

筋シナジーに基づく複合動作のパターン識別

辻 敏夫* 島 圭介* 村上 洋介*

Pattern Classification of Combined Motions Based on Muscle Synergy Theory

Toshio Tsuji*, Keisuke Shima* and Yosuke Murakami*

This paper proposes a novel pattern classification method of user's motions to use as input signals for human-machine interfaces from electromyograms (EMGs) based on a muscle synergy theory. This method can represent combined motions (e.g. wrist flexion during hand grasping), which are not trained by a recurrent neural network in advance, by combinations of synergy patterns of EMG signals preprocessed by the network. With this method, since the combined motions (i.e. unlearned motions) can be classified through learning of single motions (such as hand grasping and wrist flexion) only, the number of motions could be increased without increasing of the number of learning samples and the learning times for controlling of the machines such as a prosthetic hand.

Effectiveness of the proposed method is shown by the motion classification experiments and prosthetic hand control experiments. The results showed that 18 motions, which are 12 combined and 6 single ones, can be classified sufficiently through learning of 6 single motions only (average rate: $89.2 \pm 6.33\%$), and the amputee could control of a prosthetic hand using single and combined motions at will.

Key Words: Muscle Synergy Theory, Electromyogram, Combined Motion, Pattern Classification, Human-robot Interface

1. はじめに

筋電位 (Electromyogram; EMG) は、筋収縮時に発生する電気信号であり、人間の動作や力、筋の粘弾性といった有益な情報を数多く含んでいる。計測した EMG 信号から人間の意図を推定できれば、機械への優れたインタラクション手段として用いることが可能であり、EMG 信号を用いたヒューマンインタフェースや人間支援に関する研究が数多く行われてきた [1]~[8]。そのなかでも、人の手のように自由自在に動かすことのできる筋電義手の研究・開発は大きな課題の一つであり、古くから現在まで数多くの議論がなされている。

EMG 信号から人間の動作や意図を推定することは、各動作とそれに付随する EMG 信号のサンプル間の特性をモデル化し、与えられたサンプルデータから各動作 (クラス) を推定することにほかならない。ただし、各動作の推定問題を EMG パターンの識別問題に帰着させて考えた場合、対象とする動作数の増加に伴い、膨大な学習サンプル数や学習時間が必要となってしまう。起こりうるすべての動作に対応した EMG 信号を計測することは非常に難しく、複雑かつ多自由度な制御問題を EMG

信号を用いて実現することは困難を極めるだろう。

一方、人間の身体の自由度は筋のレベルで約 10^3 のオーダー [9] であり、運動という非常に多自由度の制御問題において、人間は複数の筋シナジーの組み合わせによって膨大な計算量を低減していると考えられている。筋シナジーとは、Sherrington により “muscle cooperative activity” と定義され [10]、これまでに EMG 信号から筋シナジーを抽出する試みがいくつか行われている。例えば、Bizzi らは蛙の足の一連の動きの EMG 信号から複数の筋シナジーを抽出し、得られた筋シナジーの組み合わせで計測時の EMG 信号が再現可能であることを示した [11]。しかしながら、この手法により抽出した筋シナジーでは、未知動作時の EMG 信号を予測することは不可能であり、測定した動作以外の表現はできない。

本論文では、手の握りや開き、手首の掌屈や背屈などのいくつかのシンプルな動作 (単一動作と呼ぶ) を取り上げ、単一動作の組み合わせによって複雑な動作を表現するという問題を考える。ここで、従来検討されている EMG 信号を用いたヒューマンインタフェースや筋シナジー解析は、計測した EMG 信号に対して特徴抽出処理を施し、主に被験者が発揮した各筋の筋力の時系列情報を対象として解析・評価が実施される場合が多い。本論文でもこれ以降、特に明記しない限り EMG 信号から抽出した各筋の筋力情報を単に EMG 信号と呼ぶ。この考えの下、本論文では各単一動作時に発生する各筋の EMG 信号を筋

原稿受付 2009年6月23日

*広島大学大学院工学研究科

*Graduate School of Engineering, Hiroshima University

■本論文は学術性で評価されました。

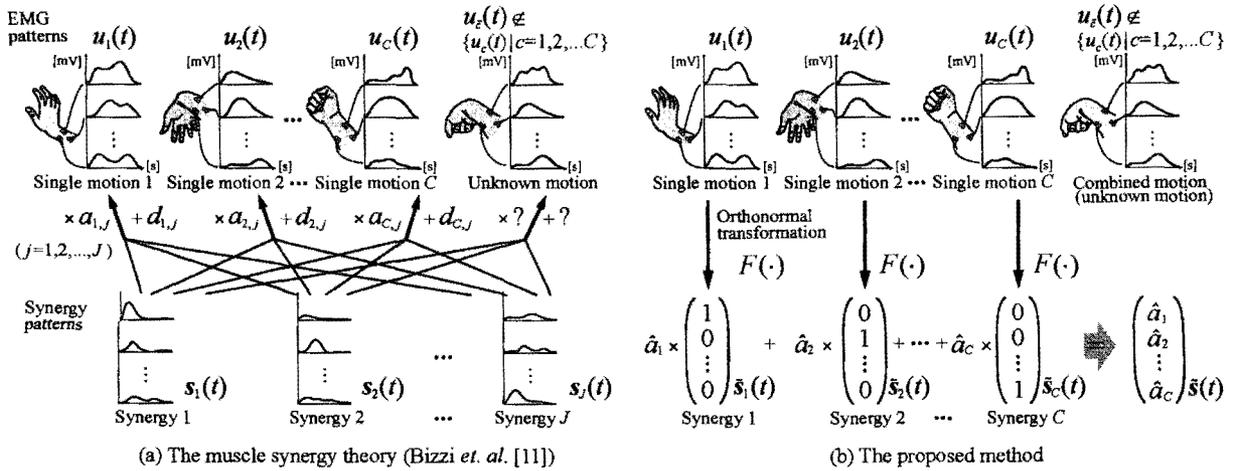


Fig. 1 Relationships between the muscle synergy theory by Bizzi et al. and the proposed method

シナジーと捉え、単一動作の筋シナジーの組み合わせによって未知の複合動作を推定するパターン識別法を提案する。提案法では、単一動作のEMGパターンからリカレントニューラルネットを用いて筋シナジーを抽出し、その組み合わせから「手を開きながら背屈する」といった複合動作の識別を実現する。単一動作のみを学習させて未知の動作である複合動作を表現することにより、未知動作のEMGパターンを取得する必要がなくなり、学習サンプル数・学習時間を増やすことなく対象とする動作数を増加することが可能となる。

以下、2章で本論文で定義するEMG信号の筋シナジーに基づく複合動作の表現法について説明し、3章で提案するパターン識別法と義手型マニピュレータの制御に提案法を適用する方法について述べる。そして、4章で筋シナジーを用いた動作識別実験および義手型マニピュレータの制御実験について説明する。

2. 筋シナジーパターンに基づく複合動作の表現法

筋シナジーとは、数多くの筋の活動を調整する構成単位を意味する。多くの自由度を有する身体運動は筋単位で制御されているのではなく、複数の筋シナジーを組み合わせることで実現されていると考えることができる。そのため、身体運動時の筋活動状態を計測し、そこから筋シナジーを抽出できれば、複雑かつ多自由度な身体運動の制御メカニズムを解明する一つの手段となり得るだろう。

そこでBizziらは、各動作時に発生するEMG信号の時系列パターンが特定の筋シナジーパターンの組み合わせで構成されると仮定し、次式を用いてEMGパターンを表現した[11]。

$$\mathbf{u}_c(t) = \sum_{j=1}^J a_{c,j} \mathbf{s}_j(t - d_{c,j}) \quad (1)$$

ここで、 $\mathbf{u}_c(t) \in \mathcal{R}^L$ は時刻 t における各動作時のEMGパターン、 $\mathbf{s}_j(t) \in \mathcal{R}^L$ ($j = 1, 2, \dots, J$) は筋シナジーパターン、 $a_{c,j}$ は重み係数、 $d_{c,j}$ は時間シフト、 L は計測に用いるチャンネル数であり、 $c = 1, 2, \dots, C$ は動作番号を示す。このとき、次式で表す誤差 E^2 が最小となる $\mathbf{s}_j(t), a_{c,j}, d_{c,j}$ を算出することで、

任意の $\mathbf{u}_c(t)$ を筋シナジーパターンを用いて分解・再構築可能である。

$$E^2 = \sum_{c=1}^C \sum_{t=1}^{T_c} \left\| \mathbf{u}_c(t) - \sum_{j=1}^J a_{c,j} \mathbf{s}_j(t - d_{c,j}) \right\|^2 \quad (2)$$

ただし、Bizziらの方法では新たなサンプルデータ $\mathbf{u}_c(t)$ が与えられるたびに $\mathbf{s}_j(t), a_{c,j}, d_{c,j}$ をあらためて導出しなければならない。そのため、 $\mathbf{s}_j(t)$ を求めても未知の動作に対応するEMGパターン $\mathbf{u}_c(t) (\notin \{\mathbf{u}_c(t) | c = 1, 2, \dots, C\})$ を再現・予測することは不可能である (Fig. 1 (a))。

そこで本論文では、 C 個の単一動作に対応する筋シナジーパターンを C 次元ベクトル空間の正規直交基底ベクトルに変換し、複合動作を C 個の基底ベクトルの線形和として表現することを考える。まず、EMGパターンの時系列 $\{\mathbf{u}(t), \mathbf{u}(t-1), \dots, \mathbf{u}(t-n)\} \in \mathcal{R}^{L \times (n+1)}$ を以下のように変換する。

$$\tilde{\mathbf{s}}(t) = F(\mathbf{u}(t), \mathbf{u}(t-1), \dots, \mathbf{u}(t-n)) \quad (3)$$

ただし、 $\tilde{\mathbf{s}}(t) = [\tilde{s}_1(t), \dots, \tilde{s}_C(t)]^T \in \mathcal{R}^C$ 、 $\sum_{j=1}^C \tilde{s}_j(t) = 1$ とする。また、 $F(\cdot)$ は j 番目の単一動作 $[\mathbf{u}_j(t), \mathbf{u}_j(t-1), \dots, \mathbf{u}_j(t-n)] \in \mathcal{R}^{L \times (n+1)}$ を、 j 番目の要素に1をとる単位ベクトル $\tilde{\mathbf{s}}_j(t) = F(\mathbf{u}_j(t), \mathbf{u}_j(t-1), \dots, \mathbf{u}_j(t-n)) \in \mathcal{R}^C$ に変換する関数である。以上の変換に基づき、複合動作の $\tilde{\mathbf{s}}(t)$ を C 個の単一動作の筋シナジーパターン $\tilde{\mathbf{s}}_j(t)$ の線形和と考え、次式で表現する。

$$\tilde{\mathbf{s}}(t) = \sum_{j=1}^C \hat{a}_j \tilde{\mathbf{s}}_j(t) \quad (4)$$

ここで \hat{a}_j は各単一動作に対する複合度を表す。 $\tilde{\mathbf{s}}_j(t)$ は正規直交系を構成するので、結局、

$$\tilde{\mathbf{s}}(t) = [\hat{a}_1, \dots, \hat{a}_j, \dots, \hat{a}_C]^T \quad (5)$$

が成立する。以上より、単一動作時の時系列EMGパターンを正規直交変換する関数 $F(\cdot)$ を獲得できれば、複合動作時の時系列EMGパターンを $F(\cdot)$ を用いて $\tilde{\mathbf{s}}(t)$ に変換することで、動

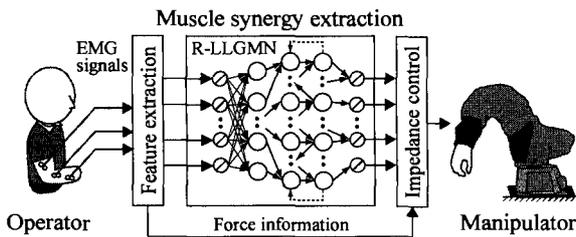


Fig. 2 Overview of the proposed pattern classification method of combined motions for a prosthetic arm

作を構成する各単一動作の複合度 \hat{a}_j を求めることが可能となる (Fig. 1 (b)). 本論文では, この関数 $F(\cdot)$ をリカレントニューラルネットを用いて学習的に構成する.

3. 筋シナジーパターンを利用した義手型マニピュレータの制御法

Fig. 2 に提案する複合動作識別法を義手型マニピュレータ [7] に適用したシステム概念図を示す. 提案する制御法は, EMG 信号の特徴抽出部, 各単一動作に対する筋シナジー抽出部, 義手型マニピュレータのインピーダンス制御部から構成される. 特徴抽出部では, 計測した EMG 信号を時系列筋電パターンに変換し, 筋シナジー抽出部では, リカレントニューラルネットを利用した時系列筋電パターンの正規直交変換によって筋シナジーを抽出する. そして, インピーダンス制御部では, 抽出した筋シナジーからインピーダンスモデルに基づく動作推定を行い, マニピュレータ制御を行う. 以下に詳細を示す.

3.1 特徴抽出部

特徴抽出部では, 操作者の腕に装着した L 対の電極から計測した EMG 信号を A/D 変換 (サンプリング周波数 f_s [Hz]) する. 計測信号は各チャンネルごとに全波整流したあと, 2 次のデジタルバタワースフィルタ (カットオフ周波数 f_c [Hz]) にて平滑化し, 得られる時系列信号を $EMG_l(t)$ ($l = 1, \dots, L$) とする. そして, 操作者の筋力情報 $F_{EMG}(t)$ を次式のように定義する.

$$F_{EMG}(t) = \frac{1}{L} \sum_{l=1}^L \frac{|EMG_l(t) - \overline{EMG_l^{st}}|}{EMG_l^{max} - \overline{EMG_l^{st}}} \quad (6)$$

ここで $\overline{EMG_l^{st}}$ は安静時における $EMG_l(t)$ の時間平均, EMG_l^{max} は事前に設定した各チャンネルの $EMG_l(t)$ の最大随意筋収縮時の値である. $F_{EMG}(t)$ があらかじめ設定した動作判定閾値 F_{th} より大きくなると, 動作中と判定する.

また, $EMG_l(t)$ の全チャンネルの和が 1 となるように次式を用いて正規化したものを $\mathbf{u}(t) = [u_1(t), u_2(t), \dots, u_L(t)]^T \in \mathbb{R}^L$ として操作者の動作推定を行う.

$$u_i(t) = \frac{|EMG_i(t) - \overline{EMG_i^{st}}|}{EMG_i^{max} - \overline{EMG_i^{st}}} \times \sum_{l=1}^L \frac{EMG_l^{max} - \overline{EMG_l^{st}}}{|EMG_l(t) - \overline{EMG_l^{st}}|} \quad (7)$$

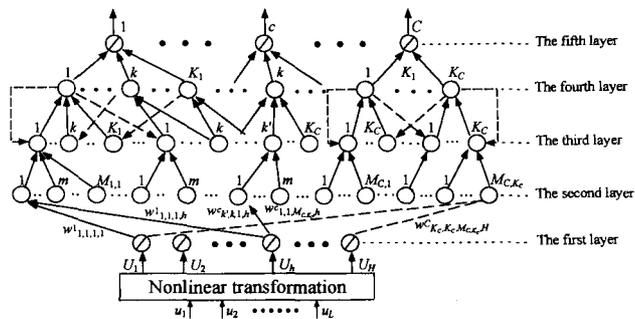


Fig. 3 Structure of the R-LLGMN [12]

3.2 筋シナジー抽出部

筋シナジー抽出部では, 単一動作時の時系列筋電パターンを正規直交化するため, 辻らによって提案されたリカレントニューラルネットワーク Recurrent Log-Linearized Gaussian Mixture Network [12] (以下, R-LLGMN と略記) を用いる. Fig. 3 に R-LLGMN の構造を示す. このネットワークは, 統計モデルの一つである混合正規分布モデルと, 動的な確率モデルの一つである隠れマルコフモデルを内包しており, 操作者の動作の時系列特性を考慮した学習が可能である. R-LLGMN を利用して操作者の EMG 信号と単一動作の関係を学習することで, 使用者の EMG 信号の時系列パターンから関数 $F(\cdot)$ を獲得できる.

R-LLGMN ではまず, 入力ベクトル $\mathbf{u}(t)$ ($t = 1, 2, \dots, T_d$; T_d は入力データの時系列長) を次式に従って非線形変換し, 新たな入力ベクトル $\mathbf{U}(t)$ を得る.

$$\mathbf{U}(t) = [1, \mathbf{u}(t)^T, u_1(t)^2, u_1(t)u_2(t), \dots, u_1(t)u_L(t), u_2(t)^2, u_2(t)u_3(t), \dots, u_2(t)u_L(t), \dots, u_L(t)^2]^T \quad (8)$$

第 1 層は $H = 1 + L(L+3)/2$ 個のユニットから構成される. 出力関数には恒等関数を用いており, 入力 $U_h(t)$ ($h = 1, 2, \dots, H$) を ${}^{(1)}O_h(t)$ として出力する.

次に, 第 2 層のユニット $\{c, k, k', m\}$ ($c = 1, \dots, C$; $k, k' = 1, \dots, K_c$; $m = 1, \dots, M_{c,k}$) は, 第 1 層のユニットの出力に重み係数 $w_{k',k,m,h}^c$ が掛け合わされたものを入力として受け取る. ただし, K_c は隠れマルコフモデルの状態数に対応するパラメータ, $M_{c,k}$ は単一動作 c , 状態 k に対応する混合正規分布モデルのコンポーネント数を表す. 第 2 層の入出力関係は,

$${}^{(2)}I_{k',k,m}^c(t) = \sum_{h=1}^H {}^{(1)}O_h(t) w_{k',k,m,h}^c \quad (9)$$

$${}^{(2)}O_{k',k,m}^c(t) = \exp\left({}^{(2)}I_{k',k,m}^c(t)\right) \quad (10)$$

となる.

第 3 層のユニット $\{c, k, k'\}$ への入力は, 第 2 層のユニット $\{c, k, k', m\}$ ($m = 1, \dots, M_{c,k}$) の出力を統合したものである. また, 入力に 1 時刻前の第 4 層の出力を乗じた値が第 3 層の出力となる. 入出力関係は,

$${}^{(3)}I_{k',k}^c(t) = \sum_{m=1}^{M_{c,k}} {}^{(2)}O_{k',k,m}^c(t) \quad (11)$$

$${}^{(3)}O_{k',k}^c(t) = {}^{(4)}O_{k'}^c(t-1) {}^{(3)}I_{k',k}^c(t) \quad (12)$$

となる。ただし、初期状態は ${}^{(4)}O_{k'}^c(0) = 1.0$ とする。

さらに第4層の入出力 ${}^{(4)}I_{k'}^c(t)$, ${}^{(4)}O_{k'}^c(t)$ は、

$${}^{(4)}I_{k'}^c(t) = \sum_{k=1}^{K_c} {}^{(3)}O_{k',k}^c(t) \quad (13)$$

$${}^{(4)}O_{k'}^c(t) = \frac{{}^{(4)}J_{k'}^c(t)}{\sum_{c'=1}^C \sum_{k'=1}^{K_{c'}} {}^{(4)}I_{k'}^{c'}(t)} \quad (14)$$

で与えられる。

最後に、第5層のユニット c は第4層の K_c ユニット $\{c, k\}$ ($k = 1, \dots, K_c$) の出力を用いる。入出力関係は、

$${}^{(5)}I^c(t) = \sum_{k=1}^{K_c} {}^{(4)}O_{k'}^c(t) \quad (15)$$

$${}^{(5)}O^c(t) = {}^{(5)}I^c(t) \quad (16)$$

となる。この出力 ${}^{(5)}O^c(t)$ が単一動作 c に対する筋シナジーパターンの要素 $\tilde{s}_c(t)$ となる。

このように R-LLGMN は、第3層と第4層の間にリカレント結合を有し、1時刻前の出力を考慮することができる。そのため、各パターンの時系列的なつながりを情報として利用でき、異動作間の重複が大きい EMG 信号の分布に対しても高精度の識別が可能である。また、第1層と第2層の間の重み係数を学習的に調節することで、単一動作に対する事後確率を混合正規分布に基づいてモデル化できる。

R-LLGMN の学習には、単一動作に対する正規化後の EMG 信号ベクトル $\mathbf{u}(t)$ のみを学習に用い、それぞれ M 個の時系列信号 ($N = M \times C$) を学習データとする。ここで、 n 番目の学習データ $\mathbf{u}(t)^{(n)}$ ($t = 1, 2, \dots, T_i$; T_i は学習データの時系列長) に対応する教師ベクトル $\mathbf{Y}^{(n)} = [Y_1^{(n)}, \dots, Y_c^{(n)}, \dots, Y_C^{(n)}]^T$ ($n = 1, \dots, N$) が与えられた場合について考える。 $Y_c^{(n)}$ は、入力した $\mathbf{u}(t)^{(n)}$ がクラス c に属するとき $Y_c^{(n)} = 1$ 、それ以外は $Y_c^{(n)} = 0$ ($\hat{c} \neq c$) とする。学習データに対するネットワークの評価関数 J は、

$$J = \sum_{n=1}^N J_n = - \sum_{n=1}^N \sum_{c=1}^C Y_c^n \log {}^{(5)}O^c(T)^{(n)} \quad (17)$$

と定義し、これを最小化、すなわち対数尤度を最大化するように学習を行う。ただし、 ${}^{(5)}O^c(T)^{(n)}$ は入力ベクトル $\mathbf{u}(t)^{(n)}$ に対する時刻 T での出力を意味している。重みの更新には、通時誤差逆伝播学習法 (BPTT) を用いる [12]。この方法により、各単一動作時の EMG 信号ベクトル $\mathbf{u}(t)$ が学習後の R-LLGMN に新たに入力された場合、R-LLGMN はその単一動作に対する要素のみを1、その他を0にとる単位ベクトルを出力することとなる。そのため、R-LLGMN を用いて式 (3) を満たす変換が実現でき、各単一動作に対する筋シナジーパターンを正規直交基底ベクトルとして抽出可能となる。

また、学習の収束時間を待つことになる操作者の精神的負担を少しでも軽減することを目的として、Zak [14] が提案したターミナルアトラクタ (Terminal Attractor) を学習則に導入し [5]、収束時間の上限値を設定可能としている。

3.3 インピーダンス制御部

ここでは、筋シナジー抽出部から得た筋シナジー $\tilde{\mathbf{s}}(t)$ を利用したマニピュレータ制御法について述べる。

巧みな作業を実現する人間の手の運動は、剛性、粘性、慣性要素からなるインピーダンスモデルを使って表現することができる [15]。したがって、人間の前腕部のインピーダンス特性を義手制御に応用できれば、より人間の手に近い前腕部の運動を実現できる可能性がある。そこで、本論文では Q リンクを有するマニピュレータの運動方程式を次式により定義する。

$$\mathbf{M}(\boldsymbol{\theta})\ddot{\boldsymbol{\theta}} + \mathbf{H}(\dot{\boldsymbol{\theta}}, \boldsymbol{\theta}) + \mathbf{G}(\boldsymbol{\theta}) = \boldsymbol{\tau} \quad (18)$$

$$\boldsymbol{\tau} = \mathbf{K}(\boldsymbol{\alpha})(\boldsymbol{\theta}^* - \boldsymbol{\theta}) - \mathbf{B}(\boldsymbol{\alpha})\dot{\boldsymbol{\theta}} \quad (19)$$

ここで、 $\boldsymbol{\theta} = [\theta_1, \theta_2, \dots, \theta_Q]^T \in \mathcal{R}^Q$ はマニピュレータの関節角度、 $\mathbf{M}(\boldsymbol{\theta}) \in \mathcal{R}^{Q \times Q}$ はマニピュレータの慣性行列、 $\mathbf{H}(\dot{\boldsymbol{\theta}}, \boldsymbol{\theta}) \in \mathcal{R}^Q$ は遠心力とコリオリ力に関する項、 $\mathbf{G}(\boldsymbol{\theta}) \in \mathcal{R}^Q$ は重力項、 $\boldsymbol{\tau} \in \mathcal{R}^Q$ は関節トルクベクトルである。また、 $\mathbf{K}(\boldsymbol{\alpha})$, $\mathbf{B}(\boldsymbol{\alpha}) \in \mathcal{R}^{Q \times Q}$ は各関節の粘弾性 $K_q(\boldsymbol{\alpha})$, $B_q(\boldsymbol{\alpha})$ ($q = 1, 2, \dots, Q$) を要素とする対角行列で、以下のように定義する。

$$K_q(\boldsymbol{\alpha}) = k_{q,1}\alpha^{k_{q,2}} + k_{q,3} \quad (20)$$

$$B_q(\boldsymbol{\alpha}) = b_{q,1}\alpha^{b_{q,2}} + b_{q,3} \quad (21)$$

ここで、 q はマニピュレータの関節番号である。 α は筋活動レベルを表し、筋力情報 F_{EMG} をもとに次式により定義する。

$$\alpha = \frac{F_{EMG}}{\sum_{j=1}^C F_{EMG}^j \hat{a}_j} \quad (22)$$

ただし、 F_{EMG}^j は事前に設定した各単一動作 j ($j = 1, 2, \dots, C$) に対する最大随意筋収縮時の F_{EMG} を表す。 α は操作者が動作を行っているときの筋の収縮レベル ($0 \leq \alpha \leq 1$) と見なすことができる。また、 $\boldsymbol{\theta}^* = [\theta_1^*, \theta_2^*, \dots, \theta_Q^*]^T$ は平衡角度ベクトルであり、関節自由度 q に対応する単一動作 j の複合度 \hat{a}_j を用いて次式で定義する。

$$\theta_q^* = \begin{cases} \theta_q^{max} & (\hat{a}_j \geq a_{th}^{max}) \\ \hat{a}_j \times (\theta_q^{max} - \theta_q) & (a_{th}^{min} \leq \hat{a}_j < a_{th}^{max}) \\ \theta_q & (\hat{a}_j < a_{th}^{min}) \end{cases} \quad (23)$$

ただし、 a_{th}^{max} は最大関節角度に対応する複合度の閾値、 a_{th}^{min} は制御に用いない単一動作の不感帯を表す閾値、 θ_q^{max} はマニピュレータ関節の最大平衡角度であり、 θ_q はマニピュレータ各関節の回転角度である。複合度 \hat{a}_j は操作者の動作を反映した値であり、式 (23) により対応する関節の θ_q^* が変動し駆動力 τ_q が発生するため、その駆動力に基づいてマニピュレータを制御することが可能となる。

4. 実験

提案法の有効性を確認するために、まず筋シナジーを用いた

識別実験を行い、各動作の推定精度の検証を行った。次に提案法を義手型ロボットマニピュレータ [7] に応用した制御実験を行った。両実験において、EMG 信号の計測には GE marquette 製の Ag 電極 (SEB120) と生体信号計測用装置 (多用途テレメータサイナクト MT11 (日本電気 (株) 製)) を使用し、双対電極の中央間隔を約 2 [cm] として計測を行った。なお EMG 信号の特徴抽出処理では、サンプリング周波数を $f_s = 1,000$ [Hz]、ローパスフィルタのカットオフ周波数を $f_c = 1$ [Hz] と設定した。

4.1 筋シナジーを利用した動作識別実験

4.1.1 方法

R-LLGMN を用いて同定した関数 $F(\cdot)$ がどの程度操作者の動作を反映しているか検証するために、筋シナジー抽出部で求めた筋シナジー $\hat{s}(t)$ を用いて識別実験を行った。動作の決定は、各動作に対応する基準パターン \hat{s} を用いて行う。ここで \hat{s} は、対応する動作が単一動作の場合、その動作に対応する要素が 1 の単位ベクトルとし、 N_s 個の単一動作からなる複合動作の場合には、単一動作に対応する各要素に $1/N_s$ を持つベクトルと定義する。この $\hat{s}(t)$ と \hat{s} とのベクトル間距離 $d_g(t)$ を算出する。

$$d_g(t) = \sqrt{\sum_{j=1}^C (\hat{s}_j(t) - \hat{s}_j^{(g)})^2} \quad (g = 1, \dots, G) \quad (24)$$

ここで、 G は単一動作、複合動作を含む全動作数である。この $d_g(t)$ が最小となる動作 g を意図した動作として識別を行った。

被験者に装着する電極数は右前腕に 4 対 (Ch. 1: 尺側手根伸筋, Ch. 2: 尺側手根屈筋, Ch. 3: 橈側手根伸筋, Ch. 4: 橈側手根屈筋), 右上腕に 2 対 (Ch. 5: 上腕三頭筋, Ch. 6: 上腕二頭筋) の計 6 対 ($L = 6$) とした。ただし、これらの電極の装着位置に関しては、ある程度自由に装着しても提案法に用いているニューラルネットにより適応が可能である [13]。各単一動作の学習データ数は 1, 筋力情報の閾値 F_{th} は 0.18 とした。また、 T_l, T_d はそれぞれ 20 [ms], 6 [ms] とした。なお、学習データ数およびデータ長 T_l, T_d に関しては従来研究 [12] [13] によって様々な議論がなされており、本論文ではこれらを参考にしてパラメータを決定した。しかしながら、各パラメータには個人差が含まれると考えられるため、本手法における複合動作の識別率との関連性のさらなる調査が今後必要である。

ここで、全動作数は $G=18$ とし、識別対象動作は単一動作を 6 動作 (1. 開き, 2. 握り, 3. 背屈, 4. 掌屈, 5. 回内, 6. 回外), $N_s = 2$ の複合動作を 12 動作 (7. 開きと回内, 8. 握りと回内, 9. 背屈と回内, 10. 掌屈と回内, 11. 開きと回外, 12. 握りと回外, 13. 背屈と回外, 14. 掌屈と回外, 15. 開きと背屈, 16. 握りと背屈, 17. 開きと掌屈, 18. 握りと掌屈) とした。このとき、六つの単一動作のうち開きと握り、背屈と掌屈、および回内と回外は互いに拮抗する動作であり、同時に起こりえないため、結果として \hat{s} は Fig. 4 に示す正八面体の中心を原点とする三次元ベクトル空間上に配置されることが考えられる。ただし、図中の \bullet が単一動作、 \circ が複合動作に対応する。なお被験者は男子学生 5 名 (A~D: 24 歳, E: 22 歳) とし、被験者には 1 時間程度の練習後、1~18 の識別動作を順に行わせた。

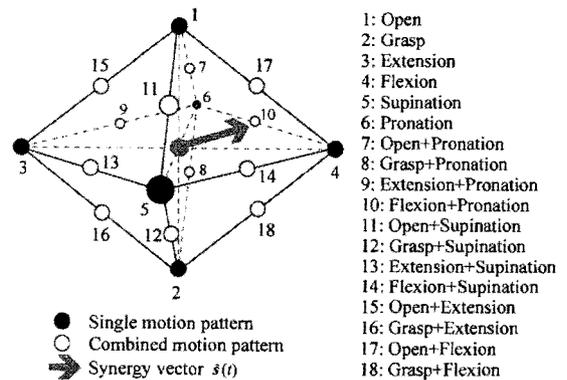


Fig. 4 A vector space for motion pattern discrimination

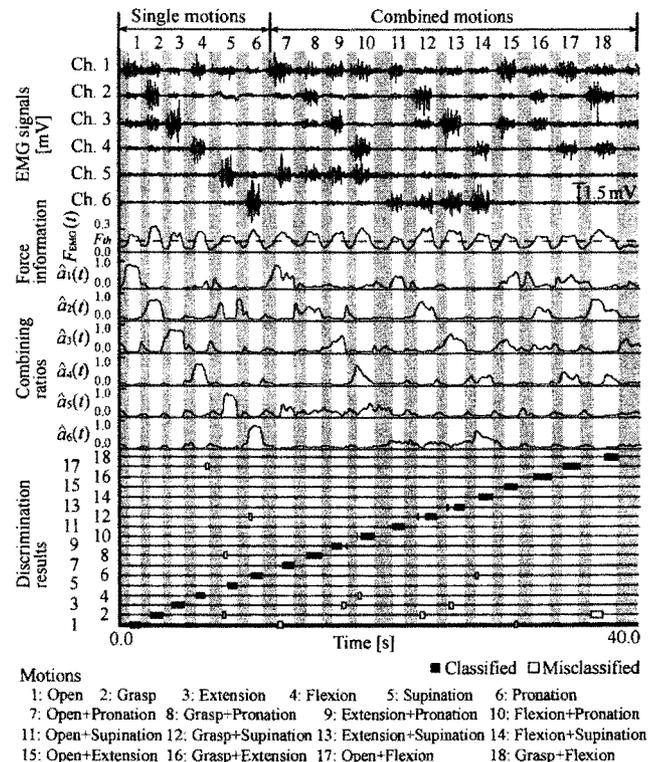


Fig. 5 An example of the discrimination results with subject A

4.1.2 結果

被験者 A による実験結果の一例を Fig. 5 に示す。上から順に EMG 信号、筋力情報、複合度、識別結果を示している。図中の陰影のない区間は動作発生区間を表している。図より、学習を行った単一動作時は比較的正しく識別が行えているのに対し、未学習動作である複合動作時に誤識別が多く生じていることが分かる。これは単一動作のみを学習している影響や、複合動作時にその動作を構成する二つの単一動作のうち一方が先に発生し、その後、動作が複合したことが原因と考えられる。

各動作を順に 5 試行を行った時の単一動作と複合動作の識別率を Fig. 6 に示す。ここで、前述のように複合動作時には、対応する単一動作のうち一方が先に発生すると考えられる。そのため、複合動作立ち上がり部分において単一動作と識別された場

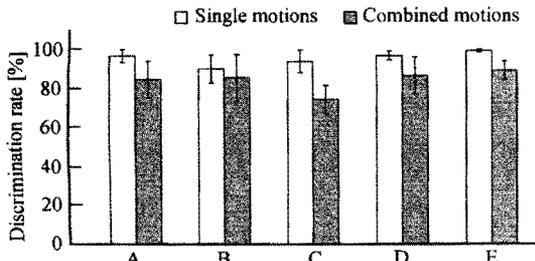


Fig. 6 Discrimination rates using the proposed method

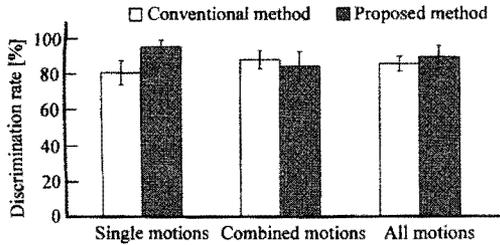


Fig. 7 Comparison of discrimination rates using the proposed and conventional methods

合は識別率の計算には含まなかった。図では、単一動作のみの学習による影響から、単一動作に比べ複合動作の識別率が低くなっているが、未学習である複合動作を80%程度で識別できていることが分かる。全被験者の平均識別率は、六つの単一動作が $95.2 \pm 3.91\%$ 、12の複合動作が $84.0 \pm 8.6\%$ であった。

次に、複合動作を含めた全18動作を学習する従来法[12]を用いた場合の全動作に対する識別率を算出し、提案法との比較を行った。Fig. 7に比較結果を示す。図は全被験者5名の計測データに対する平均識別率を示しており、全動作を学習する従来法では、全18動作に対する複合度 \hat{a}_i のうち最も高い値を示す動作を決定動作とした。また、 T_l 、 T_d ともに1[ms]とし、その他の条件は提案法と同じとした。図から、6動作のみを学習した提案法により、18動作すべてを学習した従来法とほぼ同程度の識別率が得られていることが分かる。また、従来法では、対象とする動作数が多くなるとEMG信号パターンが似通った動作に対して識別があいまいになる傾向があり、単一動作の識別率が低下している。全動作に対する平均識別率はそれぞれ、従来法が $85.5 \pm 4.14\%$ 、提案法が $89.2 \pm 6.33\%$ であった。従来法と提案法を用いた場合の識別率をt検定を用いて比較した結果、両者に有意な差は得られなかった。このことから、提案法は従来法のように18動作すべてを学習する必要がなく、6動作のみの学習で同程度の識別制度を実現できることが明らかになった。以上より、単一動作の筋シナジーを利用した識別を行うことで、単一動作のみの学習によって未知の複合動作をある程度、識別できることを確認した。

4.2 マニピュレータ制御実験

次に、提案する複合動作識別法が義手型ロボットマニピュレータ[7]の制御に応用可能であることを示すための制御実験を行った。前述のように、義手型マニピュレータなどの制御を対象とする場合には、制御対象動作数の増加に伴って学習サンプル数や学習時間が増加してしまうという問題がある。提案法では単

Table 1 Impedance parameters used in the experiments

Joint, q	Motion (j)	$k_{q,1}$ [Nm/rad]	$k_{q,2}$	$k_{q,3}$ [Nm/rad]
1	Open (1) / Grasp (2)	0.90	0.6	0.3
2	Extension (3) / Flexion (4)	32.8	0.6	3.2

一動作時のEMG信号のみを学習させることで複合動作の識別が可能であるため、学習サンプル数・学習時間を増加させることなく対象動作数を増加できると考えられる。実験では被験者を上肢切断者(49歳)とし、電極数は右前腕部に4対($L=4$; Ch. 1:尺側手根伸筋, Ch. 2:尺側手根屈筋, Ch. 3:橈側手根伸筋, Ch. 4:橈側手根屈筋)とした。全動作数は $G=8$ とし、筋シナジーの閾値はそれぞれ $a_{th}^{max} = 0.4$ 、 $a_{th}^{min} = 0.1$ とした。識別対象動作は単一動作を4動作(1. 開き, 2. 握り, 3. 背屈, 4. 掌屈)、 $N_s = 2$ の複合動作を4動作(5. 開きと背屈, 6. 握りと背屈, 7. 開きと掌屈, 8. 握りと掌屈)とした。また、その他の条件は4.1節と同じとした。なお、提案法には単一動作4動作のみを学習させ、全8動作を学習させた従来法[12]と識別率の比較を行った。

ここで、義手型マニピュレータはMove Master RM-501((株)三菱電機製)を利用した上腕部と超音波モータ駆動型動力義手((株)今仙技術研究所製)[16]から構成される。実験では、マニピュレータの2自由度(手の開閉, 背屈/掌屈)を用いて識別対象動作を実現した($Q=2$)。また、制御マニピュレータの関節に存在する粘性摩擦を考慮して $B_q(\alpha) = 0$ とし、関節剛性 $K_q(\alpha)$ に含まれるパラメータはTable 1に示す値とした。

Fig. 8に各時刻におけるマニピュレータ制御時の様子を、Fig. 9に実験結果の一例を示す。Fig. 9は上から順にEMG信号、筋力情報、筋活動レベル、複合度、マニピュレータ関節角度を示している。図中の陰影のない区間が動作発生区間である。図では単一動作時に二つの関節が動作している部分も見られるが、図では単一動作時に二つの関節が動作している部分も見られるが、複合動作を被験者が随意的に制御できていることが分かる。このとき、全動作に対する識別率は提案法が98.8%となり、全動作を学習させた従来法が97.9%となった。以上の結果から、提案システムを用いることにより、単一動作のみの学習によって未学習動作である複合動作のマニピュレータ制御が可能であることを確認した。

5. ま と め

本論文では、EMG信号を利用した筋シナジーによる複合動作のパターン識別手法を提案した。提案法では、単一動作時に計測したEMG信号をリカレントニューラルネットワークであるR-LLGMNを用いて正規直交基底ベクトルに変換する。そして、複合動作を基底ベクトルの線形和として表現することで、学習を行っていない未知の複合動作の識別が可能となる。

識別実験では、5名の被験者から計測したEMG信号から筋シナジーを抽出し、単一動作の6動作の学習によって、未学習動作である12個の複合動作の識別を行った。その結果、単一動作は $95.2 \pm 3.91\%$ 、複合動作は $84.0 \pm 8.6\%$ 、全動作は

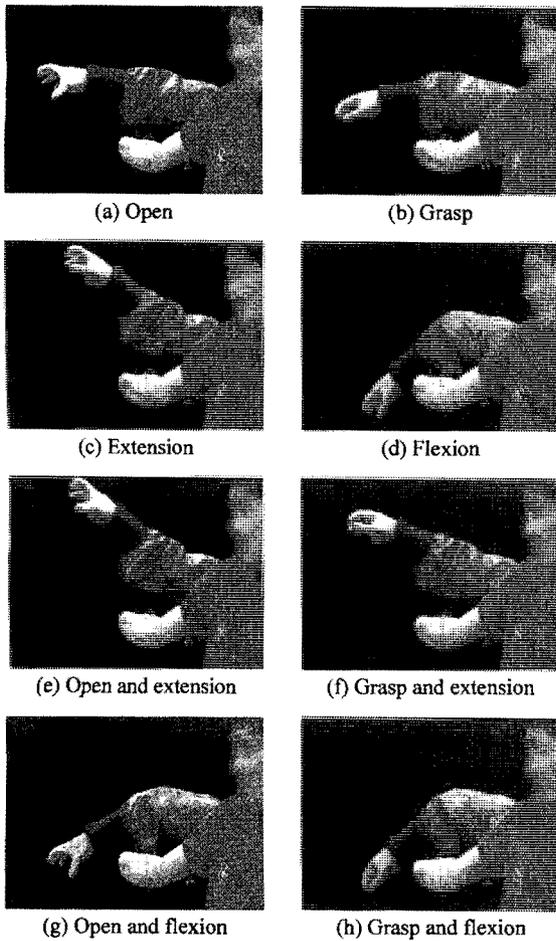


Fig. 8 An amputee controlling the manipulator

89.2 ± 6.33%の平均識別率で被験者の動作を識別できることを示した。また、全18動作をR-LLGMNによって学習させた場合は全動作に対する平均識別率が85.5 ± 4.14%であったことから、提案法を用いて単一動作と複合動作を精度良く識別できることを確認した。さらに、上肢切断者による義手型マニピュレータ制御実験により、被験者が随意的に単一動作と複合動作を制御可能なことを確認し、提案システムの有効性を示した。

ただし、提案法にはR-LLGMNに用いる入力パターンの時系列長 T_l , T_d や学習データ数、動作発生に用いる閾値など、事前に設定しなければならないパラメータがいくつか存在する。今後は、これらのパラメータを義手操作の練習時に自動的に決定するアルゴリズムの検討が必要であると考えられる。また、対象とする動作数や被験者数を増加させるとともに、ISEKの筋電位計測基準[17]に基づいた計測を実施し、より詳細に提案法の有効性を検証する必要がある。なお本論文では操作者のEMG信号のパターン識別に有効な筋シナジーの抽出を行ったが、逆にマニピュレータ制御に有効なシナジーを先に定義し、このシナジーを操作者が選択・実行することによってマニピュレータ制御を実現するというアプローチも考えられる。さらに提案法では、操作者の熟練度が動作推定精度や制御可能な動作数に影響を与えるため、実用的なシステムの開発には操作者のEMGパターン生成能力を効果的に訓練できる制御システムの構築が

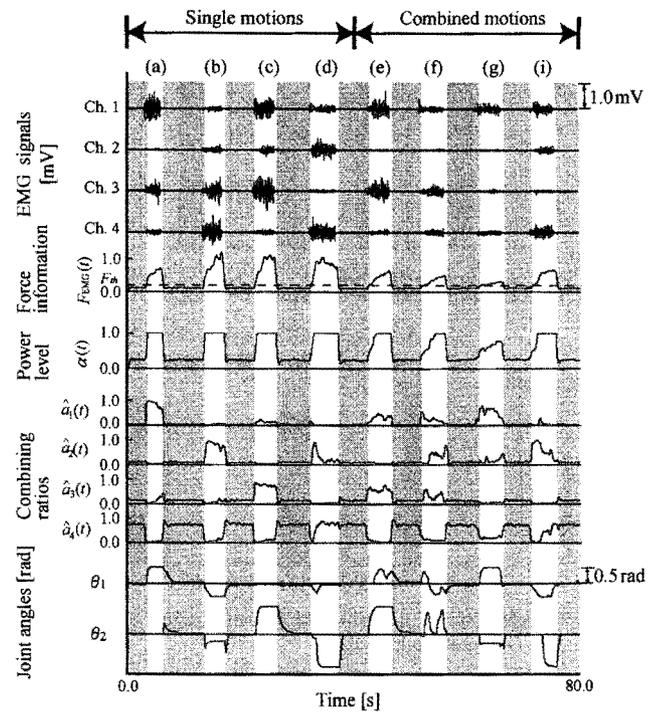


Fig. 9 An example of experimental results of manipulator control

必要であろう。

参考文献

- [1] D. Graupe, J. Magnussen and A.A.M. Beex: "A microprocessor system for multifunctional control of upper limb prostheses via myoelectric signal identification," IEEE Trans. Automat. Contr., vol.AC-23, pp.538-544, 1978.
- [2] S. Lee and G.N. Saridis: "The control of a prosthetic arm by EMG pattern recognition," IEEE Trans. Automat. Contr., vol.AC-29, pp.290-302, 1984.
- [3] 伊藤宏司, 辻敏夫: "人間-義肢系の力制御と位置制御", バイオメカニズム, vol.8, pp.275-286, 1986.
- [4] G.C. Chang, W.J. Kang, J.J. Luh, C.K. Cheng, J.S. Lai, J.J. Chen and T.S. Kuo: "Real-time implementation of electromyogram pattern recognition as a control command of man-machine interface," Medical Engineering & Physics, vol.18, no.7, pp.529-537, 1996.
- [5] T. Tsuji, O. Fukuda, H. Ichinobe and M. Kaneko: "A Log-Linearized Gaussian Mixture Network and Its Application to EEG Pattern Classification," IEEE Trans. on Systems, Man, and Cybernetics-Part C: Applications and Reviews, vol.29, no.1, pp.60-72, 1999.
- [6] W. Yu, H. Yamaguchi, H. Yokoi, M. Maruishi, Y. Mano and Y. Kakazu: "EMG automatic switch for FES control for hemiplegics using artificial neural network," Robotics and Autonomous Systems, vol.40, no.2-3, pp.213-224, 2002.
- [7] 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, vol.19, no.2, pp.210-222, 2003.
- [8] 辻敏夫, 吉久智之, 島圭介: "加速度センサを利用した義手型マニピュレータの筋音制御", 日本ロボット学会誌, vol.25, no.6, pp.874-880, 2007.
- [9] H. Takase: A study on information constraining coordination of the respiratory system, Theses for the doctoral degree of Graduate School of Human Sciences, Waseda Univ., 2003.

- [10] C.S. Sherrington: *The integrative action of the nervous system*. Yale University Press, 1961.
- [11] A. d'Avella, P. Saltiel and E. Bizzi: "Combinations of muscle synergies in the construction of a natural motor behavior," *Nature Neuroscience*, vol.6, no.3, pp.300-308, 2003.
- [12] T. Tsuji, N. Bu, O. Fukuda and M. Kaneko: "A recurrent log-linearized Gaussian mixture network," *IEEE Transactions on Neural Networks*, vol.14, no.2, pp.304-316, 2003.
- [13] 辻敏夫, 福田修, 村上満, 金子真: "ニューラルネットを利用したEMG制御型ポインティングデバイス", 計測自動制御学会論文集, vol.37, no.5, pp.425-431, 2001.
- [14] M. Zak: "Terminal Attractors for Addressable Memory in Neural Networks," *Physics Letters A*, vol.133, pp.18-22, 1988.
- [15] T. Tsuji, P. Morasso, K. Goto and K. Ito, "Human Hand Impedance Characteristics during Maintained Posture in Multi-Joint Arm Movements," *Biological Cybernetics*, vol.72, pp.475-485, 1995.
- [16] 伊藤宏司, 永岡英明, 辻敏夫, 加藤厚生, 伊藤正美: "超音波モータを用いた3自由度前腕筋電義手", 計測自動制御学会論文集, vol.27, no.11, pp.1281-1289, 1991.
- [17] R. Merletti: "Standards for reporting EMG data," *Journal of Electromyography and Kinesiology*, vol.9, pp.III-IV, 1999.



辻 敏夫 (Toshio Tsuji)

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、同助教授を経て、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(1986)、論文賞(2002)、バイオメカニズム学会論文賞(1990)、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。(日本ロボット学会正会員)



島 圭介 (Keisuke Shima)

2005年広島大学工学部第二類卒業。2007年同大学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)。日本医療機器学会論文賞(2008)、Honorable Mention awarded for the student paper presented at 2008 IEEE International Conference on Systems, Man and Cyberneticsなどを受賞。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、計測自動制御学会、電子情報通信学会などの会員。



村上洋介 (Yosuke Murakami)

2005年広島大学工学部第二類卒業。2007年同大学大学院工学研究科博士課程前期修了。同年日東電工株式会社に勤務、現在に至る。広島大学在学中は筋電信号を利用した義手型マニピュレータの制御法に関する研究に従事。