P.D. Lawrence: “Hand Prosthesis Control via Myoelectric Patterns,” Acta. Orthop. Scand., vol.44, no.4, pp.389–409, 1973.
[7] D. Graupe, J. Magnussen and H.G. Kwanty: “A microprocesser system for multifunctional control of upper limb prostheses via myoelectric signal identification,” IEEE Trans. Automat. Contr., vol.23, no.4, pp.538–544, 1978.
[8] C.M. Light, P.H. Chappell, B. Hudgins and K. Engelhart: “Intelligent multifunction myoelectric control of hand prostheses,” J. Med. Eng. Technol., vol.26, no.4, pp.139–146, 2002.
[9] 西川大亮，兪文偉，横井浩史，嘉数侑昇：“筋電義手制御のためのオンライン学習法”，信学論，vol.J82-D-II, no.9, pp.1510–1519, 1999.
[10] A.B. Ajiboye and R.F. ff Weir: “A Heuristic Fuzzy Logic Approach to EMG Pattern Recognition for Multifunctional Prosthesis Control,” IEEE Trans. on Neural Systems and Rehabilitation Eng., vol.13, no.3, pp.280–291, 2005.
[11] 加藤龍，横井浩史：“適応機能を有する運動意図推定システム —高機能ハンドと日常生活支援”，人工知能学会誌，vol.23, no.3, pp.326–333, 2008.
[12] S. Hubbard, H.R. Galway and M. Milner: “Myoelectric training methods for the preschool child with congenital below-elbow amputation,” J. Bone. Joint Surg. Br., vol.67-B, no.2, pp.273–277, 1985.
[13] L.M. Hermansson: “Structured training of children fitted with myoelectric prostheses,” Prosthet. Orthot. Int., vol.15, no.2, pp.88–92, 1991.
[14] 原良昭，松原裕幸，柴田八衣子，溝部二十四，深澤喜啓，岡本真規子，陳隆明，湊小太郎，吉田正樹：“筋電義手の習熟度の定量的評価手法の開発”，電学論 C，vol.128, no.8, pp.1257–1263, 2008.
[15] T. Kohonen: Self-Organizing Maps. Springer, 2nd Revised edition, 1995.
[16] H. Haken: Principles of Brain Functioning. Springer, Illustrated edition, 1996.
[17] K. Kita, R. Kato, H. Yokoi and T. Arai: “Analysis of skill acquisition process: A case study of arm reaching task,” Robot Autonom. Syst., vol.57, pp.167–171, 2009.

北佳保里（Kahori Kita）

2009 年東京大学大学院工学系研究科精密機械工学専攻博士後期課程修了．博士（工学）．2007 年〜2009 年，日本学術振興会特別研究員（DC2）．2009 年東京大学大学院情報学環特任研究員．2010 年より日本学術振興会特別研究員（PD），株式会社国際電気通信基礎技術研究所脳情報研究所連携研究員．脳卒中からの機能回復機序の解明に関する研究に従事．

（日本ロボット学会正会員）

横井浩史（Hiroshi Yokoi）

1993 年北海道大学大学院工学研究科精密工学専攻博士後期課程修了．博士（工学）．同年から通商産業省工業技術院生命研究所研究員．1995 年北海道大学大学院工学研究科助教授．2004 年東京大学大学院工学系研究科準教授．2009 年より電気通信大学大学院情報理工学研究科教授，東京大学大学院情報学環教授，現在に至る．2002 年よりチューリッヒ大学人工知能研究室シニア研究員，および西イングランド大学知的自動化システム研究室フェロー研究員を兼任．人・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）

加藤　龍（Ryu Kato）

2008 年東京大学大学院工学系研究科精密機械工学専攻博士後期課程修了．博士（工学）．同年，東京大学大学院工学系研究科精密機械工学専攻特任助教．2009 年より電気通信大学大学院情報理工学研究科助教，現在に至る．人・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）