筋電義手制御を目的とした簡潔なニューラルネットによる前腕の動作識別

Human Forearm Motion Discrimination by Concise Neural Network for Myoelectric Hand Control

木曾 淳(学生会員), 関 弘和(正会員), 南方 英明(非会員), 多田隈 進(非会員)

Atsushi Kiso, Hirokazu Seki, Hideaki Minakata and Susumu Tadakuma

Abstract

This paper describes a human forearm motion discrimination method by the concise neural network for myoelectric hand control. In the conventional studies, the neural network is often used to estimate the motion intention by the myoelectric potential and realize the high discrimination precision. However, the feature extraction processing of the myoelectric potential and the neural network structure tends to become complicated. Therefore, they are not suitable due to the calculation amount increase because the myoelectric hand system is difficult to be equipped with a high-speed CPU. The purpose of this study is to obtain the high discrimination precision without complicating the neural network structure. This study proposes the optimization method of "input data" to Neural Network and "data for learning". Therefore, the total system will be concise and inexpensive. In addition, this study proposes the robust relearning method against the myoelectric potential change by the muscle fatigue. Some experiments on the myoelectric hand simulator show the effectiveness of the proposed motion discrimination method.

Key Words

myoelectric potential, myoelectric hand, motion discrimination, neural network,
concise and inexpensive system

1. はじめに

本論文は、筋電義手制御を目的とした簡潔なニューラルネットによる前腕の動作識別法を提案するものである。

安全管理や事故予防が十分認識されている現代社会においても、交通事故や災害などによって腕を失っている人は国内外に数多くいる。そのような人たちは何らかの義手を使用しているが、そのほとんどは装飾を目的とした内部に動力を持たないものであり、能動的に駆動するものは現在あまり使用されていない。それでは日常生活動作(ADL)を行うのに不便が生じてしまう場合がある。そこで見た目だけでなく自分の

意思を反映して動く失った腕と同等の機能を持つ義手の開発が期待されている。そのような義手の制御信号として以前から筋電図(electromyogram : EMG)が着目されており、数多くの研究・開発が行われている。

筋電図とは、筋線維が運動指令を受けたときに発生させる筋電位(myoelectric potential : ME potential)を記録・表示したものである。したがって、筋電図は運動指令情報を含んでいる。この筋電図から切断者の運動意思を推定し制御するには、高精度のパターン解析処理が必要になり、また、個人差や環境に左右されない強固な信号処理を実現するには、高い認識能力が必要になる。そのため今まで研究では、非線形な関係を学習できる能力と汎化能力による高い耐ノイズ性からニューラルネットが多く利用されてきた。主な手法としては、筋電位の周波数情報から誤差逆伝播法を使つての動作識別¹⁾、2つの異なる構成のニューラルネットを組み合わせる動作識別²⁾、統計構造に基づいたニューラルネットを新たに構築しての動作識別³⁾⁴⁾、再構成可能ハードウェアと

2008 年 3 月 18 日受理

2008 年 10 月 7 日最終原稿受理

千葉工業大学 工学部 電気電子情報工学科

〒275-0016 千葉県習志野市津田沼 2-17-1

Chiba Institute of Technology, Department of Electrical,
Electronics and Computer Engineering,

2-17-1 Tsudanuma, Narashino-shi, Chiba, 275-0016, Japan

Fig. 1 System schema.

遺伝的アルゴリズムによる動作識別⁵⁾、6×16チャンネルの電極からモンテカルロ法を用いてチャンネルを選択しての動作認識⁶⁾、特徴量抽出を高速フーリエ変換で行い動作識別を主成分分析とニューラルネットで行う⁷⁾ものなどがある。一般的に従来の方法では、識別精度の向上のために筋電位の特徴抽出処理やニューラルネットの構造が複雑になる傾向がある。それでは学習や出力パターンを算出するための計算量が多くなってしまい、応答性を良くしようとする演算能力の高い処理装置が必要になり消費電力や価格の上昇に繋がる。またニューラルネットは、基本的に中間層のニューロン数を少なくすると汎化能力が増し、未学習のデータに対しても識別精度が高くなる。これは、誤差逆伝播法を用いる多層構造ネットワークで中間層のニューロンと重みを削減することで汎化能力が向上することが確認されている⁸⁾。

そこで本研究では、ニューラルネットの構造を複雑化せず高い識別精度を獲得できるようにすることを目的とする。その方法として、ニューラルネットへの「入力データ」と「学習用データ」の最適化法について検討し識別精度の確認をする。また、使用中に筋疲労などが原因となって筋電位の特徴が変化することに対するロバスト性向上の方法を検討する。

2. 筋電位に基づく動作識別システム

2.1 概要

動作識別システムの処理の流れをFig.1に示す。まず、腕から筋電アンプを使って測定した筋電位をA/D変換してパソコンに入力し、特徴量を抽出する。そして、特徴量をニューラルネットに入力して動作識別を行う。本研究では、義手本体がないためOpen-GLで作製したシミュレータ(Fig.6参照)に識別動作を出力する。

Table 1 Specifications of EMG amplifier.

Item	Value
Electrodes	Integral dry reusable
Input Impedance	10 T Ohms
Gain	60 dB (1000 x)
Bandwidth	20 Hz - 460 Hz
Noise	<5 μV
CRMM@60 Hz	>96 dB (typical 110 dB)

Fig. 2 Myoelectric potential waveform example.

2.2 筋電位測定

筋電位の測定には、バイオメトリクス社製の乾式筋電アンプSX230を4チャンネル使用している。仕様は、Table 1のようになっており、3次のバターワースフィルタ(20Hzのハイパスフィルタ)と8次の連立チェビシェフフィルタ(460Hzのローパスフィルタ)を内蔵している。測定するときは、株式会社ディケイエイチ社製アイソレータPH-2501/4に筋電アンプを接続して電気的に絶縁する。測定した筋電位をサンプリング周期 1kHz(1ms)でA/D変換して、パソコンに入力する。A/D変換ボードは、株式会社インターフェイス社製CSI-320416(分解能16ビット、入力レンジ±10V、差動入力)を使用する。A/D変換した筋電位は、Visual C++.net 2003で作製したアプリケーション(Fig.6参照)で波形を描画する。筋電位波形の例をFig.2に示す。

2.3 特徴量抽出

測定した筋電位は、そのままの状態では識別に使うには扱いにくい。ため前処理として特徴量を抽出し、その特徴量を使用して動作識別を行う。特徴量には、よく周波数情報が使われるが少しでも計算量を抑えるため周波数情報を使わずに、本研究では特徴量として実効値(Root Mean Square : RMS)を使用する。以下に実効値を求める式を示す。

$$RMS(t) = \sqrt{\frac{1}{2T} \sum_{\tau=-T}^T e^2(t+\tau)} \quad (1)$$

ここで、 $e(t)$ は筋電位信号で、 $(-T, T)$ が計算区間になる。対象とする区間を、少しずつ時間的にずらしながら実効値を計算することによって、実効値の時間変化を得る。

本研究では、計算区間を70msとし、70回サンプリングするごとに実効値を求めることにする。これは、筋電位が発生してから筋肉に力が発生するまでに約100msの時間が存在する⁹⁾ため操作者に時間遅れを感じさせないようにするには、この時間以内に動作識別を終わらせる必要があるためである。よって識別処理の計算時間を考えて計算区間を70msとする。

2.4 ニューラルネットによる動作識別

ニューラルネットは、3層階層構造型の誤差逆伝播(Back Propagation)を使用する(Fig.3参照)。なお、中間層および

Fig. 3 Neural Network construction.

出力層の出力関数にはシグモイド関数を用いる.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

また, 出力値 O_k と教師信号 t_k の 2 乗誤差平均 E が小さくなるように重み W を修正していき, 学習終了条件を満たしたら学習を終了とする.

$$E = \frac{1}{K} \sum_{k=1}^K (t_k - O_k)^2 \quad (3)$$

3. 入力データと学習用データの最適化法

3.1 ニューラルネットへの入力データ

測定した筋電位は, 筋電アンプで増幅されているとはいえ値は非常に小さい. そのため, 各動作での筋電位の違いがわずか(数 mV)しかない. 識別対象である各動作間で筋電位の違いがわずかしかなければ汎化能力からニューラルネットでは誤認識の発生原因になる可能性がある. この筋電位を正規化する方法として, これまでの研究では, 測定した筋電位の全 CH の和が 1 になるようにする方法¹⁰⁾やあらかじめ測定しておいた最大随意筋収縮時の値を使う⁴⁾などがある.

本研究では, 筋電位を A/D 変換して特徴量の実効値を抽出してから, 値を増幅することにより各動作で筋電位の違いを大きくする(数 V)ことで誤認識の発生を抑えられるのではないかと考えた. また, これらにより筋電アンプの増幅率に左右されずに積算するだけで簡単に値を操作できることになる.

3.2 学習用データ

学習用データは, あらかじめ測定しておいた各動作の t 回分の筋電位の実効値から平均を求める. その値を学習用データとして誤差逆伝播で学習させる. これは, ニューラルネットの汎化能力を利用している. 実際の動作での筋電位の実効値が, 学習に使用したデータより値が多少違っていても, 汎化能力から想定している出力パターンを得ることができる. また筋電位は, 同じように力を入れ続けていても一定の値を

Fig. 4 Learning data optimization method.

維持するわけではなく値は上下する. そこで, 学習対象の動作の実効値を複数回分取り出して, その平均値を学習用データにする. そうすれば, 学習用データから見れば測定した筋電位の実効値は, 学習用データに一致することはほとんどないが, ニューラルネットの汎化能力から認識できると考えられる. 例として Fig.4 に手のひらを開く動作を維持して力を入れている時の波形(実線)を示す. この図では, $t=40$ 回分の実効値の平均を算出し(破線), これを学習用データとしている. この方法であれば, 1 つの動作に対して多くの学習用データを用意しなくてもすむ. 多くの研究では, 1 つの動作に対して学習用データを 10 種類以上用意しているが, 本研究では 1 種類にする.

また, 学習には識別対象の動作のほかに, 完全に力を抜いた状態である「無動作」時の筋電位も 1 種類の動作として学習用データを用意する. こうすることで, 力を入れていない時や動作をやめた時に識別動作が「無動作」になることで誤認識を抑えられるのではないかと考えた.

学習用データには, 安定した値を取得できるように動作を一定に維持した状態で測定した筋電位を用いる.

4. 増幅率に対する動作識別能力の実験

4.1 実験環境

実験に使用した測定装置と実験装置は Fig.5 に, シミュレートは Fig.6 に示す. 測定位置は, 被験者の右前腕部に 4 チャンネルの筋電アンプを 90 度間隔で取り付ける(Fig.7 参照). 測定位置をこの位置にした理由は, 識別対象となる手のひらと手首の動作は, 主に手首から肘の間にある浅指屈筋, 橈側手根屈筋, 尺側手根屈筋, 長橈側手根屈筋などを使用するため, この場所が筋電位を測定するのに適しているからである. 肘より上に電極を配置してしまうと手のひらや手首を動かしてもほとんど筋電位は測定できない. また, 電極を 90 度間隔で配置したのは手首からの距離を覚えていれば前回学習した位置を容易に指定できるようにするためである. ネットワーク構成は各層のニューロン数を, 入力層はチャンネル

Fig. 5 Experimental setup of motion discrimination.

Fig. 6 Waveform drawing application and myoelectric hand simulator.

数分の4個, 中間層は5個, 出力層は6個とした. 中間層の数は, 設定した学習終了条件でローカルミニマムを起こさずに学習が収束できる最も少ない数になるように試行錯誤的に設定した. 従来の研究⁴⁾で, 誤差逆伝播の構成を入力層が6個, 中間層が2層でいずれも10個, 出力層が6個, また Elman's Network で入力層が6個, 中間層が150個, 出力層が6個で実験を行っているものがあるが, これらと比較すると本研究は簡潔な構造になっている. 出力層には, 手のひらを「開く」, 「握る」, 手首の「掌屈」, 「背屈」, 「回内」, 「回外」計6種類の動作 (Fig.8 参照) を割り当てた. 学習には6種類の動作のほかに, 完全に力を抜いた状態である「無動作」時の筋電位も1種類の動作として加えて全7種類の学習用データを用意する. 各動作に対応する教師信号は Table 2 のようになる. $t=40$ 回分の実効値の平均を学習用データとして誤差逆伝播で学習させる. 学習終了条件は, 2乗誤差平均 E が 10^{-4} 以下になったときとする. また, 今回の実験では動作を認識したとする出力層の閾値は「0.7」に設定する. 学習終了時の出力層の値は1に限りなく近い値なので, その値に比べて小さく設定することで学習用データにわずかも近い値の筋電位が測定されたら動作を識別できるようにして汎化

(a) The cross section of the arm. (b) Electrode locations.
Fig. 7 Measurement position of myoelectric potential.

Fig. 8 Motions assigned to the output layer.

Table 2 Teaching signal.

Motion	output layer					
	1	2	3	4	5	6
Open	1	0	0	0	0	0
Grasp	0	1	0	0	0	0
Flexion	0	0	1	0	0	0
Dorsiflexion	0	0	0	1	0	0
Pronation	0	0	0	0	1	0
Supination	0	0	0	0	0	1
No motion	0	0	0	0	0	0

能力の向上をねらった.

これらを使つての提案手法の精度を確認する為の実験内容は, 出力層に割り当てた6種類の動作を, それぞれ50回ずつ行う. そして, 誤差逆伝播による識別結果が, 実際の動作に対して, どれくらいの割合で正しく識別できているのかを確認する. その際, 動作中に別の動作が一瞬でも認識されてしまったら誤認識とする. そして, 増幅率を1, 10, 20, 30, 40, 50, 60, 70倍の8種類で実験を行い, 実効値を増幅することによる識別率の変化を確認する. そのとき, 識別に使用するデータは, 各動作を50回ずつ行ったときの筋電位の実効値を保存しておき, その値を増幅して使い, 各増幅率の実験を行う. また, 学習用データも増幅無しのとときに作成したものを増幅して使用する. そして, 誤差逆伝播の重みの初期値は

全増幅率で同じ値を使って学習させ実験を行い、この重みの初期値はランダムに変えて 10 回実験を行う。また、学習率等のパラメータは全て同じ値を使う。今回の実験は、2 人の健康者(被験者 A(31 歳, 男性), B(23 歳, 男性))で行い、認識させようとしている動作以外のことに力が入ってしまわないように、腕には負荷を与えないようにして行う。また、被験者には実験に先立ち実験内容の説明を行ない、参加の了解を得た。

4.2 実験結果

(1) 識別率

実験結果を Table 3 に示す。表は各増幅率で 10 回分の識別率の平均値(DR)と標準偏差(SD)を示している。「各増幅率の結果」を「増幅無し(1 倍)の結果」に対して t 検定を行い全増幅率のときに 1%水準で有意差が有ることが確認できた。特に 30 倍のとき 2 人とも識別率が高かった。実験により実効値を増幅してからニューラルネットに入力することで、ネットワークの構造を複雑にしなくても高い識別精度を得られることが確認できた。「4.1 実験環境」で挙げた従来の研究⁴⁾の識別率は、誤差逆伝播は 74.3%, Elman's Network は 83.7%であった。本研究では、これらより簡潔な構造で高い識別精度であった。また本研究と同等の識別率を得ている研究⁷⁾では、特徴量抽出に高速フーリエ変換を使い動作識別に主成分分析とニューラルネット(入力層 3 個, 中間層 20 個, 出力層 4 個の誤差逆伝播)を使っており、本研究の識別システムの方が簡潔になっている。

また、増幅することで大きな力を出さなくても動作を認識できるようになることが実験により確認できた。これは、わずかな動きによる筋電位でも増幅されることにより反応しやすくなったものと考えられる。しかし、増幅率を上げすぎると、今度は識別率が少し低下している。これは、実効値の増幅率が大きすぎるため、わずかな動きによる筋電位の変化でも大きくなりすぎて過剰に反応してしまい、出力層の値が「0.7」を超えてしまうからだと考えられる。特に、発生する筋電位が大きい動作は、この影響を強く受けていた。この誤認識を回避するには、実効値に対して学習用データに近い値の閾値を設定して、閾値以下の場合はニューラルネットによる識別結果を無効にするといった方法が考えられる。また、今回の実験では動作を認識したとする出力層の閾値は「0.7」に設定したが、この閾

値を、各動作の学習が終了したときの出力層の値に限りなく近い値にして、測定した筋電位が学習用データに近い値でないと認識できないようにするといった方法も考えられる。今回は、増幅による識別精度の変化を確認することが目的であったため閾値の操作は行わなかった。

(2) 増幅の効果

実験により誤認識が発生するタイミングを調べた結果、動作の始めと終わりに集中していることがわかった。そして特に、発生する筋電位の値が大きい動作の「動かし始めと終わり」、つまり、筋電位が「発生し始めと終わり」の値が小さい時に、他の「発生する筋電位の値が小さい動作」を誤認識してしまっていることがわかった。Fig.9 に増幅無しのときに発生した誤認識の例を示す。手首を背屈し始めたときに、手のひらを開く動作を誤認識したときの波形である。これは、上記にあるように筋電位の発生し始めに、発生する筋電位の値が小さい動作が誤認識している状態にある。筋電位が上昇中に他の動作(開く)の学習値に近づいてしまい誤認識している。Fig.9 にあるように誤認識時は、各動作の測定値と学習値の差はわずかしかない。この程度の差では、ニューラルネットの

Fig. 9 Waveform of "learning value of open" and "measured value of dorsiflexion" without amplification (misrecognition).

Fig. 10 Waveform of "learning value of open" and "measured value of dorsiflexion" with 50 times amplification (correct recognition).

Table 3 Discrimination rates for amplification rates.

Gain(x)		1	10	20	30	40	50	60	70
Subject A	DR	74.7	82.9	89.1	95.5	95.7	94.0	89.6	85.1
	SD	3.3	2.1	2.9	2.0	2.1	2.0	2.0	2.6
Subject B	DR	57.8	71.6	83.1	93.4	88.2	84.3	80.7	75.2
	SD	6.5	7.2	5.5	3.4	2.9	3.3	3.0	4.4
Average	DR	66.2	77.2	86.1	94.4	91.9	89.2	85.2	80.1
	SD	4.9	4.7	4.2	2.7	2.5	2.7	2.5	3.5

DR : Discrimination rate[%], SD : Standard deviation[%]

汎化能力から学習値の動作(開く)を誤認識してしまう可能性がある。同じ動作でも、Fig.10のように実効値を50倍に増幅していると誤認識は発生しなかった。これは、同じ周期で筋電位の実効値を求めていても増幅している分だけ、手のひらを「開く」動作の学習値と、手首を「背屈」する動作の測定値との差が増幅されているため、ニューラルネットが誤認識を起こさない範囲まで差が広がった為と考えられる。Fig.10に、各動作の測定値と学習値が最も近づいたときの差を示す。このとき、出力層の値は「0.7」に近い値になるときはあるが誤認識は発生しない。

(3) 増幅による重みの変化

学習が終了したときの重みの絶対値の平均を求め、増幅無しときを1としたとき、増幅したときの重みとの大きさの比較をFig.11に示す。このとき、入力層と中間層の間の重みをW1、中間層と出力層の間の重みをW2とし、全ての増幅率のときに使用した重みの初期値は同一のものである。入力データを10倍にしたときは、重みの平均は0.4程度まで落ちているが、その後は増幅率を上げても大きな変化はせずに40倍辺りで変化はほとんどなくなっている。この40倍は識別率で高い値を示した増幅率と同じである。このような重みの平均が安定し始めたときの増幅率と、良い識別率を得ることができた増幅率が同じである傾向は、2人の被験者で見られた。

Fig.11より実効値を40倍に増幅しても、W1は約0.17倍にしかになっていないことがわかる。増幅することで入力データが数値上大きくなっているにも関わらず、入力データと直接演算するW1は増幅率に合わせて減少していくわけではなく、40倍辺りで変化が止まっている。これは入力空間でデータの分布が変わっていないくても増幅することでスケールが拡大され、6種類の動作を識別するには最適なスケールになった為だと考えられる。スケールが小さいとFig.9のように他の動作の学習データに近づきやすくなってしまう。また、40倍以降増幅率を上げても重みの大きさの変化が小さいのは識別を行うのに十分なスケールに拡大した為だと考えられる。よって、増幅することはスケールの最適化を行うことになる。

また、実験により確認できた増幅率を上げていくとわずかな動きによる筋電位でも動作を認識しやすくなったことは、増幅率を上げていっても重みの大きさに変化がほとんどないためだと考えられる。入力データは70倍になっても重みの大きさは40倍のときとほとんど変わらないので、わずかな動きの筋電位でも認識できるのだと考えられる。

(4) 考察

本研究では、中間層のニューロン数は試行錯誤的に決定したが、ニューロン数を最小にすることが、必ずしも汎化能力に対して最適とは限らない¹¹⁾ため、今後は情報量基準¹²⁾などを利用して最良の個数を推定してから中間層のニューロン

Fig. 11 A change of the weight by the amplification.

数を決定したい。また、汎化能力の向上をねらって出力層の閾値を「0.7」に設定したが、増幅率を高くしたときには誤認識発生原因の1つになってしまった。そこで、出力層、実効値ともに閾値の設定について検討していきたい。

ニューラルネットで、未学習データに対する汎化能力を向上させる方法は、基本的に「学習用データを豊富にする」か「ネットワークの自由度を制限する(中間層のニューロン数を制限する)」かの2つの方法が考えられる。学習用データを豊富にすれば、汎化能力を確保できるが、学習を収束させるためにネットワークのニューロンが多く必要になり構造が複雑になってしまい、それでは計算量が増えてしまう。そこで提案手法のようにネットワークの自由度を制限して(構造を簡潔にして)確保することで計算量を抑えることができ、システム全体を簡潔にしていけることができる。これは多くの片側前腕切断者が現在の筋電義手に望む改善点として挙げている「価格」¹³⁾に対応できると考えられる。

本研究の実験では、識別対象の動作以外の部分に力が入らないように行った。しかし、日常生活動作をする時、特に道具を使う場合は、他の部分にまったく力を入れずに腕のみを動かすことは難しい。よって今後は、いろいろな状況に対応できるように、腕に日常使う道具などを重りとして付けたり、体の姿勢を変える、他の動作と組み合わせるなどして腕に負荷をかけた状態での識別精度の確認を行ってきたい。

本研究の実験で、実効値を増幅することで大きな力を出さなくても動作を認識しやすくなることが確認できた。これにより、力の弱い人でも筋電位を扱いやすくなるのではないかと考えられる。これは、腕を切断することで筋肉が衰えてしまった障害者に対して有効に働く可能性がある。

筋電義手を制御する際、動作を誤認識してしまうと非常に危険をともなう場合がある。たとえば、Fig.9に示してあるような誤認識をした場合、手首を曲げようとして手のひらが開いてしまうと、そのとき何かを持っていた場合、落としてしまう可能性がある。また、義手が想定外の動きをしたら使用者は不快に感じて筋電義手の使用を避けるようになってしまうかもしれ

Fig. 12 Neural Network output value example.

ない。上記の問題を避けるためにも筋電義手の制御を行うには、まず動作識別の精度を上げておく必要がある。

5. 筋疲労時のロバスト性向上

5.1 筋疲労に対する対策

筋肉を長時間使用していると筋電位は、筋疲労などが原因となって徐々に変化する¹⁴⁾。そのため、使用前に学習したニューラルネットの重みでは、うまく動作を識別できなくなる可能性がある。使用中に変化した筋電位に合わせて学習し直すとしても、識別システムは被験者の意図した動作を知ることが出来ないため、正しい教師信号を与えることができない。よって、筋疲労などの要因を考慮した動作識別をする必要がある。これまでの研究では、ニューラルネットでの識別結果から求めたエントロピーを使って識別結果が正しいかを判断して使用中に学習し直す方法¹⁵⁾がある。

そこで本研究では、正しく識別されたと判断する尺度として、 L 回連続で同じ動作が識別されたら、その識別結果は正しいとして扱う。これは「4.2 実験結果(2)増幅の効果」に示してあるように誤認識の発生は、筋電位の発生し始め(終わり)の一瞬に集中しており複数回連続することは、殆どないと推測できるからである。Fig.12に、誤認識が発生した時のニューラルネットの出力例を示す。その際、 L 回目の筋電位の実効値 (L_times_data)と今まで使っていた重みの学習時に使用した学習用データ ($last_data$)とで平均を取る。この平均値を再学習用データ ($relearning_data$)とする。

$$relearning_data = (last_data + L_times_data) / 2 \quad (4)$$

そして、再学習用データを使って L 回連続して識別された動作を教師信号として与え再学習する。通常、学習処理を行うときは、重みの初期値はランダム値を設定するが再学習のときは、今まで使っていた重みを初期値として読み込んで学習する。その際、学習がローカルミニマムになってしまったら、重みは修正しない。再学習が終わったら、再度 1 から数え直

Fig. 13 Experimental results "with and without relearning".(Subject A)

Fig. 14 Experimental results "with and without relearning".(Subject B)

して、また L 回連続で同じ動作が識別されたら再学習をする。

5.2 再学習による動作識別能力の実験

(1) 実験環境

実験は「4. 増幅率に対する動作識別能力の実験」を、腕を休めずに 3 回連続で行い識別精度の変化を確認する。再学習を行う条件は、 $L=1 \sim 5$ の 5 種類で行い、増幅率は 2 人とも識別率が高かった 30 倍に固定する。また、被験者には実験に先立ち実験内容の説明を行ない、参加の了解を得た。

(2) 実験結果

実験結果を Fig.13,14 に示す。再学習を行い続けることで、再学習を行わないときと比べて、筋疲労が発生しても識別率の低下が抑えられることが確認できた。 $L=1 \sim 4$ では 2 人とも 90%以上を保っているが、 $L=5$ のときは再学習無しと比べると低下を抑えることができてはいるが大きく低下している。これは、再学習を行う条件を $L=5$ 回としたため間隔が長くなり、変化した筋電位に対応した重みを学習し終える前に動作が終了してしまうために、徐々に筋疲労に対応しきれなくなってしまうと考えられる。そこで、本論文では L_times_data と $last_data$ とで平均を求めていた為に徐々にしか筋疲労に対応できなかったと考えられる。そこで、再学習用データを作る

ときに L_times_data の割合を大きくすることで筋疲労への対応が早くなり、さらに識別精度の低下を抑えることができるのではないかと考えられる。

(3) 考察

筋電義手を制御する際、動作を誤認識してしまうと非常に危険をともなう場合がある。そこで筋電義手の制御を行うには、長時間使用して状況が変化しても高い動作識別精度を保てるようにする必要がある。

本手法により筋疲労が原因となって徐々に変化する筋電位に対応できることが確認できた。しかし、筋疲労に完全に対応させてしまうと、筋電義手を外して疲労を取ってから再び義手を使おうとすると、筋疲労状態でニューラルネットが学習してしまっているため、今度は筋疲労のない通常時の識別精度が低下してしまう可能性がある。そこで、どの程度筋疲労に対応させるべきか、そして疲労が取れた後の対応についても検討する必要がある。

6. まとめ

本研究では、筋電義手の制御を目的とした簡潔なニューラルネットによる前腕の動作識別法を提案した。筋電位の実効値を増幅してニューラルネットへの「入力データ」とし、あらかじめ測定しておいた各動作の t 回分の筋電位の実効値から求めた平均を「学習用データ」として最適化することで、従来の方法では複雑化する傾向のあるニューラルネットの構造を複雑にせず高い識別精度が獲得できることを示した。これによって、システム全体を簡潔で安価にすることができる。

また本研究では、筋疲労時のロバスト性向上のために使用中のニューラルネットの再学習法を提案した。複数回連続して同じ動作を認識したら、その認識された動作は正しいとして再学習することで、筋疲労による識別精度の低下を抑えることを示した。これによって、長時間使用しても高い識別精度を保つことができる。

今後は、日常生活のいろいろな動作・状況に対して高い識別精度を獲得できるように、よりロバストな動作識別法の構築を目指す。また筋疲労については、疲労から回復したときの対応について検討していきたい。

参考文献

- 1) 平岩 明, 内田典佳, 曾根原登, 下原勝憲, “筋電操作ハンドの制御のための皮膚表面筋電信号のニューラルネットによる認識”, 計測自動制御学会論文集 1994; Vol.30, No.2 : 216-224.
- 2) M. F. Kelly, P. A. Parker and R. N. Scott, “The application of neural networks to myoelectric signal analysis: A preliminary study.” IEEE

Trans. on Biomedical Engineering 1990; Vol.37, No.3 : 221-230.

- 3) 辻 敏夫, 森大一郎, 伊藤宏司, “統計的構造を組み込んだニューラルネットによる EMG 動作識別法”, 電気学会論文誌 C 1992; Vol.112, No.8 : 465-473.
- 4) 福田 修, 樋口 敏夫, “生 EMG 信号による電動義手の制御”, 計測自動制御学会論文集 2004; Vol.40, No.11 : 1124-1131.
- 5) 梶谷 勇, 樋口 哲也, 大津展之, “多機能筋電義手における動作識別精度の改善手法”, ヒューマンインターフェース学会誌 2003; Vol.5, No.4 : 421-428.
- 6) 永田健太郎, 安藤啓一, 山田雅史, 曲谷一成, “チャン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 2006; Vol.44, No.1 : 138-147.
- 7) 榊原久司, “筋電制御2自由度前腕義手の開発(第2報)”, 電子情報通信学会技術研究報告 2007; Vol.107, No.154 : 67-70.
- 8) M.Hagiwara, “A simple and effective method for removal of hidden units and weights” Neurocomputing 1994; Vol.6, No.2 : 207-218.
- 9) 木塚朝博, 増田 正, 木竜 徹, 佐渡山亜兵, “バイオメカニズム・ライブラリー 表面筋電図”, 第1版, バイオメカニズム学会編, 東京電気大学出版局, 2006.
- 10) 福田 修, 辻 敏夫, 金子 真, “ニューラルネットによる連続動作 EMG パターンの識別”, 電気学会論文誌 C 1997; Vol.117, No.10 : 1490-1497.
- 11) 渡辺栄治, 清水 光, “2 値パターン分類問題における階層型ニューラルネットワークの内部表現と汎化能力の関係”, 電子情報通信学会技術研究報告 NC 1993; Vol.92, No.522 : 65-72.
- 12) 栗田多喜夫, “情報量基準による3層ニューラルネットの隠れ層のユニット数の決定法”, 電子情報通信学会論文誌 D-II 1990; Vol.J73, No.11 : 1872-1878.
- 13) 岡本 晋, 田村 徹, 小池雅俊, 高橋功次, “片側前腕切断者における電動義手に対する意識調査”, 国立リハビリテーションセンター研究紀要 2001; 第 22 号 : 55-61.
- 14) 木竜 徹, “疲労とストレス 局所筋疲労を表面筋電図でみる”, バイオメカニズム学会誌 1997; Vol.21, No.2 : 75-80.
- 15) 辻 敏夫, 市延弘行, 伊藤宏司, 長町三生, “エントロピーを用いた誤差逆伝搬型ニューラルネットによる EMG からの前腕動作の識別”, 計測自動制御学会論文集 1993; Vol.29, No.10 : 1213-1220.