

未学習動作を考慮した5指駆動型ロボットハンドのEMG制御

小宮山 翼^{*1}, 迎田 隆幸^{*2}, 島 圭介^{*3}

A novel EMG-based control system of five-fingered robot hand with unlearned-motion detection

Tsubasa KOMIYAMA^{*1}, Takayuki MUKAEDA^{*2} and Keisuke SHIMA^{*3}

^{*1} Educational Program for Electrical and Computer Engineering, School of Engineering Science, Yokohama National University, Electrical and Computer Engineering Bldg., 79-5, Tokiwadai, Hodogaya-ku, Yokohama-shi, Kanagawa, 240-8501, Japan

^{*2} Graduate School of Engineering Science, Yokohama National University,

Electrical and Computer Engineering Bldg., 79-5, Tokiwadai, Hodogaya-ku, Yokohama-shi, Kanagawa, 240-8501, Japan

^{*3} Faculty of Engineering, Yokohama National University., 79-5, Tokiwadai, Hodogaya-ku, Yokohama-shi, Kanagawa, 240-8501, Japan

Many man-machine interfaces controlled by electromyogram (EMG) signals such as the myoelectric prosthetic hand have been proposed. General classifiers do not cover unintended motions in the training phase and misclassify those inevitably. Since the misclassification can cause dangerous incidents, an interface with high security is required. To solve this problem, this paper proposes a novel control method of man-machine interfaces that can treat unlearned motions. In the experiments, the proposed method was applied to forearm and finger motion classification to evaluate the validity. The outcomes showed that the approach produces higher and more stable classification performance than comparative methods.

Key Words : Probabilistic neural network, Anomaly detection, EMG signal, Prosthetic hand

1. はじめに

筋電位 (Electromyogram: EMG) は運動時の筋収縮に伴って発生する生体信号であり, 筋電義手や車いすなどのインタフェースの制御信号として用いられてきた⁽¹⁾⁽²⁾. しかしながら, これらの従来研究ではあらかじめ設定した動作 (クラス) のみを識別することで義手の制御を実現しており, 異常なパターンが入力された場合に必然的に発生する誤識別から予期しない誤動作が生じる. この問題は意図せず把持する物体を離してしまうような危険なインシデントを誘発する可能性がある. このような異常パターンを扱う分類手法は多数提案されており, 異常値の希少性を考慮して正常なデータのみを学習に利用する半教師あり学習が適用されることも多い⁽³⁾⁽⁴⁾. Shimaらは未学習クラスに対する余事象の分布を定義することで想定しないクラスに属する事後確率を推定可能な新たな混合正規分布モデル (Gaussian mixture model:

GMM) を提案した⁽⁵⁾. また, 迎田らは GMM と混合余事象分布 (Complementary Gaussian mixture model: CGMM) を内包する未学習クラス推定確率ニューラルネットワーク (Normal And Complementary Gaussian Mixture Network: NACGMN) を提案している⁽⁶⁾⁽⁷⁾. このネットワークでは多クラス識別と異常検知を単一のネットワークにより実現でき, 少ない学習データからも安定したパラメータ最適化が可能であるという特徴を有する. 一方, 実際の筋電義手への実装や指などの複雑な動作に対する識別精度の検証は不十分である.

そこで本論文では NACGMN⁽⁶⁾⁽⁷⁾ を利用した 5 指型ロボットハンドに対する新たな制御システムを提案し, 単純な前腕動作と指の動作を含む複雑な動作に対する識別性能を検証する. 提案システムでは計測した EMG 信号から抽出する特徴ベクトルを NACGMN に入力し, 得られた識別結果からロボットハンドで学習動作を再現し未学習動作による動作を制限することで, 未学習動作に起因する誤動作を防止した 5 指ロボットハンドの制御を可能にする.

2. ロボットハンド制御システム

提案システムは, 図 1 に示される 3 つの要素から構成される. 特徴抽出部では計測した EMG 信号を動作

^{*1} 横浜国立大学理工学部数物・電子情報系学科電子情報システム教育プログラム (〒 240-8501 横浜市保土ヶ谷区常盤台 79-5 電子情報工学棟) komiyama-tsubasa-vw@ynu.jp

^{*2} 横浜国立大学大学院理工学府数物・電子情報系理工学専攻 (〒 240-8501 横浜市保土ヶ谷区常盤台 79-5 電子情報工学棟)

^{*3} 横浜国立大学大学院工学研究院 知的構造の創生部門電気電子と数理情報分野 (〒 240-8501 横浜市保土ヶ谷区常盤台 79-5 電子情報工学棟)




Fig. 1 Structure of the proposed system

分類に適した特徴パターンへ変換し、動作識別部では抽出した特徴パターンを NACGMN に入力することで動作推定を行う。分類結果に基づき Arduino から制御信号を生成し、ロボットハンドの制御を行う。

2.1 特徴抽出部 文献 [1] を参考に D 対の電極を用いて取得した EMG 信号から特徴ベクトル $\mathbf{x}_t \in \mathfrak{R}^D$ を構成する。計測した EMG 信号の全チャンネルに対して全波整流を行った後、カットオフ周波数 f_c [Hz] の 2 次のローパスフィルタにより平滑化を行う。次に各チャンネルの平滑化後の信号 E_d ($d = 1, \dots, D$) の最大値 $E_d^{(\max)}$ で正規化した信号を $E_d^{(\text{norm})}(t)$ とし、全チャンネルの和が 1 になるように正規化することで、各チャンネルに対する特徴ベクトル $x_d(t)$ ($d = 1, \dots, D$) を得る。

$$E_d^{(\text{norm})}(t) = \frac{E_d(t) - E_d^{(\text{st})}}{E_d^{(\max)} - E_d^{(\text{st})}} \quad (1)$$

$$x_d(t) = \frac{E_d^{(\text{norm})}(t)}{F(t)}, \quad F(t) = \sum_{d'=1}^D E_{d'}^{(\text{norm})}(t) \quad (2)$$

ここで、 $E_d^{(\text{st})}$ は安静時の EMG 信号を表す。 $F(t)$ は筋力情報を示しており、動作発生判定に用いる。

2.2 動作識別部 提案システムでは事前に未学習動作の発生を考慮した識別を可能とする迎田らによって提案された NACGMN を利用する⁽⁶⁾⁽⁷⁾。

図 2 に示される NACGMN は 5 層で構成され、

$$\theta = \left\{ p(k=0), \mathbf{w}^{(k,m)}, w_N^{(k,m)}, w_C^{(k,m)}, w_E^{(k,m)} \right\}_{\substack{k=1, \dots, K, \\ m=1, \dots, M_k}}$$

をネットワークの重みパラメータとして有する。まず、入力する特徴ベクトル $\mathbf{x}_t \in \mathfrak{R}^D$ を非線形変換し、

$$\mathbf{X}_t = \left(1, \mathbf{x}_t^\top, x_1^2, x_1 x_2, \dots, x_1 x_D, x_2^2, x_2 x_3, \dots, x_D^2 \right)^\top \quad (3)$$

と定義される $\mathbf{X}_t \in \mathfrak{R}^H$ ($H = 1 + D(D+3)/2$) を第 1 層の入力とする。このとき、各層の入出力関係は

$${}^{(1)}I_h = X_h(t), \quad {}^{(1)}O_h = {}^{(1)}I_h \quad (4)$$

$${}^{(2)}I_{k,m} = \sum_{h=1}^H {}^{(1)}O_h w_h^{(k,m)}, \quad {}^{(2)}O_{k,m} = {}^{(2)}I_{k,m} \quad (5)$$

$${}^{(3)}I_{k,m} = {}^{(2)}O_{k,m} w_N^{(k,m)}, \quad {}^{(3)}O_{k,m} = {}^{(3)}I_{k,m} \quad (6)$$

$${}^{(3)}I_{\bar{k},m} = {}^{(2)}O_{k,m} w_E^{(k,m)} + w_C^{(k,m)}, \quad {}^{(3)}O_{\bar{k},m} = {}^{(3)}I_{\bar{k},m} \quad (7)$$

$${}^{(3)}I'_{k,m} = -{}^{(2)}O_{k,m}, \quad {}^{(3)}O'_{k,m} = \log^{(3)} I'_{k,m} \quad (8)$$

$${}^{(4)}I_{k,m} = {}^{(3)}O_{k,m}, \quad {}^{(4)}I_{\bar{k},m} = {}^{(3)}O_{\bar{k},m} + {}^{(3)}O'_{k,m} \quad (9)$$

$${}^{(4)}O_{k,m} = \frac{p(k \neq 0)}{F_{\text{NN}}} \exp\left({}^{(4)}I_{k,m}\right) \quad (10)$$

$${}^{(4)}O_{\bar{k},m} = \frac{p(k=0)}{F_{\text{NN}}} \exp\left({}^{(4)}I_{\bar{k},m}\right) \quad (11)$$

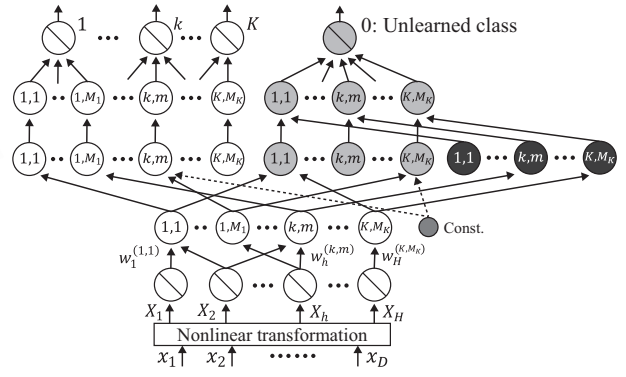


Fig. 2 Structure of NACGMN

$$F_{\text{NN}} = p(k \neq 0) \sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \exp\left({}^{(4)}I_{k',m'}\right) + p(k=0) \sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} \exp\left({}^{(4)}I_{k',m'}\right) \quad (12)$$

となる。最後に、第 5 層のユニット k は第 4 層のコンポーネントの出力を統合したものであり、入出力関係はユニット数を $K+1$ として、

$${}^{(5)}I_k = \begin{cases} \sum_{m'=1}^{M_k} {}^{(4)}O_{k,m'} & (k \neq 0) \\ \sum_{k'=1}^K \sum_{m'=1}^{M_{k'}} {}^{(4)}O_{k',m'} & (k=0) \end{cases} \quad (13)$$

$${}^{(5)}O_k = {}^{(5)}I_k \quad (14)$$

となる。 ${}^{(5)}O_k$ ($k = 0, \dots, K$) は各クラスの事後確率 $p(k|\mathbf{x}_t)$ と一致する。

θ の学習には分類対象動作の EMG 信号ベクトル \mathbf{x}_t のみを学習データとして利用する半教師あり学習を適用する。学習データに対する教師信号を用いて次式の評価関数 J により評価し、Kullback-Leibler 情報量を最小化するように $\mathbf{w}^{(k,m)}$ やその他の重みの学習を行う。

2.3 ロボットハンド制御部 識別結果に対応する動作をワンボードマイコン (Arduino 社製, Arduino Uno) によって判別し、5 指型ロボットハンド (SainSmart 社製, DIY 5 フィンガー) のサーボモータを角度制御することで設定した動作を再現する。

3. 前腕動作に対する識別性能評価

3.1 実験条件 提案システムの単純な動作に対する有効性の確認のために前腕動作のオフラインの識別実験を行った。被験者は右利きの健康な成人男性 3 名 (A-C) であり、4 チャンネルの追坂電子機器製の筋電センサ (ID3PAD) を各被験者の尺側手根伸筋 (Ch. 1)、尺側手根屈筋 (Ch. 2)、長母指外転筋 (Ch. 3)、橈側手根伸筋 (Ch. 4) に貼付した (図 3)。EMG 信号の計測にはワイヤレス EMG ロガー (LP-MS1002, ロジカルプロダクト社製) を利用し、計測時のサンプリング周波数




Fig. 3 Selected motions for motion recognition experiments




Fig. 4 Classification rates of unlearned class detection methods

は 200 [Hz] とした。図 3 に示すように実施動作は 8 種類とし、学習動作を選定した計測部位に対応する背屈 (M1)、掌屈 (M2)、橈屈 (M3)、尺屈 (M4) の 4 動作、未学習動作を指の動作を含む握り (M5)、開き (M6)、ピースサイン (M7)、ピンチング (M8) の 4 動作とした。学習データの取得のために学習クラスの動作を各 3 回行い、評価用のデータの計測時には未学習クラスの動作を含めた 8 動作を順に各 2 回実施した。テストデータの識別はオフラインで行い、動作分類の識別精度を検証する。比較手法には Shima らの従来法⁽⁵⁾と、Support vector machine (SVM) による多クラス識別器と One-class SVM による異常検知器を組み合わせた手法⁽³⁾、確率ニューラルネットワーク (LLGMN)⁽²⁾と Isolation Forest (IF)⁽⁴⁾を組み合わせた手法を利用する。SVM による識別法では RBF (: Radial basis function) カーネルを使用し、One-class SVM の学習では学習データのすべてを陽と定義した。IF では木の数を 100 とし、閾値決定には Liu らの提案法を利用した⁽⁴⁾。

3.2 実験結果 各被験者および全被験者における平均識別率を算出した結果を図 4 に示す。図中の標準偏差は各動作を分類した際の識別率ばらつきを表している。結果では提案法は全ての被験者に対して高い識別率を記録した。また、提案法の識別率のばらつきが最も小さく、比較手法より安定した学習を実現できることが示された。

4. 指動作の分類に基づくロボットハンドの制御

本実験では図 5 に示す提案法を用いた新たなオンライン識別システムによるリアルタイムな制御を行い、

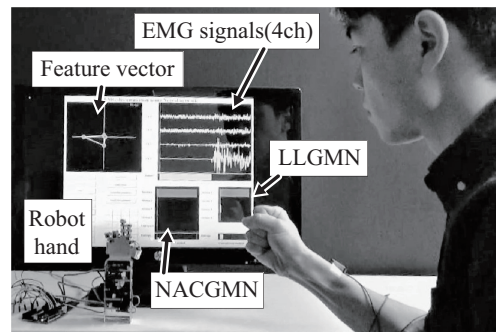


Fig. 5 Examples of online estimate system

前腕動作に比べて識別が難しい指の動作に対する有効性について検証する。

4.1 実験条件 手指動作の識別実験とロボットハンドの制御を行った。被験者を右利きの健常な成人男性 3 名 (D - F) とし、前述した計測機器を利用して EMG 信号を同様に計測した。本実験では用いるロボットハンドの自由度を考慮し、前腕や手首の動作を含まないハンドジェスチャーを分類対象とする。事前の予備実験で識別率の高かった 8 種類のジェスチャーを選定し、握り (F1)、ピースサイン (F2)、ピンチング (F3)、示指を立てる動作 (F4) の 4 動作を学習対象とし、グッドサイン (F5)、母指と示指を立てる動作 (F6)、中指と環指を曲げる動作 (F7)、環指と小指を曲げる動作 (F8) の 4 動作を未学習動作として用いた。電極位置は指の動作に関連する筋の中、短母指伸筋 (Ch. 1)、示指伸筋 (Ch. 2)、総指伸筋 (Ch. 3)、浅指屈筋 (Ch. 4) とした (図 6)。学習クラスの各動作を 3 試行分計測し (各クラス 1500 サンプル)、学習データに用いた。評価実験では被験者が未学習クラスの動作を含む識別対象の 8 動作を F1 から順に F8 まで行う試行を 10 セット行い、テストデータとして利用した。また、提案システムの学習時の各パラメータは識別性能評価実験と同様のものを利用し、比較手法においても同様の条件下でオフラインでの識別を行った。

図 6 に行った動作およびロボットハンドの制御例を示す。学習動作に対しては動作を再現し、未学習動作に対しては予期しない誤動作を防止するために動作を制限するようにロボットハンドの制御則を設定した。

4.2 実験結果 図 7 はロボットハンドの制御時の各チャンネルの EMG 信号、筋力情報、提案手法の識別器の識別結果の一例 (被験者 E) を示している。図中では筋力情報から判定した動作区間を白抜きで表している。また、識別結果では F0 が未学習クラスとして判定されたことを意味する。分類結果から学習クラス、未学習クラスの両クラスにおいて識別は概ね精度よくできていることがわかる。

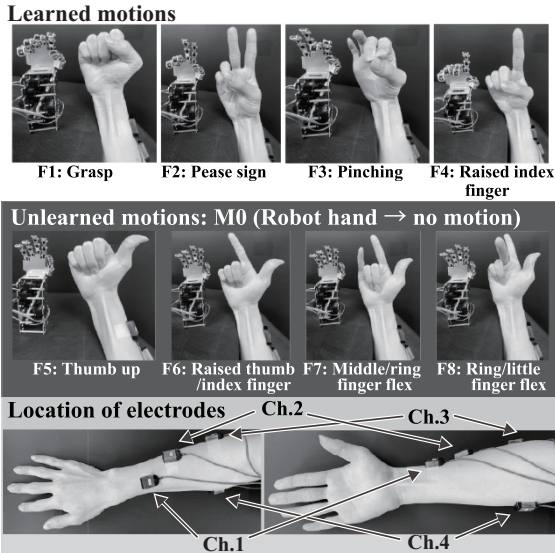


Fig. 6 Examples of robot hand control experiment




Fig. 7 Examples of EMGs and classification results

各被験者および全被験者の平均識別率を図8に示す。図中の標準偏差は10試行のテストデータに対する識別率のばらつきを表しており、平均識別率(Ave.)の標準偏差は被験者毎のばらつきを意味する。各被験者の結果から提案法の識別率のばらつきが最も小さく、指の動作識別に関しても提案法では安定した学習が可能であることが示唆された。また、全被験者の平均識別率では有意差は確認できなかったものの、比較手法に比べて高い精度での推定が可能であったことが確認できた。ただし、今回の実験では全ての学習動作に母指の屈曲状態が含まれており、未学習動作とした全ての動作とは異なっている。そのため、今後は学習動作と未学習動作の対応関係や提案法の限界についての検証が必要である。

5. おわりに

本論文では、学習時に想定されていない未学習動作を考慮した筋電位信号による5指駆動型ロボットハンドの制御システムを提案し、未学習動作による誤動作




Fig. 8 Classification rates of unlearned class detection methods

を防止した指動作に対応するマンマシンインタフェースを実現した。提案システムは動作識別部に未学習動作に対する事後確率を推定可能な確率ニューラルネットワーク(NACGMN)を用いることで学習動作の再現と未学習動作による意図しない誤動作の防止を可能とする。実験から提案システムは単純な前腕動作だけでなく複雑な指の動作においても安定した分類性能を獲得でき、リアルタイムでの指の動作識別と5指ロボットハンドの制御が可能であることを確認した。今後はデータの時間変化を考慮したリカレント構造の導入などによる識別精度の向上や対象動作の拡充、被験者の増加、さらに複数の動作を組み合わせた複雑な作業を可能にするロボットハンドの制御アルゴリズムの開発などに取り組んでいく。

参考文献

- (1) O. Fukuda, T. Tsuji, M. Kaneko and A. Otsuka, "A human-assisting manipulator teleoperated by EMG signals and arm motions," *IEEE Trans. on Robotics and Automation*, Vol. 19-2 (2003), pp.210-222.
- (2) T. Tsuji, O. Fukuda, H. Ichinobe, and M. Kaneko, "A Log-Linearized Gaussian Mixture Network and Its Application to EEG Pattern Classification," Vol. 29, No. 1 (1999), pp. 60-72.
- (3) C. M. Rocco S and E. Zio, "A support vector machine integrated system for the classification of operation anomalies in nuclear components and systems," *Reliability Engineering and System Safety*, Vol. 92 (2007), pp. 593-600.
- (4) F. Tony Liu, K. Ming Ting and Z.-H. Zhou, "Isolation Forest," *IEEE Int. Conf. on Data Mining* (2008), pp. 413-422.
- (5) K. Shima, T. Aoki, "A Novel Classification Method with Unlearned-class Detection Based on a Gaussian Mixture Model," *IEEE Int. Conf. on Systems, Man, and Cybernetics* (2014), pp.3726-3731.
- (6) 迎田 隆幸, 島 圭介, "余事象確率密度関数を内包する未学習クラス推定型確率ニューラルネットワーク," 第25回ロボティクスシンポジウム講演論文集 (2020), pp. 88-90.
- (7) 迎田 隆幸, 島 圭介, "混合余事象分布に基づく未学習クラスの推定確率ニューラルネットワーク," 計測自動制御学会論文集, Vol. 56, No. 12 (2020), pp. 532-540.