

平成 14 年度

修士学位論文

モバイルインタフェースの開発用手首挙動認識システムの構築
に関する研究

Research on Construction of Wrist Behavior Recognition System
for Development of Mobile Interface

学籍番号 1055125 中原 昌樹

高知工科大学大学院基盤工学専攻情報システムコース

指導教員 竹田史章 教授

2003 年 1 月 31 日

要旨

高知工科大学大学院情報システムコース

モバイルインタフェースの開発用手首挙動認識システムの構築 に関する研究

中原昌樹

近年、携帯電話に代表される情報端末の社会への普及により機器の高機能化、軽量小型化が進んでいる。しかしながら、小型化された機器は操作性を低下させる問題点を新たに発生させている。したがって、現在小型で操作性の高い入力インタフェースの開発が望まれている。このため、本研究ではモバイル端末インタフェースの開発を前提とした手首挙動認識システムを提案する。システムの制御信号には被験者の随意運動に伴い発生する筋活動電位(EMG)を用いる。EMGは人の随意運動に伴い発生し、力の入れ具合および運動の柔らかさなどの情報を含有し、人の動作解析において有用な生体情報である。本論文ではEMGのパターン識別にニューラルネットワークを応用する。まず、提案システムの基本性能を検証し、手首挙動の識別において実現可能であることを示す。さらに、実用化を目的としたシステム構築を行い、より市場性を顧慮したシステム構成とする。これによりマウスで得るイベント情報を手首挙動で実現する可能性についても考察する。さらに、個人の手首挙動のばらつきを吸収するためにシステムのオンラインチューニングについても検討する。

キーワード モバイルインタフェース, ニューラルネットワーク, 汎用化, DSP, FFT, 筋活動電位, パターン認識

Abstract

Research on Construction of Wrist Behavior Recognition System for Development of Mobile Interface

Masaki NAKAHARA

Recently, information terminals such as mobile phone are widely used. Furthermore, these devices are to be light and small. However, these devices are not always comfortable and convenient to use because of their small shape. Consequently, we need to develop a new type of the input interface whose operation is easier and shape is smaller. We have paid attention to electromyogram (EMG) which is discussed for an artificial arm. EMG is generated along to the person's behavior and it has information, which contains of the level of behavior. Especially, learning and recognition of EMG by using neural networks, is supposed to be possible. We have shown its basic ability and possibility by the simulation for the realization of the practical use on the wrist behavior recognition. Furthermore, we consider about online tuning of neural network for robust of fluctuation of individual wrist behavior.

Keywords: Mobile interface, Neural network, wide use, DSP, FFT, Electromyogram,
Pattern recognition

目次

1 はじめに	1
2 生体情報	3
2.1 生体情報	3
2.2 筋活動電位 (EMG)	3
3 手首挙動認識システムの構成	6
3.1 入力部	7
3.1.1 挿入電極と表面電極	7
3.1.2 湿式電極と乾式電極	8
3.1.3 オペアンプの実装	9
3.1.4 電極数と電極位置	11
3.1.5 電極方向	14
3.2 信号処理部	14
3.3 特徴抽出部	18
3.3.1 FFT	18
3.3.2 入力ベクトルの算出	21
3.3.3 ニューロデータ作成	24
3.4 登録・識別部	28
4 実験	37
4.1 前腕に電極を配置	37
4.1.1 入力層細胞数の検討	42
4.1.2 中間層細胞数の検討	47
4.2 手首に電極を配置	50

4.3 手首挙動の検討	56
4.3.1 入力値の統計解析	57
4.3.2 手首挙動の検討	59
4.4 個人差への適応	65
4.4.1 NN ウェイトのオンラインチューニング	66
4.4.2 DSP ユニットによる実験	67
4.4.3 ポータブル DSP システムの提案	71
5 まとめ	73
謝辞	74
参考文献	75
付録	81

目次

図 2.1	EMG 発生機構	4
図 2.2	細胞の興奮と活動電位.....	5
図 3.1	システム概観	6
図 3.2	システム構成	7
図 3.3	電極	9
図 3.4	電解クリーム	9
図 3.5	増幅位置の有無	10
図 3.6	データ採取位置(基礎システム)	11
図 3.7	背屈	12
図 3.8	掌屈	12
図 3.9	データ採取位置(実システム)	13
図 3.10	電極配置(4ch:実システム)	13
図 3.11	手首挙動と時系列波形とパワースペクトル(4ch)	13
図 3.12	電極配置方向	14
図 3.13	差動増幅回路の構成	16
図 3.14	2ch 用差動アンプの概観.....	17
図 3.15	4ch 用差動アンプの概観.....	17
図 3.16	直流電源(実システム)	18
図 3.17	手首挙動と時系列波形とパワースペクトル(4ch)	20
図 3.18	ニューラルネットワークへの入力データモデル.....	22
図 3.19	特徴抽出手法 1	23
図 3.20	入力情報の比較(手首挙動:掌を閉じた状態, 背屈 電極数:2)	23

図 3.21 特徴抽出手法 2	24
図 3.22 データファイルの構成	28
図 3.23 NN パラメータ設定ファイルの内容	29
図 3.24 学習データ抽出イメージ	30
図 3.25 学習ファイルと各 SLAB ファイルの関係	30
図 3.26 教師ファイル作成イメージ	31
図 3.27 シグモイド関数	33
図 3.28 慣性定数と振動定数の範囲	35
図 3.29 学習状態画面(認識パターン数:2)	36
図 3.30 評価状態画面(認識パターン数:2)	36
図 4.1 EMG 採取姿勢	37
図 4.2 被験者 A の学習データのばらつき	40
図 4.3 被験者 5 人の学習データのばらつき	40
図 4.4 実験 2 の場合での NN の反応値	41
図 4.5 実験 4 の場合での NN の反応値	41
図 4.6 NN への入力波形(入力層細胞数:50)	44
図 4.7 手首挙動:背屈	53
図 4.8 手首挙動:掌屈	53
図 4.9 前腕の運動に使用する筋	56
図 4.10 ユークリッド距離と手首挙動データの分布	61
図 4.11 手首挙動と計測信号	62
図 4.12 学習サンプル数と認識率との関係	65
図 4.13 オンラインチューニングのシステムイメージ	67
図 4.14 DSP ユニットの概観	68
図 4.15 DSP ユニットの構成	68

図 4.16	モニタプログラム.....	69
図 4.17	モバイルインタフェース用オンライン学習システムイメージ.....	72
図 0.1	基本ニューロンモデル.....	81
図 0.2	NN の分類.....	83
図 0.3	出力関数.....	84

表目次

表 3.1 A / D 変換カード仕様	15
表 3.2 データ採取条件	15
表 3.3 差動増幅器の設計仕様	17
表 3.4 NN データのフォーマット	25
表 3.5 ヘッダ情報のフォーマット	26
表 4.1 実験条件(実験 1~4)	39
表 4.2 実験結果(実験 1~4)	39
表 4.3 認識パターン	42
表 4.4 実験条件(実験 5, 6)	43
表 4.5 手首挙動を背屈・掌屈で実験した場合	45
表 4.6 手首挙動を背屈・掌屈・右・左で実験した場合	45
表 4.7 手首挙動を背屈・掌屈・回内・回外で実験した場合	45
表 4.8 手首挙動を背屈・掌屈・右・左・回内・回外で実験した場合	46
表 4.9 実験条件(実験 7~9)	48
表 4.10 実験結果(実験 7~9)	49
表 4.11 実験条件(実験 10, 11)	51
表 4.12 実験結果(実験 10, 11)	51
表 4.13 実験条件(実験 12~15)	54
表 4.14 実験結果(実験 12~15)	55
表 4.15 入力値の統計解析と NN の出力値の関係	58
表 4.16 実験条件(実験 17)	64
表 4.17 実験結果(実験 17)	64

表 4.18 実験条件(実験 18)	70
表 4.19 DSP ユニットを用いた実験結果(実験 18)	70
表 0.1 分類別における NN の特徴 ⁽⁵⁹⁾	83
表 0.2 (手法 2)を用いた NN データの統計解析結果.....	85
表 0.3 表 0.2 の結果から算出されたパターン間距離の大きい上位 10 組の組み合わせ	89
表 0.4 (手法 1:正規化定数 $k=1000$)を用いた NN データの統計解析結果.....	90
表 0.5 表 0.4 の結果から算出されたパターン間距離の大きい上位 10 組の組み合わせ	94

1 はじめに

近年、計算機や携帯電話などの多様な情報端末の普及に伴い、これらの機器の軽量・小型化が進んでいる。しかしながら、機器の小型化は使用者の操作性を損ねる場合が多い。そのため、音声入力装置やペン入力装置などさまざまな入力インタフェースが開発されている。しかしながら、これらは騒音を問題とする公共の場では使用できないことやペン入力するための環境が必要であることなど使用環境に依存するという問題を抱えている。したがって、使用環境の制限がなく、小型で操作性の高い入力インタフェースの開発が求められている。著者はこれらの条件を満たす新しい入力インタフェースを開発することを目的とし、手首挙動にて機器制御を行う認識システムを提案する。その機器の制御信号として、筋収縮の際に発生する筋活動電位 (EMG: Electromyogram) に着目する。

EMG は力の入れ具合、運動の柔らかさ、運動レベルに応じた情報を含み、人の動作解析において有用な生体情報 (Biometrics) である。また、腕切断者についても残存筋からの EMG を採取することができることから、EMG パターン認識の研究は古くから電動義手やマニピュレータの制御信号として、多くの研究者によって研究されてきた⁽¹⁾⁻⁽¹⁵⁾。このため、EMG に関する研究は障害者を対象とした福祉的な利用が多数報告されている^{(1)-(11), (13)-(16)}。その例として辻らが EMG の高速フーリエ変換 (FFT: Fast Fourier Transform) 処理によるニューラルネットワーク (NN: Neural Network) を用いた手首挙動認識システムを開発したことを報告している⁽¹⁾⁻⁽¹⁷⁾。しかしながら、動作により発生する EMG は低再現性であることから実用化にいたるまでにはさらなる研究が必要である。また、EMG の採取位置についても、そのほとんどが腕や肩の筋肉等の比較的大きな筋肉からの EMG を検出するものである。そのため、EMG パターン認識に関する研究ではこれからのさらなる研究が期待されている。

EMG は雑音を含みかつ種々の筋肉の活動電位の合成信号として検出されるため、動作に固有な EMG からの特徴量抽出には従来の統計解析では十分な認識能力が得られない⁽¹⁸⁾⁻⁽³³⁾。このため、本論文では NN を EMG パターンの認識に応用し、手首挙動による機器

制御を行うことを前提とした健常者対象の手首挙動認識システムを検討する^{(34)~(44)}。さらに、種々の NN の性能確認実験を実施し、手首挙動認識において NN の有用性を定量的に示す。

手首挙動の認識には、手首挙動において収縮する筋である橈側(とうそく)主根屈筋と尺側(しゃくそく)主根屈筋からの EMG が主に発生することから、これらの筋上に電極を配することが好ましい⁽⁴⁵⁾。したがって、橈側主根屈筋と尺側主根屈筋上に電極を配し、手首挙動パターン数を 2(背屈, 掌屈)とし、認識実験を行う。また、個人による EMG の変動をシミュレーション実験により示す。

前述のように提案システムの具体化を考慮すると、上記の電極配置は使用者の利便性を低下させることは自明である。したがって、電極の装着・着脱の容易性が不可欠である。本論文ではリストバンドや腕時計型としての使用を視野に入れ、手首からの EMG を検出し、手首挙動認識実験を行う。

また、さらなる提案システムの実用化を考慮すると認識パターン数の増加、操作性、処理の高速化、機器の小型化などが必要条件となる。認識パターン数の増加および操作性についてはマウスなどのポインティングデバイスの基本動作(6 イベント:上・下・右・左・右クリック・左クリック)を手首挙動により実現するために認識パターン数を 6 以上とすることが好ましい。したがって、操作性が高く、かつ特定個人に対してパターン間距離が大きい手首挙動の選択についても検討する。また、提案システムをデジタル・シグナル・プロセッサ(DSP: Digital Signal Processor)を核とする DSP ユニットへ移植することにより個人間での EMG の変動を吸収するための基礎実験を実施する。また、複数人の EMG データベースにより作成した初期 NN ウェイトを用い、使用者本人に適した NN ウェイトを作成するオンラインチューニングの構想についても記述する。さらに、DSP ユニットと計算機を用いたシミュレーション結果との比較を行い、提案システムの実用性能の具現化の可能性についても考察する。機器の小型化については、この DSP システムを小型化したポータブル DSP システムの構想についても言及する。

2 生体情報

本章では生体情報についての概説を述べ、採取する EMG の発生機構についても述べる。

2.1 生体情報

生体情報には EMG の他に、指紋、掌形、静脈パターン、顔、虹彩、網膜、DNA、声紋、署名、キーストロックなどが挙げられ、身体的特徴と行動的特徴に大別される。前者 6 つは身体的特徴、後者 4 つは行動的特徴に相当し、身体的特徴は行動的特徴に比べ、終生不変であるため一般に再現性が高い。また、万人不同という特徴を持つ。行動的特徴は身体的特徴に比べ、使用者の心理的抵抗が低いという特徴を持つ⁽⁴⁶⁾。EMG は行動的特徴に相当し、人の随意運動により変化することから、一般の入力インタフェースとしても利用できると考えられる。しかしながら、EMG をはじめとする音声、掌紋など生体情報は一般に個人差が大きく、その再現性も低いことが報告されている⁽⁴⁶⁾。これは個人による運動の癖、筋肉・脂肪の量や皮膚の厚さ、刻々と変化する皮膚状態の変化、筋疲労などによるものと考えられる⁽¹³⁾。

2.2 筋活動電位 (EMG)

本節では採取する筋活動電位について記述する。EMG は筋電図または筋電位とも呼ばれ、筋収縮の際に検出される微弱な電気信号である。運動の機能的な単位は筋収縮である。つまり、すべての運動は関節を中心とし、骨の屈伸、内外転、回旋運動の組み合わせで行われ、その駆動力は筋収縮によるものである^{(47)~(49)}。

運動ニューロンの細胞膜の内部と外部は Na^+ 、 K^+ 、 Cl^- で構成される。外部は Na^+ が多く、

内部は外部に対し、電位が低くなっている。このため、膜内部の静止電位は -70mV 程度に保たれている。脳からの刺激や反射により脊髄内の運動神経細胞が興奮すると、その信号は運動神経軸索を通じ、神経と筋肉の接点である神経筋接合部(MU:Motor Unit)に達する。神経終末から伝達物質であるアセチルコリンが放出される。MUでは受容体(レセプター)がアセチルコリンを受容するとレセプターは活性化し、細胞膜の Na^+ に対する透過性が増大する。ナトリウムポンプを通じて Na^+ が細胞膜内部に侵入することにより膜の内外の電位が瞬間的に逆転する。このとき、筋肉の機能単位である筋線維は興奮し、収縮する。この発生した電位差を(約 100mV)をEMGと呼ぶ。図2.1にEMG発生の順序機構を図2.2に細胞の興奮と活動電位を示す。

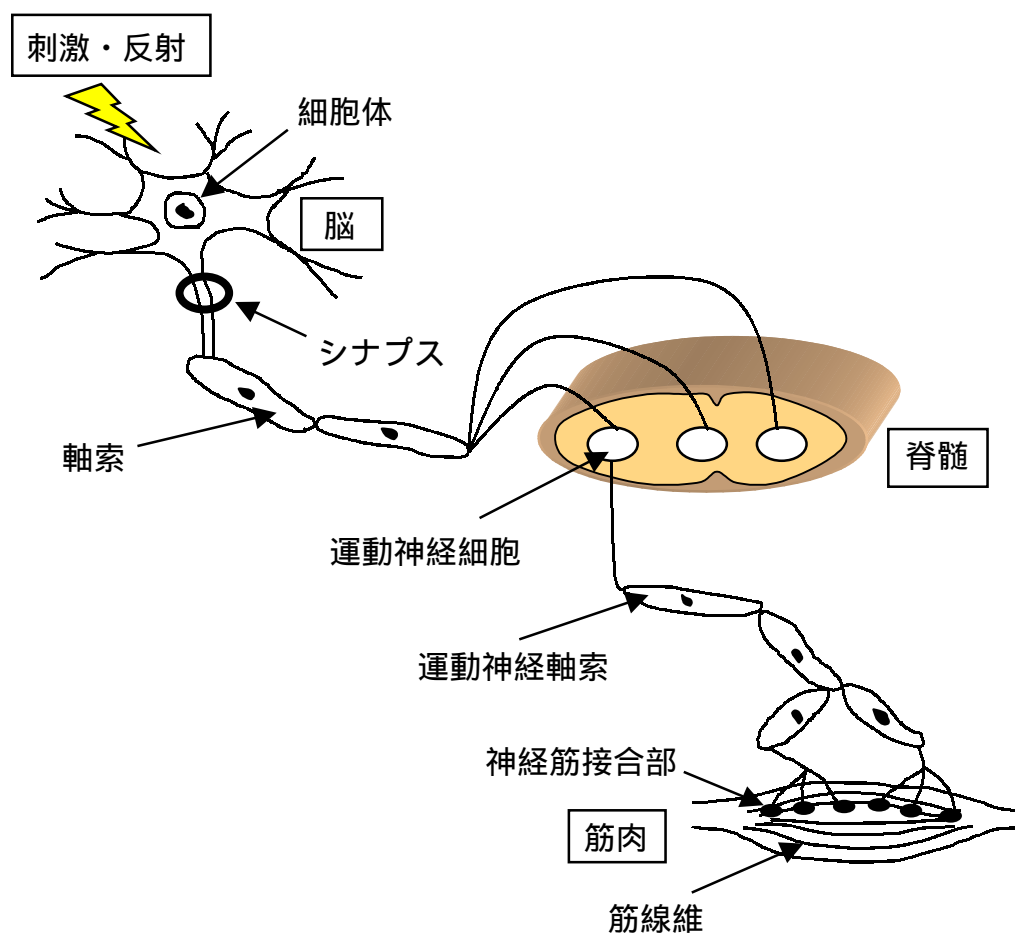


図 2.1 EMG 発生機構




図 2.2 細胞の興奮と活動電位

3 手首挙動認識システムの構成

本章では提案システム構成について記述し、各節にて詳細を示す。まず、手首挙動において電極を最適位置に設置し、手首挙動認識システムを構築する。その結果、認識システムとしての NN の基本性能を確認する。以降、このシステムを基礎システムと記述する。また、さらなる基礎システムの実用化を考慮し、実用化を前提としたシステムについても提案する。以降、このシステムを実システムと記述する。本章では基礎システムと実システムについて記述し、その改良点を明確にする。

EMG パターン認識システムは入力部、信号処理部、特徴抽出部、登録・識別部より構成され、その大要は(データ採取)→(増幅)→(特徴抽出)→(学習)→(認識)の流れで処理される。入力部では電極から EMG データ(時系列データ)を計測する。計測した EMG は微弱な電気信号であるため、信号処理部の差動増幅器にて増幅する。さらに、A/D 変換器を介し、計算機内に格納する。特徴抽出部では前処理として計算機内の FFT 処理プログラムより EMG データ(パワースペクトル)を得る。さらに、NN への入力ベクトルを作成し、EMG データの内容を記述したヘッダ情報を付加する。登録・識別部では前段にて前処理したパターンごとの EMG データを NN により学習・認識し、被験者の手首挙動結果を出力する。システム概観を図 3.1、システム構成を図 3.2 に示す。以下では、図 3.2 に基づき各モジュールごとの機能について述べる。



(a) 基礎システム



(b) 実システム

図 3.1 システム概観




図 3.2 システム構成

3.1 入力部

入力部では電極を用いて EMG を計測する. そこで, 本節では EMG 計測に採用する電極について記述する. 生体信号計測に使用する電極は生体—計測装置間において電荷の授受を行うインタフェースとしての役割がある. 生体信号は特に低周波帯域において発生する微弱な電位であることから, 生体信号計測用電極には電極インピーダンスが低いこと, 電極電位が安定であることが必要である⁽⁵⁰⁾.

3.1.1 挿入電極と表面電極

一般に, EMG を採取する電極は挿入電極と表面電極に大別される. 挿入電極は針電極とも呼ばれ, MU に直接電極を装着することにより特定の筋からの安定した EMG が得ることが可能である. しかしながら, 皮膚に電極を挿入することから使用者の拒否感が大きい. また, 表面電極は皮膚上に電極を配置するため, 挿入電極と比較し, 使用者の拒否感は少ない. しかしながら, 計測される EMG (表面筋電) は表面上に存在する複数の筋からの合成信号で, 筋肉・脂肪の量の影響による MU から皮膚表面までの伝達特性の違いなどの影響を受ける. さらに, 皮膚の電極の位置ずれなどによるノイズの影響を受けやすい. 本論文では実用化に伴い, 使用者の拒否感の少ないことに加え, さまざまな動作を認識することから, 多様な筋からの情報を計測可能な表面電極を採用する.

3.1.2 湿式電極と乾式電極

表面電極はさらに湿式電極と乾式電極に分類される。湿式電極は心電図計測などに使用されるものと同様の医療計測用であり、皮膚－電極間の接触抵抗(アーチファクト)を抑制するため電解クリームを用いる。このことから、取り付けや取り扱いに手間がかかる。しかしながら、乾式電極と比較し、電極インピーダンスが低いことから安定した表面筋電を採取することが可能である。一方、乾式電極は取り付けや取り扱いが容易であるが、湿式電極と比較し、不安定な密着性により検出性能が低下するという問題点もある。

基礎システムでは湿式電極を採用する。これは乾式電極に対し、安定した EMG を採取可能なためである。また、湿式電極の素材として、銀－塩化銀を採用する。銀－塩化銀電極は電極電位が安定していること、低周波帯域において電極インピーダンスが低いこと、生体組織液に対して溶液中の Cl⁻イオンを介して安定な平衡状態を保持できるという利点がある⁽⁵⁰⁾。しかしながら、湿式電極はさらなる実用化を考慮すると電解クリームを使用することによる取り扱いの複雑さや装着の容易性から好ましくないと考えられる。そのため、実システムでは乾式電極を採用する。採用する乾式電極は皮膚－電極間の接触抵抗の変化がノイズの原因となるため、柔軟な素材基板で腕形状に密着するセンサを製作し、接触抵抗を小さくかつ安定にしている。電極形状は腕湾曲方向に長くし、手首が動いた場合においても接触面積を確保可能としている。また、乾式電極の素材については銀－塩化銀を入手できなかったことから、同等性能の得られる銅板に金メッキを塗装したものを採用する。

電極構成は基礎システム、実システムともに EMG において、一般に使用される 1 対の測定電極(+,-入力)と 1 個の不感電極(グランド)を配置する双極誘導法を用いる。図 3.3 (a)に湿式電極を、図 3.3 (b)に乾式電極を示す。図 3.4 に電解クリームを示す。



(a) 湿式電極(基礎システム)



(b) 乾式能動電極(実システム)

図 3.3 電極

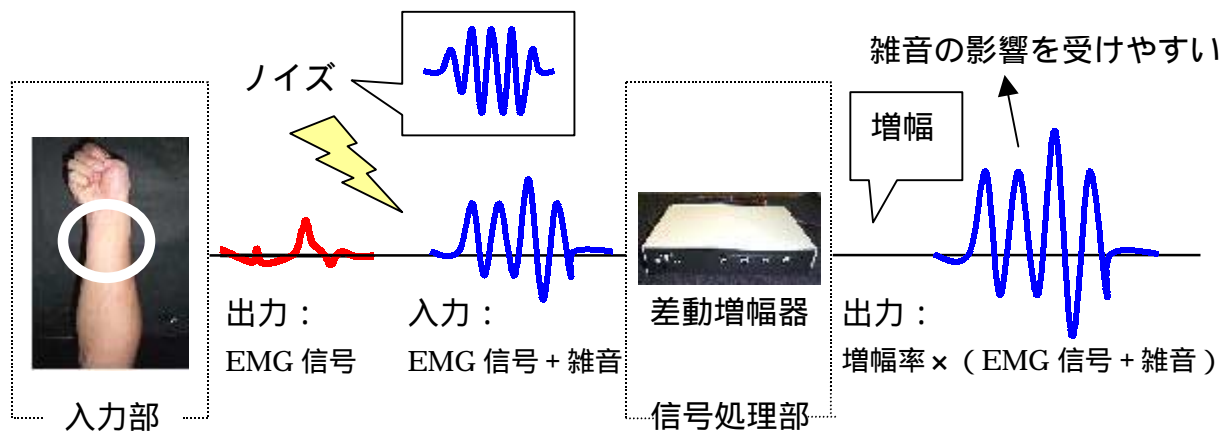


図 3.4 電解クリーム

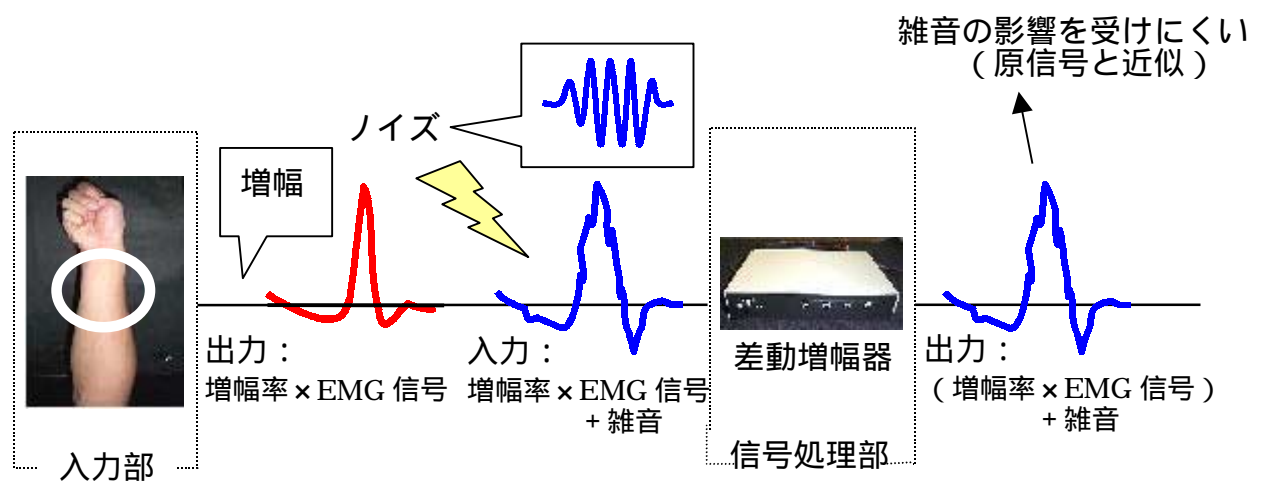
3.1.3 オペアンプの実装

実システムで採用する乾式電極は湿式電極と同等性能を得るため、電極に近い位置に初段の増幅器(電流増幅)を配置することによりセンサから差動増幅器までの配線で混入するノイズの影響を減少させている。具体的には図 3.3 (b) に示すように電極部に演算増幅器(オペアンプ)を実装する⁽⁵¹⁾。この手法を能動電極と呼び、電極インピーダンスを小さくし、電解ペーストを使用した湿式電極と同等性能にすることが可能である。このため、乾式能動電極は電解ペーストを使用しない。

基礎システムでは主に信号処理部において採取した EMG を増幅する. しかしながら, 図 3.5 (a) に示すようにノイズは入力部—信号処理部間の配線に混入ことが考えられ, 信号処理部にて増幅する信号は採取時の信号と比較し, S / N 比は減少する. つまり, 増幅位置を前段に配置することにより, ノイズの影響を抑えることが可能である. 図 3.5 (b) に示す手法を実システムでは使用する.



(a) 基礎システム



(b) 実システム(能動電極)

図 3.5 増幅位置の有無

3.1.4 電極数と電極位置

基礎システムでは手首挙動において EMG の最大検出可能な橈側主根屈筋と尺側主根屈筋上に電極をそれぞれ配置する。橈側主根屈筋と尺側主根屈筋を図 3.6 に示す。さらに、手首に電極を配し、掌を閉じた状態での背屈、掌屈動作により計測される手首挙動と EMG 波形(時系列波形, 周波数系列波形)を図 3.7, 図 3.8 にそれぞれ示す。図 3.7, 図 3.8 においてグレーの波形は橈側主根屈筋(Ch1:Channel 1)から発生した EMG を, 白色の波形は尺側主根屈筋(Ch2)からの EMG を示している。ここで, FFT データ(パワースペクトル)の波形について橈側主根屈筋の出力波形は上側に尺側主根屈筋からの出力波形は下側に出力している。これは視覚性を考慮し, Ch2 の波形に -1 を掛け反転させ出力している。

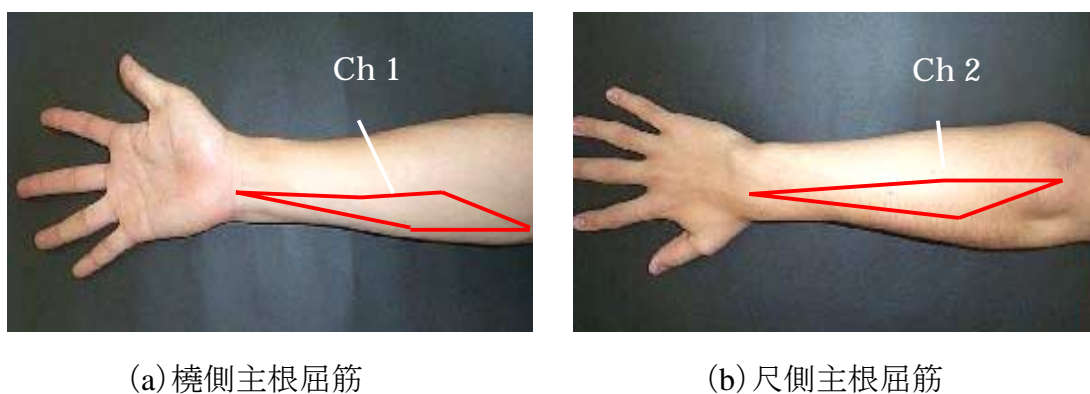


図 3.6 データ採取位置(基礎システム)

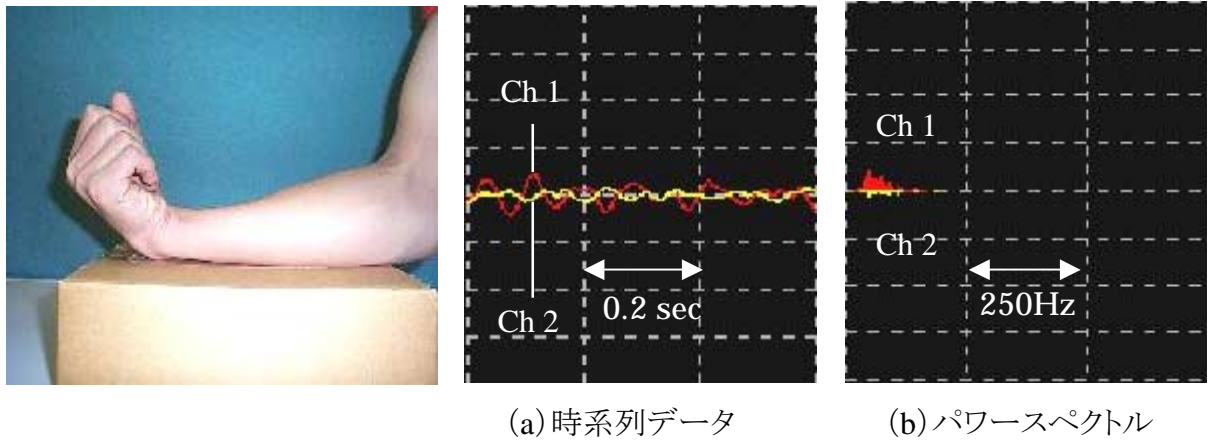


図 3.7 背屈

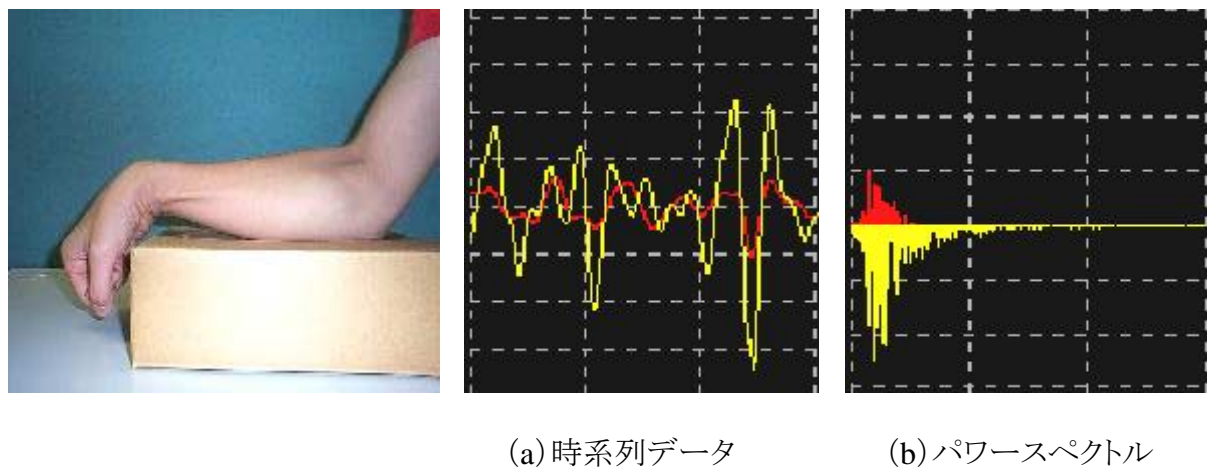


図 3.8 掌屈

本論文では前述の通り、提案システムの実用化を前提としているため、基礎システムにおいての認識対象パターン数(2 パターン)を増加させ、多様な手首挙動パターンを認識させる必要がある。したがって、認識パターンの増加に伴い、実システムでは電極数を2 極から4 極へと増加させる。実用化の観点から機器の操作性を考慮すると、機器を腕時計型やリストバンド型として利用することが適していると考えられる。このため、実システムでは電極位置を手首へと移行する。図 3.9 にデータ採取位置、図 3.10 に 4ch における電極配置を示す。図 3.11 (a), (b) に掌を閉じた状態での背屈、掌屈動作における EMG 波形(時系列波形および周波数系列波形)を示す。



図 3.9 データ採取位置(実システム)






図 3.10 電極配置(4ch:実システム)



時系列データ

パワースペクトル

(a) 背屈



時系列データ

パワースペクトル

(b) 掌屈

図 3.11 手首挙動と時系列波形とパワースペクトル(4ch)

3.1.5 電極方向

筋線維は筋肉を構成するものである。特定の動作の場合、特定の筋肉が収縮することから特定の筋線維からの EMG が発生する。基礎システムでは多様な動作を認識するため筋線維方向に対し、垂直に電極を配置する。これは電極(+, -入力)間に存在するすべての筋線維からの EMG を計測することが可能であるためである。

しかしながら、特定の動作を認識する場合、他の筋線維からのクロストークを防ぐことができることから筋線維方向に沿って電極を配置することが望ましい。また、この電極配置は前述の電極配置方向と比較して、電極数の増加にも容易に対応できるという長所もある。したがって、実システムでは筋線維方向に平行に電極を配置する。図3.12に電極配置方向を示す。

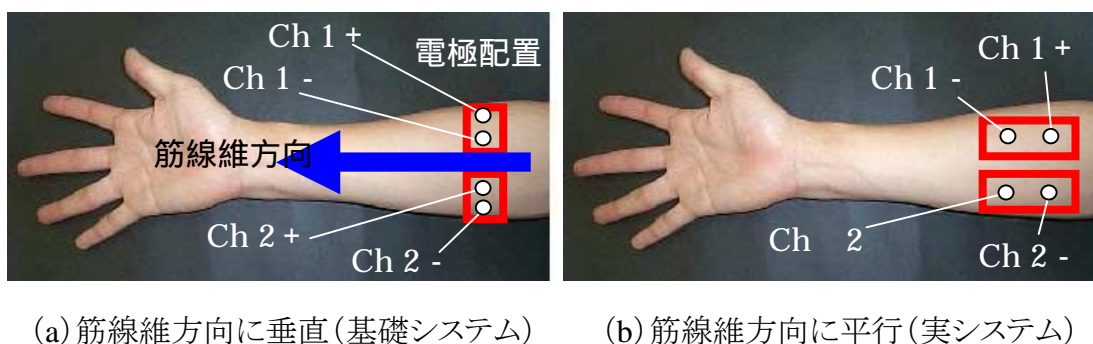


図 3.12 電極配置方向

3.2 信号処理部

信号処理部では、入力部にて計測した EMG(アナログ信号)に対してフィルタを介し、特定周波数帯域の EMG 抽出する。さらに、この抽出した EMG を増幅する。

表面筋電は一般に 2, 3Hz~2kHz 程度周波数帯域から検出される。EMG は微弱な信号であり、S / N 比は低い。この要因として、電源などからの電磁波ノイズ(60Hz)の割合が大きく、EMG よりも大きな信号となり EMG に混入していることが挙げられる。また、低周波領域に

は微弱ながら心電図, 脳波, アーチファクトノイズなどの雑音も混入することが考えられるため, ノイズが混入する可能性の低い 70Hz~2kHz の周波数帯域の EMG をローパスフィルタとノッチフィルタを用い, これらの周波数成分を除去する.

基礎システムでは抽出周波数帯域を 70Hz~2kHz と設定する. しかしながら, 採取される 1kHz 以上の EMG は微小であったことから, 実システムでは抽出周波数帯域を 70Hz~1kHz と設定する. また, A / D 変換カードの A / D 変換最大周波数は 1ch の場合, 50kHz であるため, 2ch 電極使用時には 20K サンプル×2ch で EMG をサンプリングする. 実システムでは電極数を 4 極へと追加することから 10K サンプル×4ch でサンプリングする. 表 3.1 に A / D 変換カード仕様を示す. さらに, 表 3.2 にデータ採取条件を示す.

表 3.1 A / D 変換カード仕様

入力チャンネル数	最大 4ch
A / D 分解能	12 bit
A / D 変換周波数	最高 50 KHz (1ch 時)
変換方式	逐次変換方式
入力電圧レンジ	-5.0~+5.0 V

表 3.2 データ採取条件

サンプリング周波数	2ch 時	20 KHz
	4ch 時	10 KHz
データ数	2ch 時	2048
	4ch 時	1024
FFT データの周波数間隔	9.766 Hz	
解析対象時間	2.0 sec (使用データ 1.0~1.1 sec)	

< 差動増幅器 >

電極からの EMG を信号ケーブルを通じ伝送すると、商用電源の電磁誘導によりケーブル線とアース線に同相のノイズが混入する。この同相ノイズ V_n を除去するため差動増幅器を利用する。双極誘導は測定電極 (+, - 入力) と不感電極 (グラウンド) で構成される。式 (3.1) に示す通り、基準電圧であるグラウンドと + 入力, - 入力の間の電圧の差分を取り増幅することにより、各入力 (+, - 入力) に同様の形状で混入するノイズを差し引くことでノイズを除去する。また、アンプの筐体はアルミ製とし、外来ノイズの影響を軽減させる。差動増幅回路構成を図 3.13 に示す。また、出力される増幅後の電圧を式 (3.1) に記述する。表 3.3 に差動増幅器の設計仕様を示す。また、2ch 用差動増幅器の概観を図 3.14 に、4ch 用差動増幅器の概観を図 3.15 に示す。

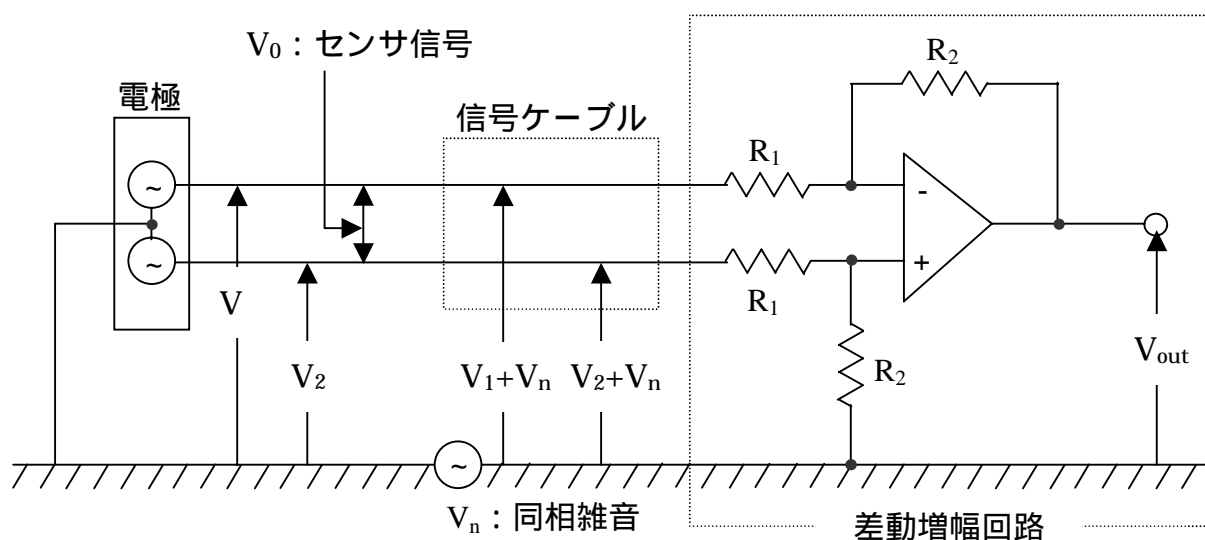


図 3.13 差動増幅回路の構成

$$\begin{aligned}
 V_{out} &= \frac{R_2}{R_1} (V_2 - V_1) \\
 &= -\frac{R_2}{R_1} V_0
 \end{aligned}
 \tag{3.1}$$

表3.3 差動増幅器の設計仕様

低域遮断周波数	70Hz (6次フィルタ)	
高域遮断周波数	2kHz (6次フィルタ)	
増幅率(ゲイン)	電極： 橈側主根屈筋 尺側主根屈筋 に配置時	約2000倍 (65dB)
	電極：手首に配置時	約3000倍 (65dB)
入力定格電圧	$\pm 2.5\text{mV}$	
CMRR※	60dB 以上	

※ CMRR: Common Mode Rejection Ratio: 同相信号除去比. ノイズ除去能力を示す.



(a) 外観



(b) 内観

図 3.14 2ch 用差動アンプの概観



(a) 外観



(b) 内観

図 3.15 4ch 用差動アンプの概観

増幅器に供給する電源として基礎システムでは 9V の直流電池を採用したが，実システムでは図 3.16 に示す 5V 直流安定化電源へと変更する。



図 3.16 直流電源(実システム)

3.3 特徴抽出部

特徴抽出部では，前項にて増幅した EMG データを A/D 変換し，計算機内に格納された前処理プログラムにより FFT 処理を施す．さらに，算出した FFT データ(パワースペクトル)より NN への入力ベクトルを作成する．NN は紙幣識別に使用したネットワークを EMG パターン認識に応用したものであるため，金種・国情報などのヘッダ情報を要求する．したがって，抽出した FFT データにヘッダ情報を付加する．

3.3.1 FFT

FFT とは離散フーリエ変換(DFT:Discrete Fourier Transform)の演算回数をビット反転処理とバタフライ演算により大幅に短縮させたものである．フーリエ変換とはフーリエ係数を求める処理で， $x(t)$ のフーリエ級数展開は


$$x(t) = a_0 + \sum_{n=1}^{\infty} (a_n \cos 2 \pi n t / T + b_n \sin 2 \pi n t / T) \quad (3.2)$$

と表せる. a_n, b_n はフーリエ係数で, a_0 は直流成分を表す. 直流成分は入力データの平均値で, フーリエ係数は信号 $x(t)$ に含まれる各成分の割合を示す. FFT 処理を施し, 算出されたフーリエ係数 a_n, b_n より式 (3.3) に示すパワースペクトルを求める.


$$X_n^2 = a_n^2 + b_n^2 \quad (3.3)$$

これは振幅スペクトルの2乗値に相当し, 各周波数成分に含まれるエネルギー比を表す. 認識対象とする掌を握った状態においての手首挙動と計測される EMG (時系列波形, パワースペクトル) を図 3.17 に示す. ここで, 時系列表示のグラフの1目盛りは x 軸方向では 0.2 秒, y 軸方向では 0.05V である. 周波数系列表示のグラフの1目盛りは x 軸方向では 250Hz, y 軸方向はパワースペクトルで 25 (≒ 約 0.061V) である. NN への入力データとなる EMG は前述の通り, 1.0~1.1 秒の安定状態の EMG とする.


パワースペクトルは式 (3.3) に示す通り, 正数である. Ch2, 3 のパワースペクトルについては Ch1, 4 と波形が重複するため, 出力されるパワースペクトルに -1 を掛け, グラフを反転させて表示している.




(a) 静止状態




(b) 背屈




(c) 掌屈




(d) 右



(e) 左



(f) 回内



(g) 回外

図 3.17 手首挙動と時系列波形とパワースペクトル(4ch)

3.3.2 入力ベクトルの算出

本項では手首挙動より得られた EMG データ(FFT データ)から NN の入力層細胞数分データを算出する手法について記述する. 本論文では NN の入力層細胞数を 2 種類(50, 80)用意する. まず, NN の入力層細胞数を 50 と設定する理由はつぎの通りである. 使用する NN の演算の高速化を実現するために, DSP ユニットにて処理することを前提としている. このため, DSP でのメモリ空間の制約上, 準備できる最大の NN の構成が $50 \times 50 \times 50$ であるためである. これは NN が前向き計算のみの場合 $100 \times 100 \times 100$ であるが, 後述するフィードバック演算処理を含む BP 法を使用するため半分の構成となる. したがって, 計算機上において, DSP ユニットを使用する場合との比較実験を行うために計算機上においても同様の構成である $50 \times 50 \times 50$ を用意する.

また, NN の入力層細胞数を 80 と設定する理由はつぎの通りである. 計算機シミュレーション(MS-DOS 上で動作)の場合, 16 ビット CPU でのメモリ空間上で用意できる最大の NN の構成が $80 \times 80 \times 80$ であるため, 入力層細胞数を 80 とし, これについても検討する. ここで, NN への入力値を SLAB 値と記述する.

<SLAB 値の算出手法>

EMG パターン認識に関する研究において, NN への入力値は主に手首挙動が静止状態である場合に発生した EMG を電圧オフセットとした全波整流値が使用される^{(10), (14), (16)}. 本論文においても全波整流値を用いて SLAB 値を作成したところ, ノイズの除去に加え, 認識率の向上も確認できた(後述の手法2を用い, 学習サンプル数:5 評価サンプル数:20 とした場合の 6 パターン(静止状態, 背屈, 掌屈, 右, 左, 回内, 回外の平均認識率 90.5%). しかしながら, 最終的に連続動作 EMG パターンを認識する上で, どの動作タイミングを静止状態と定義するかが困難であると考えられる. このため, 本論文では全波整流を用いない新たな SLAB 値の算出手法を提案する. ここでは, 2 手法を提案し, その算出方法を記述する.

(手法 1)

入力層細胞数を m 、電極数を n とすると、 (m/n) 個の特徴量を 1ch あたりに抽出する。図 3.18 に NN への入力データモデルを示す。また、FFT データの周波数間隔は表 3.2 に示すように 9.766Hz である。

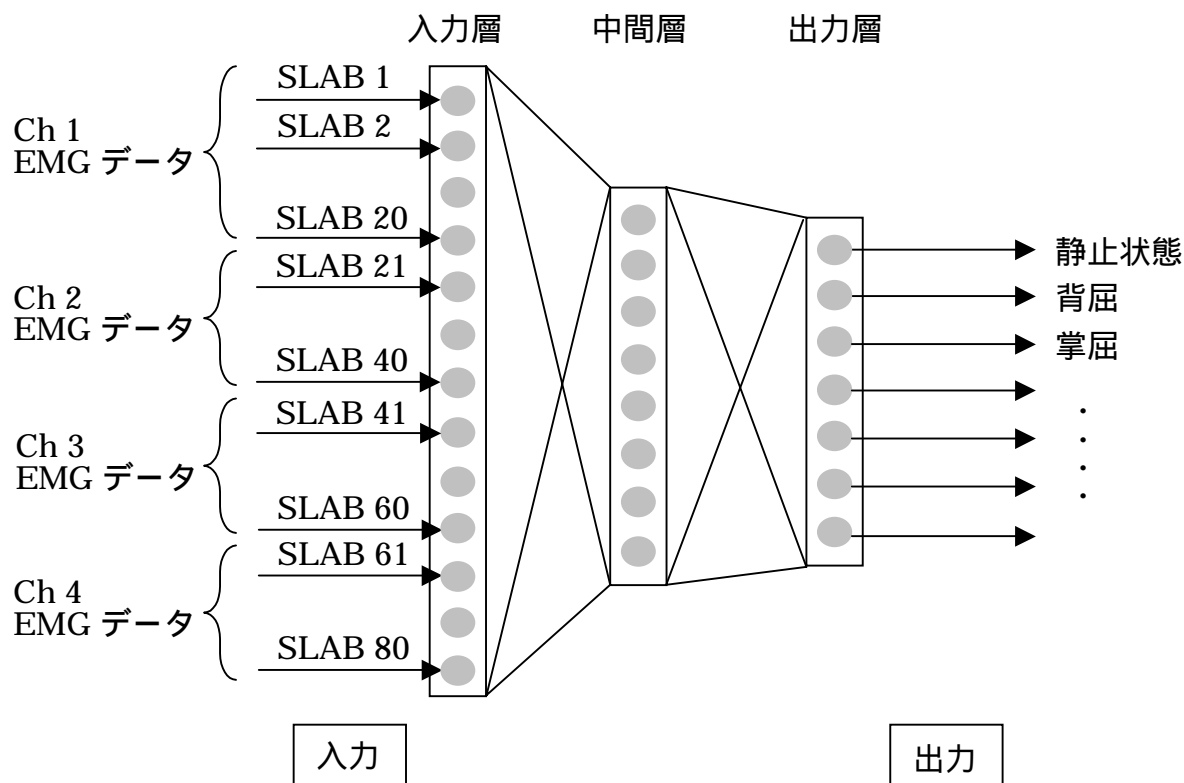


図 3.18 ニューラルネットワークへの入力データモデル

(入力層細胞数:80 電極数:4)

ここで、各チャンネル毎の入力 SLAB $k(k = 1, 2, \dots, (m/n - 1))$ への入力手法について述べる。抽出周波数帯域(70Hz~2kHz)内の FFT データを x 個とし、FFT データ $\{x/(m/n - 1)\}$ 個の加算和を算出する。この加算和を使用周波数帯域の FFT データの総和で正規化する。SLAB $(k+1)$ についても加算する周波数帯域をシフトすることにより同様の処理を行う。

SLAB (m/n) には FFT データの総和を適当な定数 $const$ で割る。これは入力値のダイナミックレンジを 0~10 の範囲にとどめるものとする。この一連の処理を 1ch あたりの SLAB 値の

算出方法とし、残りの(n-1)チャンネルに対しても同様の処理を行う。

本手法により得られた特徴ベクトル(SLAB 1, SLAB 2...SLAB m)をNNへの入力ベクトルとする。電極数を2, 入力層細胞数50とした場合の具体例を図3.19に示す。さらに、図3.20に橈側主根屈筋に電極を配置した場合の背屈動作のNNへの入力情報を示す。この波形より、EMGは各チャンネルとも主に低周波帯域において発生していることが確認できる。

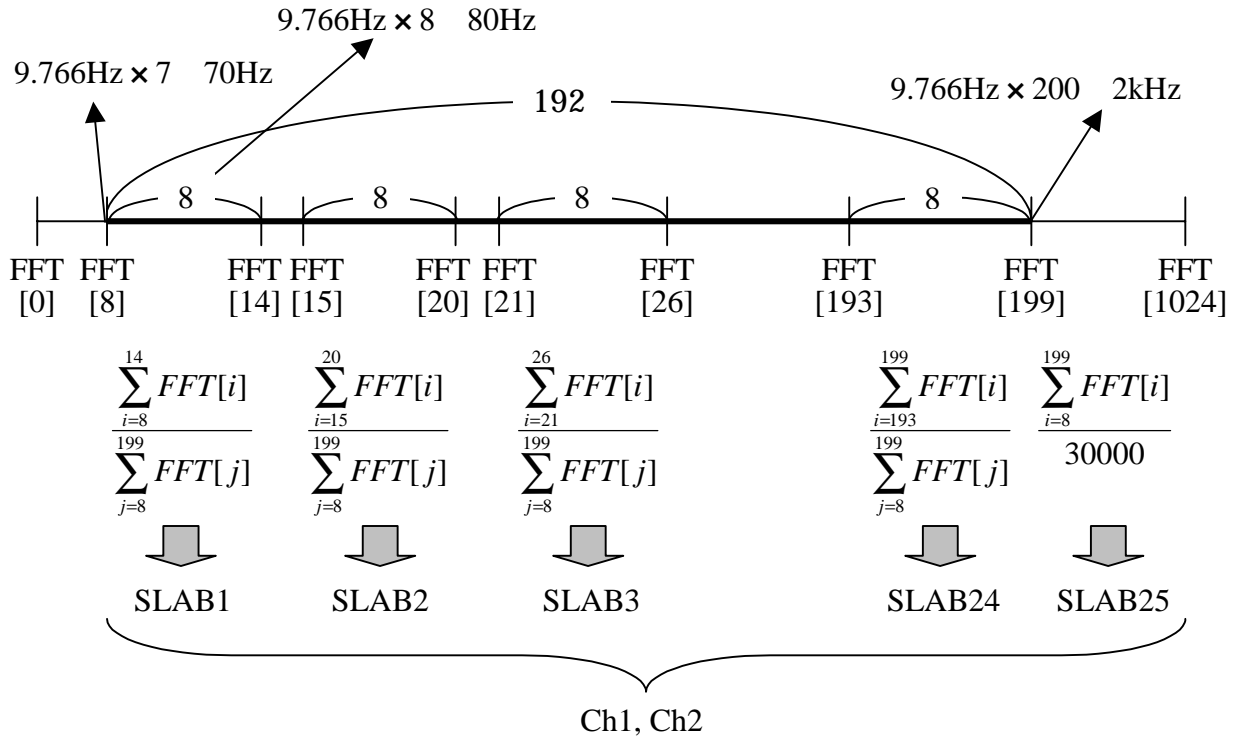
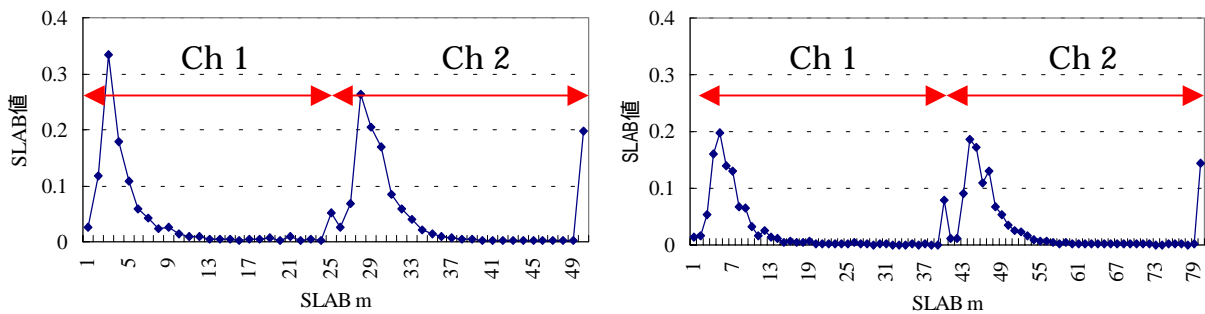


図 3.19 特徴抽出手法 1

(入力層細胞数:50 電極数:2 const:30000)



(a) 入力層細胞数:50

(b) 入力層細胞数:80

図 3.20 入力情報の比較(手首挙動:掌を閉じた状態, 背屈 電極数:2)

(手法 2)

(手法 1)と同様, 1chあたり (m/n) 個の SLAB 値を割り当てる. また, SLAB1~ $(m/n-1)$ については等間隔の周波数帯域 $\{x/(m/n-1) \times 9.766\}$ Hz における加算平均値をそれぞれ入力する. すべての入力の分母には入力値のオーダを抑制するために 10 を掛ける. SLAB (m/n) には各チャンネルのパワースペクトルの平均値を入力する. 図 3.21 に特徴抽出の具体例を示す(例は抽出周波数帯域 70Hz~1kHz).

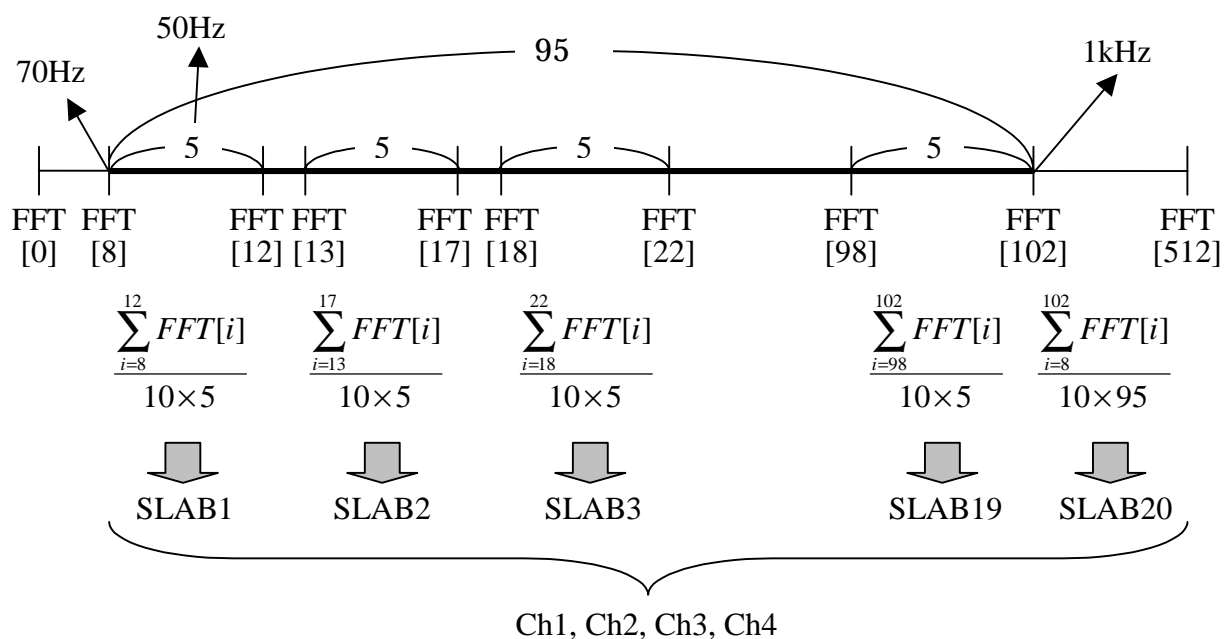


図 3.21 特徴抽出手法 2

(入力層細胞数:80 電極数:4)

3.3.3 ニューロデータ作成

本論文で使用する NN は元来, 紙幣識別用に開発された学習・識別システムである. このため, NN は入力データとして前項により算出した SLAB 値, 金種, パターン番号などを記述したヘッダ情報, 紙幣画像データを要求する. しかしながら, EMG パターン識別には画像データは不必要であることは自明である. したがって, 学習・識別システムの汎用性を保つためにダミーデータとして領域の確保のみを行う. 表 3.4 に EMG データ 1 サンプルのフォーマットを示す.

表3.4 NNデータのフォーマット

ヘッダ情報	64 byte	
ダミーデータ	400 byte	
SLAB値データ	入力層細胞数 50	200 byte
	入力層細胞数 80	320 byte

1 データの構成はヘッダ情報に 64 byte, ダミーデータに 400 byteを確保する. SLAB 値はプログラム中, float 型(4 byte)で宣言されているため, SLAB 値データには入力層細胞数が 50 である場合 50 個×4 byte=200 byte, 80 である場合 80 個×4 byte=320 byteを確保している. 表 3.5 は表 3.4 におけるデータ 1 サンプルのヘッダ部分の構成を示す.

表 3.5 ヘッダ情報のフォーマット

予約領域 1	(4 byte)
データ 1枚分の総サイズ	(4 byte)
パターン番号	(1 byte)
金種	(1 byte)
方向	(1 byte)
国情報	(1 byte)
通し番号	(2 byte)
機種	(1 byte)
号機	(1 byte)
種別	(1 byte)
センサ番号	(1 byte)
画像のXサイズ(画素数)	(2 byte)
画像のYサイズ(画素数)	(2 byte)
センサ有効域チャンネル番号(L)	(2 byte)
センサ有効域チャンネル番号(H)	(2 byte)
予約領域 2	(2 byte)
センサ分解能(X方向)	(1 byte)
センサ分解能(Y方向)	(1 byte)
予約領域 3	(6 byte)
紙幣の中心画素のX座標	(2 byte)
紙幣の中心画素のY座標	(2 byte)
画像データのオフセット	(4 byte)
予約領域 4	(4 byte)
SLAB値の種類数	(1 byte)
1種類目のSLAB値のマスクID	(1 byte)
1種類目のSLAB値の個数	(1 byte)
予約領域 5	(5 byte)
SLAB値のオフセット	(4 byte)
予約領域 6	(4 byte)

- 予約領域

学習システムを拡張するために用意する.

- データ 1 枚分の総サイズ

上記で示したヘッダ情報 64 byte, ダミーデータ 400 byte, SLAB 値データ入力層細胞数 50 の場合 200 byte で計 664 byte である. 入力層細胞数 80 の場合 320 byte で計 784 byte である.

- 画像フレームの X サイズ, Y サイズ

画像データの大きさ.

- 画像データのオフセット

ヘッダの先頭を 0 バイト目と設定する場合, 画像データの先頭からのバイト数.

- 1 パターン目の SLAB 値の数

ニューラルネットへの入力層細胞数.

- SLAB 値データのオフセット

ヘッダの先頭を 0 バイト目と設定する場合, SLAB 値データの先頭からのバイト数.

ここで, 作成した手首挙動パターンごとのデータの集合をデータファイルとし, 同挙動パターンを 1 ファイルに管理する. データファイルの構成を図 3.22 に示す.

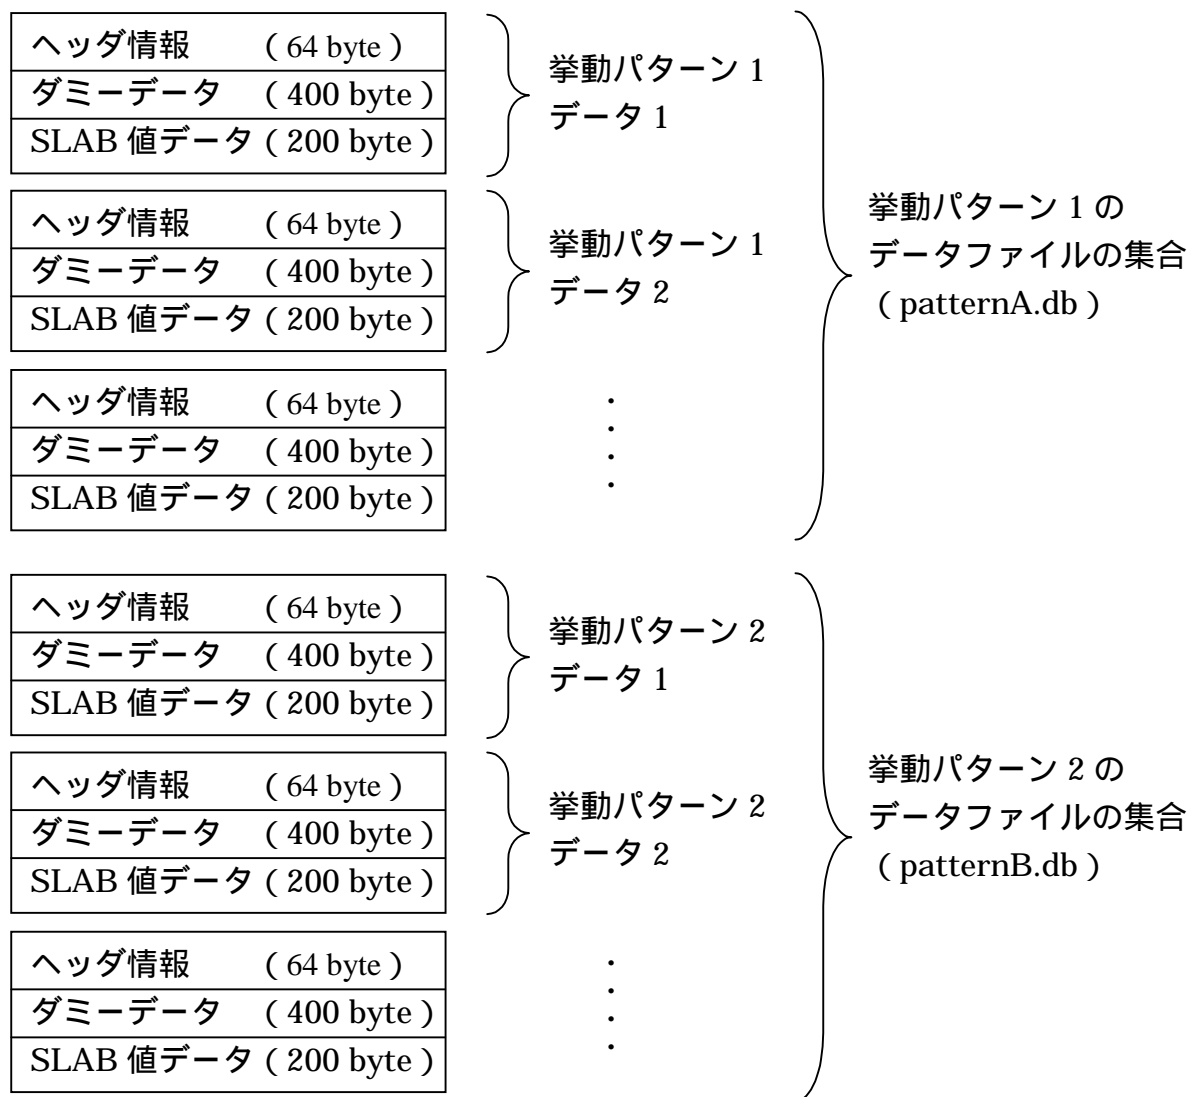


図 3.22 データファイルの構成

(入力層細胞数を 50 とした場合)

3.4 登録・識別部

本節では取得した各パターンの EMG (FFT データ) を認識する上で使用するニューロ学習・評価システムおよび NN の構成について記述する。

<ニューロ学習システム>

ニューロ学習システム(以下, 学習システムと略記)は後述の改良型 BP 法を学習アルゴリズムとするバッチファイルである. 学習システム全体の動作手順は下記に示すように

- ① 学習データの抽出
- ② SLAB ファイルの並び替え
- ③ 教師ファイル作成
- ④ 学習

の流れで処理される. 以下に各プログラムの動作内容について記述する.

① 学習データの抽出

NN パラメータ設定ファイルには図 3.23 に示すパラメータを設定する. この NN パラメータ設定ファイルにて指定した 1 パターンの学習サンプル数分だけデータファイル(図 3.22 参照)の先頭から抽出し, 学習データファイルを作成する. 図 3.24 に具体例を示す.

入力層細胞数	学習定数
中間層数	慣性定数
中間層細胞数	振動定数
出力層細胞数	最終誤差判定値
学習パターン数	最大学習回数
1 パターンの提示(学習)枚数	

図 3.23 NN パラメータ設定ファイルの内容

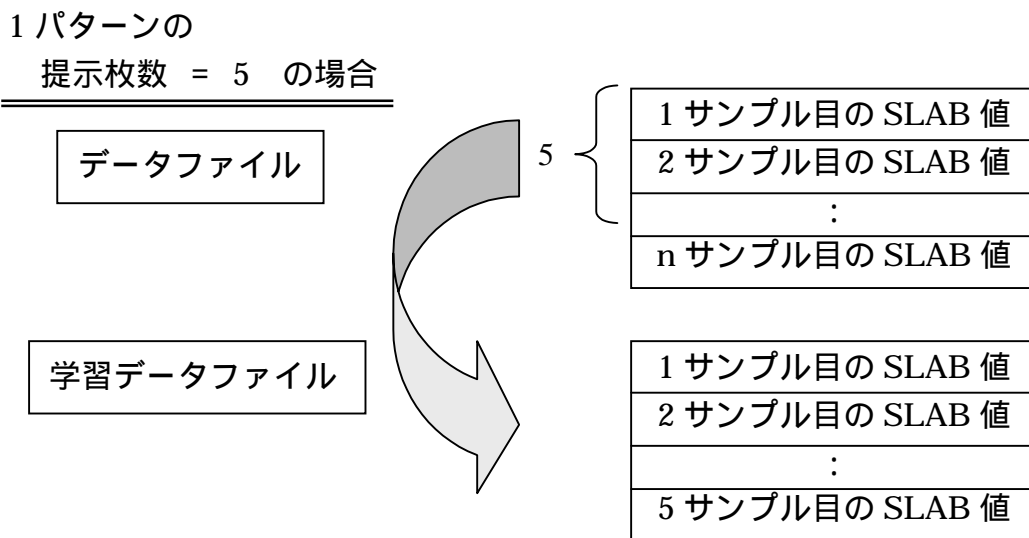


図 3.24 学習データ抽出イメージ

② SLAB ファイルの並び替え

学習データファイルの SLAB 値(3.3.2 節により取得した各パターンの SLAB 値)を抽出し、SLAB ファイルを作成する. さらに、学習収束を安定させ、かつ収束条件に早く到達するために SLAB ファイルを並び替え、学習ファイルを作成する. 認識パターン数を 2 とした場合の学習ファイルと各 SLAB ファイルの関係を図 3.25 に示す.

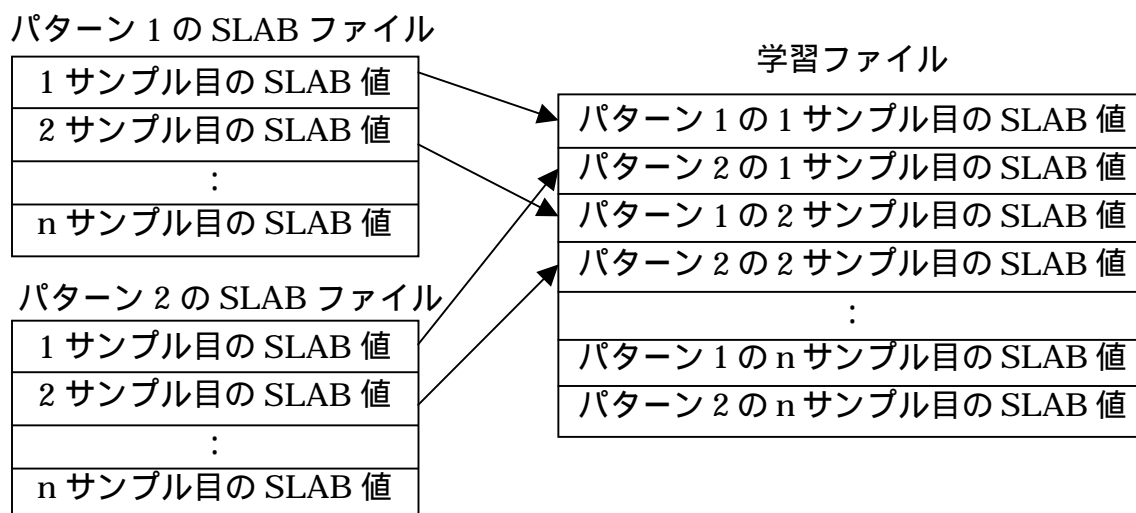


図 3.25 学習ファイルと各 SLAB ファイルの関係

(認識パターン数:2)

③ 教師ファイル作成

NN パラメータ設定ファイルで指定された認識パターン数に従い, NN への教師ファイルを作成する. NN の期待出力として正解ならば 1, 不正解ならば 0 を教師する行列を作成する. 作成された行列は認識パターン数を n とすると, $n \times n$ 行列である. 図 3.26 に背屈と掌屈を認識パターンとしたときの教師ファイルの具体例を示す.




図 3.26 教師ファイル作成イメージ

(認識パターン数:2)

④ 学習

各パターンの EMG の学習に階層型 NN を適用する. ここでは, NN の学習に使用する改良型 BP 法について記述する. 学習とは提示された正解パターンに対応するニューロンが正しい発火をできるように誤差を減少させ, 重みを更新する作業である. 更新された新しい重み w_{new} は式(3.4)に示すように現在の重み w_{old} と重みの修正量 Δw の和で表される. ここでは, 出力層から入力層に向けての層ごとの重み更新法を示し, Δw の求め方について述べる.

$$w_{new} = w_{old} + \Delta w \quad (3.4)$$

まず, 出力層－中間層間の重み修正方法について述べる. ある入力パターン与えた場合, 出力層の k 番目のニューロンの期待出力 d_k と k 番目のニューロンの実際の出力 o_k の誤差 E_p は

$$E_p = \frac{1}{2}(d_k - o_k)^2 \quad (3.5)$$

と表される。したがって、1つの学習パターン q における出力層の誤差 E_q は

$$E_q = \frac{1}{2} \sum_{k=1}^K (d_k - o_k)^2 \quad (3.6)$$

と示される。すべての学習パターンの誤差和を E とすると、誤差関数は

$$E = \frac{1}{2} \sum E_q \quad (3.7)$$

と表される。また、ニューロンへの入力を式(3.8)に出力を式(3.9)に示す。ここで、 w_{kj} はニューロン k からニューロン j への重みである。

$$x_k = \sum_{j=1}^J w_{kj} y_j \quad (3.8)$$

$$O_k = f(x_k) \quad (3.9)$$

本論文では出力関数として、式(3.10)に示すシグモイド関数を用いる。ここで TH はニューロンの閾値を示す。ここでは $TH=0$ と設定する。

$$f(x) = \frac{1}{1 + \exp\left(\frac{-x + TH}{T}\right)} \quad (3.10)$$

図 3.27 に示すようにネットワークの温度 T は誤差に比例して、1.3 から 0.7 まで変化させ、アニーリングを行う。この操作は学習プログラムが自動的に行う。




図 3.27 シグモイド関数

式(3.7)と式(3.8)より最急降下法と連鎖則を適用し,

$$\begin{aligned}\Delta w_{kj} &= -\eta \frac{\partial E}{\partial w_{kj}} \\ &= -\eta \frac{\partial E}{\partial x_k} \frac{\partial x_k}{\partial w_{kj}}\end{aligned}\quad (3.11)$$

誤差の変化をニューロンへの総入力の変化の関数として

$$-\frac{\partial E}{\partial x_k} = \delta_k \quad (3.12)$$

と表すことができる. ここで, η を学習定数とする. したがって

$$\Delta w_{kj} = \eta \delta_k y_j \quad (3.13)$$

となる. つまり, 重みを $\delta_j \cdot o_j$ に比例して更新することにより E を減少させることができる.

$$\begin{aligned}
\delta_k &= -\frac{\partial E}{\partial x_k} \\
&= -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial x_k} \\
&= -\{-(d_k - o_k)\}f'(x_k) \\
&= (d_k - o_k)f'(x_k)
\end{aligned} \tag{3.14}$$

出力層以外の重み変更方法は期待出力が存在しないため、同様の処理が不可能である。そのため、出力層以外の場合は連鎖則を再び適用し、

$$\begin{aligned}
\Delta v_{ji} &= -\eta \frac{\partial E}{\partial w_{ji}} \\
&= -\eta \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial x_j} \frac{\partial x_j}{\partial w_{ji}} \\
&= -\eta \frac{\partial E}{\partial o_j} f'(x_j) y_j \\
&= -\eta \sum_k \frac{\partial E}{\partial x_i} \frac{\partial x_i}{\partial o_j} f'(x_j) y_j \\
&= -\eta \sum_i \frac{\partial E}{\partial x_i} w_{ji} f'(x_j) y_j
\end{aligned} \tag{3.15}$$

ここで、式(3.12)より

$$= \eta \sum_i \delta_i w_{ji} f'(x_j) y_j \tag{3.16}$$

よって、式(3.14)に対応させて記述すると

$$\delta_k = f'(x_j) \sum_i \delta_i w_{ji} \tag{3.17}$$

となる。この重みの修正方法を **BP 法** と呼ぶ。さらに最急降下法の収束を早めるために上記に **BP 法** に現在の重みの変化を考慮し、慣性項と振動項を付加する。本論文では式(3.18)を **NN** の学習アルゴリズムとして採用する。以降、改良型 **BP 法** と記述する。

$$\Delta W_{jk}(t) = -\eta \delta_k O_j + \alpha \Delta W_{jk}(t-1) + \beta \Delta W_{jk}(t-2) \quad (3.18)$$

ここで t は学習回数, α は慣性項の比例定数, β は振動項の比例定数を示す. 慣性項により学習初期には誤差が局所的に増加するような方向へも変化が起こり, その後全体的な最小値へ向かうことが期待できるからである. すなわち, 学習初期でネットワークがローカルミニマムに与えられる機会を減少させることができる. また, 振動項は極小値から脱出させる働きをする. これは Asakawa らがバネ-ダッシュポット系として振動項を導出し, 図 3.28 に示す慣性項・振動項の境界条件を設定した⁽⁵⁶⁾. したがって, 慣性項・振動項について, その領域内で線形計画法と同じような形で任意の組み合わせをその範囲内から試行錯誤的に選択すればよい. この手法を用いて, 竹田らは紙幣識別において, 最も早く安定した状態で学習収束状態に到達する慣性項と振動項の最適な組み合わせ ($\alpha = 0.95$, $\beta = -0.1$) を算出ことを報告している⁽¹⁸⁾. 本論文では任意に選択した 10 種類の組み合わせのうち, 最も学習収束が安定していた前述の組み合わせを採用し, 学習を行う.




図 3.28 慣性定数と振動定数の範囲

上記の改良型 BP 法に前述のパラメータを適用し, NN ウェイトを作成する. 学習プログラムは NN パラメータ設定ファイルに記述された最終誤差判定値または学習回数の方の条件を満足した時点で終了する. 図 3.29 に NN の学習状態を示す. 図中の左下は出力層ニューロンの誤差値 E (式 (3.7) 参照) を表す誤差曲線である. 右半分は各パターン出力ユニット値を表す.

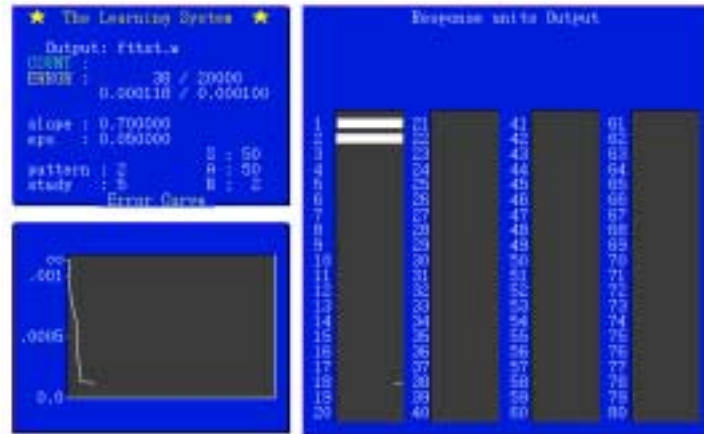


図 3.29 学習状態画面(認識パターン数:2)

⑤ 評価

学習により作成した NN ウェイトを用いて、未学習データを評価する。図 3.30 に認識パターン数を 2 とした場合の評価実行画面を示す。図中の右半分は 1 行目がパターン 1 に対する NN の反応値, 2 行目がパターン 2 に対する NN の反応値を表す。この場合、パターン 1 は手首挙動が背屈であるデータ、パターン 2 は掌屈であるデータを示す。したがって、図 3.30 の評価画面より NN はパターン 2 に大きく反応していることから、NN の判定によると入力データは被験者の手首挙動が掌屈のデータであることが判明する。




図 3.30 評価状態画面(認識パターン数:2)

4 実験

本章では 3 章にて述べた基礎システムと実システムを用い、EMG パターン認識実験を行う。被験者は図 4.1 のように右腕の脇をしめ、腕を 90 度に曲げた状態で手首を動作させ、EMG を計測する。実験対象とする EMG は動作開始後 1.0～1.1 秒後に計測される定常状態の EMG を用いる。これは動作のタイミング、手首挙動速度を考慮すると、NN には過渡状態の EMG と比較し、定常状態の EMG は認識の容易なデータであると考えられるためである。本論文では EMG パターン識別において提案システムの基本性能を確認することを最優先事項とし、定常状態の EMG を実験対象データと決定する。



図 4.1 EMG 採取姿勢

4.1 前腕に電極を配置

EMG パターン識別において、NN の有用性を確認するために本節では基礎システムに基づいた手首挙動識別実験を行う。手首挙動の際、橈側主根屈筋と尺側主根屈筋が使用される。すなわち、手首挙動において、これらの筋上に電極を設置する場合、EMG の最大検出が可能である。ここでは 2 極の湿式電極をこれらの筋上に設置する(図 3.6 参照)。また、認識動作パターン数を 2(背屈・掌屈)とする。入力ベクトルの抽出手法は 3.3.2 項の(手法 1)を採用する。本節では下記の 4 種類の実験を行う。

- (実験 1) 被験者 A (21 歳男性健常者) のみの EMG データを NN への教師データ(学習データ)とし, 被験者 A の EMG データを認識対象データ(評価データ)とし, 実験を行う.
- (実験 2) 被験者 A のみの EMG データを NN への学習データとし, 被験者 A 以外の EMG データを評価データとし, 実験を行う.
- (実験 3) 被験者 A 以外の被験者 5 名(全員男子大学生健常者)各 1 サンプルを学習データとし, 被験者 A のみのデータを評価データとする実験を行う.
- (実験 4) 被験者 A 以外からの EMG データを学習データとし, 被験者 A 以外の被験者 20 名(全員男子大学生健常者)各 1 サンプルの EMG データを評価データとし, 実験を行う.

実験 1～実験 4 においての実験条件を表 4.1 に, 実験結果を表 4.2 に示す. また, 認識率は式(4.1)に示す通り, 入力パターンが目的対象動作に最大の反応値を示したものを正解とする.

$$\text{認識率} = \frac{\text{目的対象動作が最大発火した個数}}{\text{未学習データ数}} \times 100 \quad (4.1)$$

表 4.1 実験条件(実験 1~4)

電極数	2
電極種類	湿式電極
NN 構成	50×50×2
学習アルゴリズム	改良型 BP 法 式(3.18)
学習定数 η	0.05
慣性定数 α	0.95
振動定数 β	-0.1
正規化定数k	30000
1 パターンあたりの 学習サンプル数	5
1 パターンあたりの 評価サンプル数	20
最大学習回数	20000
最終誤差判定値	1.0E-4

※ 出力層細胞にはそれぞれの手首挙動の状態に発火する細胞を割り当てる

すなわち, 認識パターン数 = 出力層細胞数 である.

正規化定数kについては 3.3.2 項参照

表 4.2 実験結果(実験 1~4)

	認識率			
	実験 1	実験 2	実験 3	実験 4
背屈	100.0%	100.0%	100.0%	100.0%
掌屈	100.0%	100.0%	100.0%	100.0%
平均	100.0%	100.0%	100.0%	100.0%

上記の結果より、EMG データは個人差が大きく低再現性であるが、手首挙動の認識には NN が有用であることが示された。また、NN が EMG パターンの個人差を吸収していることも確認できる。認識率はすべての実験において良好な結果を示したが、実験 1 の NN の反応値と実験 2～実験 4 の反応値を比較すると、実験 1 の NN の反応値が最も安定した出力結果が得られた。

図 4.2 に同一被験者における学習データのばらつきを示す。また、図 4.3 に異なる被験者 5 人におけるデータのばらつきを示す。これらグラフからも個人差によるデータのばらつきと比較し、同一被験者のデータのばらつきは微小であるが、同一被験者間においてもデータのばらつきが顕著であることを確認することができる。

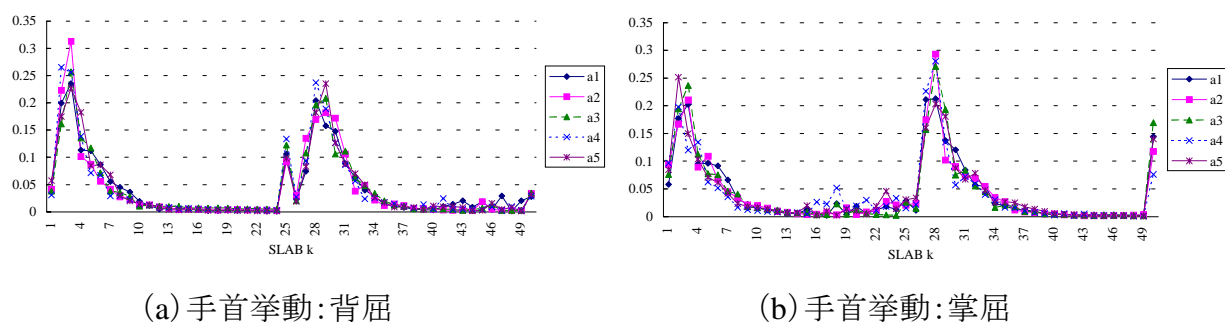


図 4.2 被験者 A の学習データのばらつき

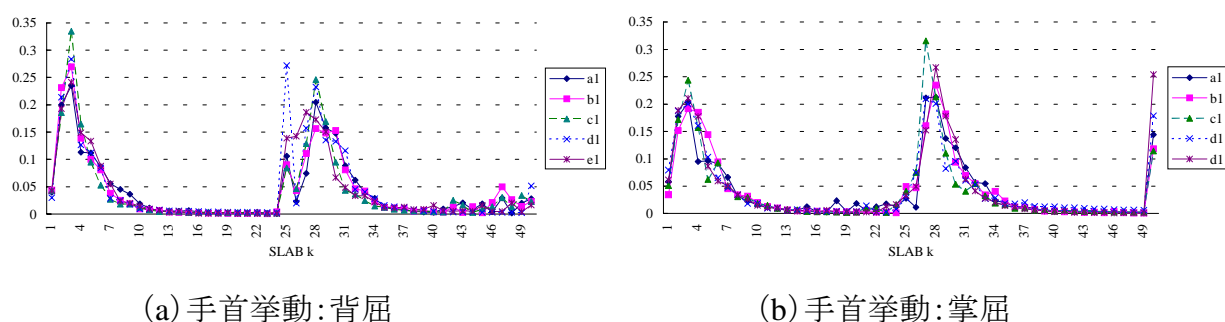


図 4.3 被験者 5 人の学習データのばらつき

図 4.4 に実験 2 における NN の反応値を、図 4.5 に実験 4 における NN の反応値を示す。図中 x 軸上の b1 は被験者 B の 1 サンプル目のデータを示す。データの反応値が特に低かった図 4.4 (a) と図 4.5 (b) 中の被験者 C の 5 サンプル目のデータの反応値に着目すると、図 4.4 (a) の反応値と比較し、図 4.5 (a) の反応値の方が背屈に反応する細胞と掌屈に

反応する細胞の反応値の差が拡大していることが確認できる. 実験2の結果から, 特定個人により多様な被験者の手首挙動認識が可能であることが示された. しかしながら, 複数被験者の手首挙動の認識について, さらなる汎化能力の向上を検討する場合, 複数被験者により作成した学習データを使用することが望ましいことが判明した. また, この結果により, 学習データに複数被験者を用いることは, 特定被験者のみで学習データを作成する場合と比較し, 学習収束までには時間を費やすものの, 個人差間のEMGデータのばらつきを吸収できることが示された.

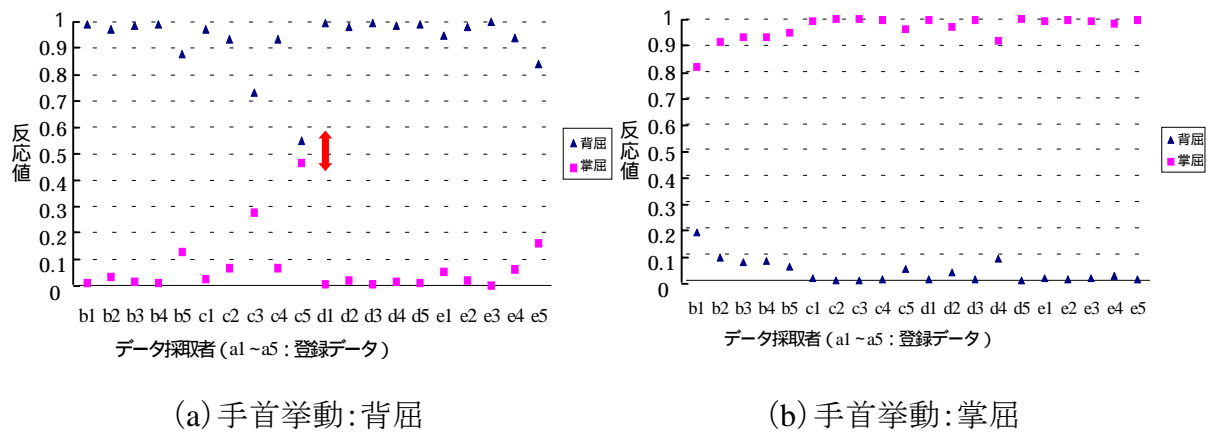


図 4.4 実験 2 の場合での NN の反応値

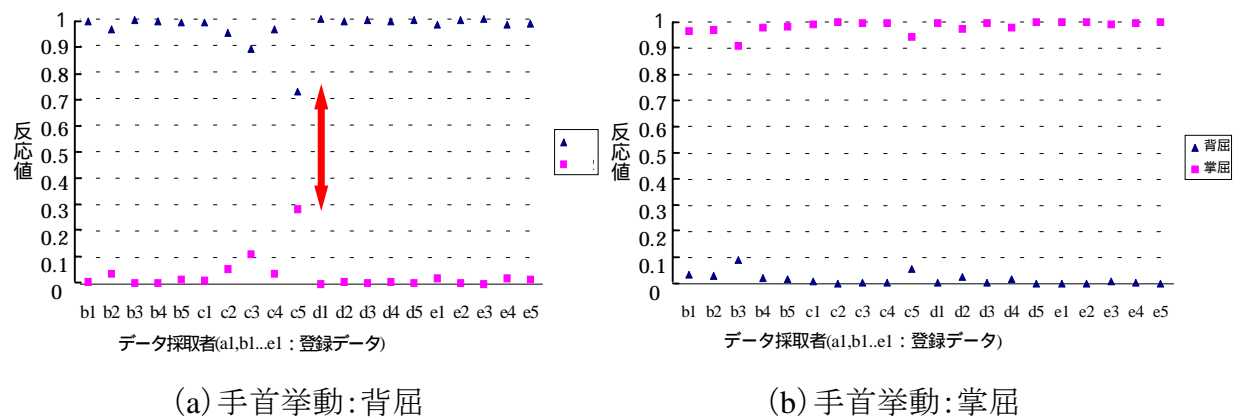


図 4.5 実験 4 の場合での NN の反応値

<NN の構成の検討>

実験 1~実験 4 では手首挙動において, 良好な認識結果を得た. この実験結果の要因として, 最適な測定位置に電極を設置したこと, 認識パターン数が少数であることが列挙され

る.したがって,以降では認識パターン数を増加させ実験を行う.また,NNの構成を検討するために種々の実験を行う.一般に入力層細胞数と出力層細胞数の関係は学習の収束性と未学習データに対する汎化能力の観点から式(4.2)に示すようなNNの構成が望ましいと報告されている⁽³⁰⁾.このため,本論文では式(4.2)の条件を満たすNN構成を検討する.

$$\text{入力層細胞数} > \text{出力層細胞数} \quad (4.2)$$

4.1.1 入力層細胞数の検討

手首挙動により,マウスの基本動作6パターン(上・下・右・左・右クリック・左クリック)を実現するために認識パターン数を2,4,6と増加させる.さらに,入力層細胞数を2種類(50,80)検討する.また,それぞれの実験において掌を開いた状態,閉じた状態での動作パターンについても検討する.認識パターンとする動作を表4.3に示す.被験者が掌を閉じた状態で背屈動作を行ったデータについて,入力層細胞数を50および80とした入力波形の例を図3.20(a),(b)に示す.これより,類似波形を示しているため,NNへ入力される入力値は妥当であることが判明している.

表 4.3 認識パターン

認識パターン数	手首挙動と対応する出力層細胞
2	背屈・掌屈
4	背屈・掌屈・右・左
4	背屈・掌屈・回内・回外
6	背屈・掌屈・右・左・回内・回外

(実験 5) 被験者 A のみの EMG データを NN への学習データとし, 被験者 A のみのデータを評価データとした実験を行う.

NN の構成: $50 \times 50 \times (2, 4, 6)$


(実験 6) 実験 5 と同様, 被験者 A の EMG データを NN への学習データとし, 被験者 A のデータを評価データとした実験を行う.

NN の構成: $80 \times 80 \times (2, 4, 6)$


実験 5 および実験 6 の実験条件を表 4.4 に示す. 使用する CPU は Intel Pentium II Processor 233 MHz とする. 実験 5, 実験 6 ともに認識パターン数の増加から学習時間が飛躍的に増大したことから, NN の収束条件である最大学習回数と最終誤差判定値に変更を加える. 図 4.6(a) に掌を開いた状態と図 4.6(b) に掌を閉じた状態 NN への入力波形を示す. また, 使用する電極は図 3.3(b) に示す乾式電極を使用し, 電極配置は図 3.6 に示す通りである.

表 4.4 実験条件(実験 5, 6)


電極数	2
電極種類	乾式電極
学習アルゴリズム	改良型 BP 法 式(3.18)
学習定数 η	0.05
慣性定数 α	0.95
振動定数 β	-0.1
正規化定数 k	30000
1 パターンあたりの 学習サンプル数	5
1 パターンあたりの 評価サンプル数	25
最大学習回数	5000
最終誤差判定値	$5.0E-4$




(i) 背屈




(ii) 掌屈




(iii) 右



(iv) 左



(v) 回内



(vi) 回外

(a) 掌を開いた場合

(b) 掌を閉じた場合

図 4.6 NN への入力波形 (入力層細胞数: 50)

(x 軸方向: SLAB 数 y 軸方向: SLAB 値)

表 4.5 手首挙動を背屈・掌屈で実験した場合

(a) 掌を開いた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	50.0%	100.0%
掌屈	95.0%	90.0%
平均	72.5%	95.0%

(b) 掌を閉じた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	100.0%	95.0%
掌屈	100.0%	80.0%
平均	100.0%	87.5%

表 4.6 手首挙動を背屈・掌屈・右・左で実験した場合

(a) 掌を開いた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	40.0%	50.0%
掌屈	90.0%	85.0%
右	40.0%	50.0%
左	80.0%	65.0%
平均	62.5%	62.5%

(b) 掌を閉じた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	85.0%	65.0%
掌屈	100.0%	90.0%
右	55.0%	45.0%
左	90.0%	80.0%
平均	82.5%	70.0%

表 4.7 手首挙動を背屈・掌屈・回内・回外で実験した場合

(a) 掌を開いた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	60.0%	45.0%
掌屈	70.0%	55.0%
回内	60.0%	45.0%
回外	85.0%	80.0%
平均	68.8%	56.3%

(b) 掌を閉じた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	90.0%	90.0%
掌屈	95.0%	70.0%
回内	95.0%	35.0%
回外	90.0%	100.0%
平均	92.5%	73.8%

表 4.8 手首挙動を背屈・掌屈・右・左・回内・回外で実験した場合

(a) 掌を開いた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	40.0%	55.0%
掌屈	100.0%	55.0%
右	35.0%	60.0%
左	50.0%	50.0%
回内	45.0%	35.0%
回外	85.0%	35.0%
平均	59.2%	48.3%

(b) 掌を閉じた場合

	入力層 細胞数 50	入力層 細胞数 80
背屈	95.0%	45.0%
掌屈	95.0%	55.0%
右	65.0%	60.0%
左	95.0%	50.0%
回内	95.0%	35.0%
回外	90.0%	35.0%
平均	89.2%	46.7%

表 4.5(a)～表 4.8(b) に示すように、掌を閉じた状態の認識率が掌を開いた状態の認識率と比較し、高いことが示された。これは、掌を閉じた状態の方がより筋肉の緊張状態を強調することとなり、EMG が手首挙動に敏感に発生するからであると推察される。この結果より、次項および次節では被験者の手首挙動は掌を閉じた状態で実験することとする。また、入力層細胞数が 80 の場合、50 と比較し、識別性能が低下することが確認できた。すなわち EMG の FFT データは 10Hz や 20Hz の範囲での振幅の変動が大きく、入力層細胞数が 50 から 80 へと変化する際、SLAB 値への加算個数が 8 から 5 へと変化する。これは図 3.20(a)、(b) より入力層細胞数の変化に伴い、入力値が全体的に低下していることから確認できる。したがって、入力層細胞数 80 は加算個数が減少するために平均化処理の観点からノイズの影響を受けやすくなったと考えられる。しかしながら、入力層細胞数が 80 の場合は 50 と比較し、電極数の増加に伴い、NN への入力情報の増加に柔軟に対応することが可能であることから、以降の実験では入力層細胞数を 80 と定める。また、表 4.8(b) においては、学習は目標誤差 ($5.0E-4$) にまで収束しなかった。これは認識パターン数の増加に伴い NN の規模が大きくなったことに加え、EMG の再現性の低さに起因するものと推察される。

4.1.2 中間層細胞数の検討

前項にて、入力層細胞数を決定した。本項では中間層細胞数についても検討し、NN の構成を決定する。中間層細胞数は入力層細胞数と同数である 80 とその半数である 40 を検討する。入力層細胞数の半数である 40 と検討する要因としては著者がこれまで紙幣識別や米選別などにおける NN の構成を決定する場合に経験上、入力層細胞数の半数程度として実験を行ってきたことに起因する^{(31), (32)}。また、本項では手首挙動において、個人による EMG の変動を実験により定量的に示す。さらに、誤認識した評価データを学習データに追加し、再学習を行う追加学習の有用性と個人差における EMG の認識率を得るために、3 種類の実験を行う。また、インタフェースのイベント情報として待機信号を追加することも視野に入れ、前項にて使用した認識パターン 6 動作に静止状態を加え、7 動作での認識実験を行う。

(実験 7) 被験者 A の EMG データを NN への学習データとし、被験者 A のデータを評価データとした実験を行う。

NN の構成: $80 \times 40 \times 7$
 $80 \times 80 \times 7$

(実験 8) 被験者 A の EMG データを NN への学習データとし、被験者 A 以外の被験者 13 名 (18 歳～24 歳の男性健常者) の EMG データ各 1 サンプルに対し、手首挙動認識実験を行う。

NN の構成: $80 \times 40 \times 7$
 $80 \times 80 \times 7$

(実験 9) 認識率向上を図るため、実験 8 において誤認識した評価データを学習データに追加し、追加学習を行う。

NN の構成: $80 \times 40 \times 7$
 $80 \times 80 \times 7$

表 4.9 実験条件(実験 7~9)

電極数	4		
電極種類	乾式電極		
学習アルゴリズム	改良型 BP 法 式(3.18)		
学習定数 η	0.05		
慣性定数 α	0.95		
振動定数 β	-0.1		
正規化定数k	30000		
1 パターンあたりの 学習サンプル数	5		
1 パターンあたりの 評価サンプル数	実験 7	実験 8	実験 9
	21	13	9~13
最大学習回数	5000		
最終誤差判定値	1.0E-4		

実験 9 においての評価データのばらつきは誤認識した評価データを学習データに追加したため

表 4.10 実験結果(実験 7～9)

	認識率					
	実験 7		実験 8		実験 9	
中間層細胞数	40	80	40	80	40	80
静止状態	42.9%	52.4%	38.4%	38.4%	69.2%	69.2%
背屈	85.7%	76.2%	23.0%	15.3%	69.2%	61.5%
掌屈	100.0%	100.0%	84.6%	84.6%	69.2%	92.3%
右	90.5%	90.5%	69.2%	69.2%	100.0%	100.0%
左	100.0%	100.0%	61.5%	61.5%	92.3%	84.6%
回内	66.7%	66.7%	9.0%	9.0%	81.8%	90.9%
回外	95.2%	100.0%	22.2%	22.2%	88.9%	100.0%
平均	83.0%	83.7%	45.8%	44.7%	81.1%	84.7%

表 4.10 に実験 7～実験 9 の結果を示す。実験 7 と実験 8 は最終誤差判定値に達し収束した。しかしながら、実験 9 では最終誤差判定値まで到達せず、学習回数が最大学習回数である 5000 回に達した。この結果と実験 5 と実験 6 の結果から個人による EMG の変動が同一人物における EMG の変動と比較し、大きいことが示された。

また、実験 7 では中間層細胞数 80 の場合、実験 8 では中間層細胞数 40 の場合において認識率が高いことが示された。一般的に入力層細胞数と出力層細胞数を同数とした場合、中間層細胞数の多い方がネットワークの規模が大きいことから、個人に特化した認識性能を示す。すなわち、規模の大きなネットワークはデータ変動が微小であるデータを認識対象とする場合には高い汎化能力を示す。したがって、上記の実験結果の要因として、複数被験者における EMG の変動が同一被験者間と比較し、顕著であることが挙げられる。

実験 9 では実験 8 の認識結果が 45% 前後であったのに対し、40% 程度の認識性能の向

上が確認できた。また、追加学習により個人差による EMG の揺らぎを学習に反映することが可能となり、汎化能力を高めることが示された。実験 7～実験 9 の実験結果より、中間層細胞数の差異による認識率の変化が小さいことから、本項以降では中間層細胞数を 40 と設定し実験を行う。これは中間層細胞数 80 の場合と比較し、ネットワーク規模が半分であるために処理時間が高速であるという利点もある。

4.2 手首に電極を配置

前節では手首挙動において最適な計測位置で認識実験を行った。本節では本システムのさらなる実用化を図るために、本節では手首に電極を配し、実システムに基づいた実験を行う。また、入力ベクトルの算出手法は 3.3.2 項の(手法 1)を用いる。

(実験 10) 被験者 A を学習データとし、被験者 A を評価データとして実験する。

(実験 11) 被験者 A を学習データとし、被験者 A 以外を評価データとして実験を行う。

実験 10, 実験 11 ともに実験条件を表 4.11 に示す。

表 4.11 実験条件(実験 10, 11)

電極数	4
電極種類	乾式電極
学習アルゴリズム	改良型 BP 法 式(3.18)
学習定数 η	0.05
慣性定数 α	0.95
振動定数 β	-0.1
正規化定数 k	30000
1 パターンあたりの 学習サンプル数	5
1 パターンあたりの 評価サンプル数	25
最大学習回数	5000
最終誤差判定値	1.0E-4

表 4.12 実験結果(実験 10, 11)

	認識率	
	実験 10	実験 11
静止状態	48.0%	20.0%
背屈	24.0%	0.0%
掌屈	100.0%	88.0%
右	60.0%	36.0%
左	84.0%	48.0%
回内	36.0%	12.0%
回外	56.0%	20.0%
平均	58.3%	32.0%

この結果から実験 10, 実験 11 ともに計測条件の変化に伴い, 認識率が大きく低下したことが示された. ここで, 図 4.7 に同一被験者が異なる採取位置において, 背屈動作を行った場合の SLAB 値波形を示す. 図 4.7(a)は橈側主根屈筋と尺側主根屈筋に電極を配置したときの入力情報を示す(図 4.6(b)と同波形). 図 4.7(b)に電極を手首に配した場合の入力情報を示す. これによると, 電極位置が手首に設定したことにより計測される EMG が低下したことから, NN への入力情報全体の数値も低下したことが確認できる. このため, 各チャンネルの総和を定数 30000 で正規化している入力値(図 4.7(a)では SLAB 25, 50 図 4.7(b)では SLAB 20, 40, 60, 80)については大きく特徴が失われている. したがって, 認識率の要因として正規化定数 30000 が橈側主根屈筋と尺側主根屈筋において最適な定数であったことが推察される. この理由付けとなる証明を行うため, 実験 10, 実験 11 と同条件にて正規化定数 $k=3000, 1000$ と変更し, 実験を行った. この結果, 7 パターンの平均認識率は $k=3000$ の場合, 79.5%, $k=1000$ の場合, 89.7%を得た.

実用化において機器の使用時, 電極の位置ずれなどや皮膚状態の変化などに対しても柔軟に対応可能とするためには, NN への入力方法として定数にて正規化する手法は好ましくない. このため, 新たな入力ベクトル作成手法として, 3.3.2 項にて記述した隣接加算平均を用いる(手法 2)を採用する. 図 4.8 に掌屈動作の場合の SLAB 値波形を示す.

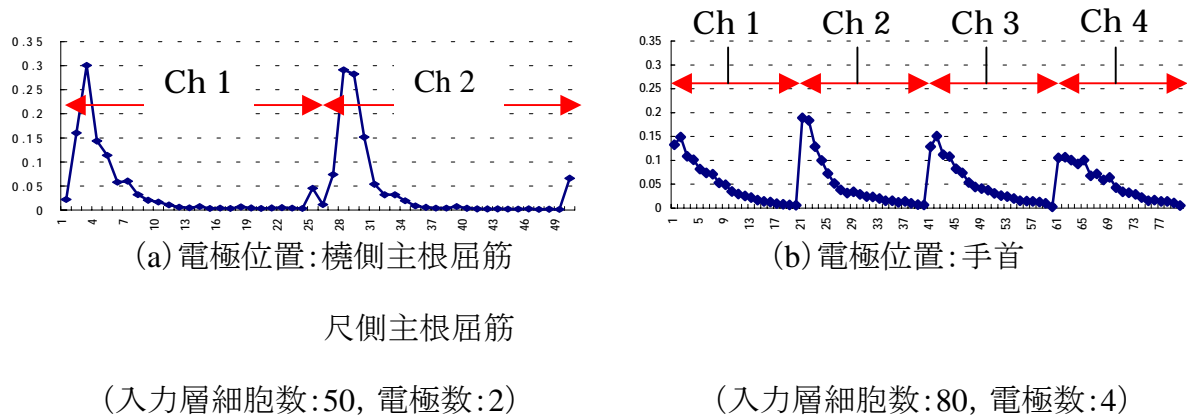


図 4.7 手首挙動:背屈

(x 軸方向:SLAB 数 y 軸方向:SLAB 値)




図 4.8 手首挙動:掌屈

(x 軸方向:SLAB 数 y 軸方向:SLAB 値)

また, 下記の理由により, 抽出する周波数帯域を 70Hz~1kHz と変更する⁽⁵⁷⁾.

- ・図 4.7, 図 4.8 などに示す通り高周波数帯域において EMG が顕著に観測できなかったこと
- ・電極位置の手首への変更を検討するにおいて, EMG の合計値が低下したため

実験 10, 実験 11 では電極位置の手首への移行に伴い, 手首挙動認識率が著しく低下したことから, 正規化定数を使用しない新たな入力ベクトル作成手法として(手法 2)を使用して手首挙動認識実験を実施する.

(実験 12) 被験者 A のデータを学習データおよび評価データとして実験する.

(実験 13) 実験 12 において誤認識した評価データを学習データに追加し, 追加学習を行う.

(実験 14) 被験者 A のデータを学習データとし, 被験者 A 以外の被験者に対して手首挙動の認識実験を行う.

(実験 15) 実験 14 において誤認識したデータを学習データに追加し, 追加学習を行う.

実験条件を表 4.13 に, 実験結果を表 4.14 に示す.

表 4.13 実験条件(実験 12~15)

電極数	4			
電極種類	乾式電極			
学習アルゴリズム	改良型 BP 法 式(3.18)			
学習定数 η	0.05			
慣性定数 α	0.95			
振動定数 β	-0.1			
1 パターンあたりの 学習サンプル数	実験 12	実験 13	実験 14	実験 15
	5	13	5	19
1 パターンあたりの 評価サンプル数	実験 12	実験 13	実験 14	実験 15
	21	13~21	13~18	3~11
最大学習回数	5000			
最終誤差判定値	1.0E-4			

※ 評価サンプル数のばらつきは誤認識したデータを学習データに追加したため

表 4.14 実験結果(実験 12～15)

	認識率			
	実験 12	実験 13	実験 14	実験 15
静止状態	61.9%	76.9%	33.3%	66.7%
背屈	66.7%	78.6%	17.6%	0.0%
掌屈	100.0%	85.7%	78.6%	18.2%
右	66.7%	100.0%	64.7%	54.5%
左	100.0%	85.7%	43.8%	85.7%
回内	66.7%	100.0%	20.0%	100.0%
回外	85.7%	77.8%	38.5%	100.0%
平均	78.2%	86.1%	41.8%	56.5%

実験 12, 実験 13 の認識率は実験 10, 実験 11 と比較し, 飛躍的に向上した. 実験 12 と実験 13 は学習データと評価データともに被験者 A のデータのみを使用している. そのため, 個人データのばらつきを考慮せず, 電極の装着状態の差のみ考慮されるため認識率は実験 14, 実験 15 と比較し, 高認識率を得たことが推測できる. また, 実験 12 では手首の掌屈と左へ動作の認識率が良好な結果を示した. 特に手首が掌屈の動作は EMG データの出力合計値が大きく, 目視の場合においても明確にパターンを識別できることから高認識率が得られたと考えられる. 一方, 静止状態と回外動作は他の動作に比べ, 比較的認識率が低い. 図 3.17 に示す通り, この 2 つのデータは目視においても近似しており, 認識率の低下につながったものと推測できる. これは, 図 4.9 に示すように電極を配置する手首付近に回外に使用する筋が存在しないことから確認できる. 実験 13 では, 実験 12 と比較して全体的に認識率の向上が確認でき, 追加学習の有用性が示された. 追加学習により認識率の低下

が見られたパターンが存在する原因として、パターン分離間距離が近いために誤認識したデータと推察されるデータについても学習データとして追加したために識別曲面が大きく変動したものと考えられる。

実験 14 では実験 12 と比較し、認識率の低下が顕著であり、ここでも EMG データの個人差が大きいことが示された。そのような中、実験 12 でも安定した認識率を検出し、掌屈の手首挙動の認識率は他の動作と比較し、高い認識率を得た。この結果からも手首挙動が掌屈のデータは他の挙動に比べ、パターン間距離が大きいことが示される。

実験 12～実験 15 では実験 15 のみ学習回数が 5000 回にと到達し、最終誤差判定値まで誤差を低下させることができなかった。実験 14 と比べて、全体的に認識率が向上した。実験 15 をについても追加学習の有用性が示された。実験結果より実用認識率 90%を実現するためには個人に特化したシステム構築を検討することが望ましい。次節以降、個人に特化したシステム構築を行い、認識対象とする手首挙動の組み合わせについても検討する。




図 4.9 前腕の運動に使用する筋

4.3 手首挙動の検討

本節では SLAB 値と NN の出力値の因果関係を解析し、認識対象パターンとする手首挙動の選択について検討する。

4.3.1 入力値の統計解析

NN による非線形識別結果を線形識別であるパターン間距離との相関を確認するために前述の実験 12 より得られた NN の反応値を用い、同一人物における手首挙動のパターン間距離と NN の発火の相関関係について解析する。さらに、種々の手首挙動による EMG の分離状況を考察する。

(実験 16) (手法 2)により作成した NN データについて、式(4.3)に示すマハラノビス距離を導入して統計的解析を行う。

表 4.15 に入力値の統計解析と NN の出力値の関係を示す。表中の上段の数值はマハラノビス距離により算出された距離を示す。中段は NN の出力が最大発火を希望するパターン(対象パターン=表 4.15 の対角上)の場合、評価データ中の NN の最低発火値を示す。また、NN の出力が最大発火を希望しないパターン(対象外パターン)の場合、評価データ中の NN の最大発火値を示す。下段の数值は評価データに対する NN の反応値の平均を示す。具体的には網掛けのセルに記述する数值は上段から“静止状態”-“背屈”のマハラノビス距離、評価データにおける NN の最大発火値、手首挙動が“静止状態”時において、手首挙動が“背屈”動作であると出力した NN の反応値の平均値を示す。本実験は全 30 動作について実験を行った。選択候補とした手首挙動 30 パターンと全結果については巻末の(付録)にて記載する。

$$l_{ij} = \sqrt{\frac{(\bar{x}_i - \bar{x}_j)^2}{\sigma_i^2 + \sigma_j^2}} \quad (4.3)$$

\bar{x}_i, \bar{x}_j : パターン i, j の NN への入力値の総和の平均値を示す。各パターンについて、同パターンの動作 5 試行を行い、それぞれの NN への SLAB 値 1~80 の最小値をオフセットとし、差し引いた場合の平均値である。

σ_i^2, σ_j^2 : パターン i, j の NN への入力値の総和の分散値を示す。

表 4.15 入力値の統計解析と NN の出力値の関係

		NN の反応値						
		静止状態	背屈	掌屈	右	左	回内	回外
手 首 挙 動	静 止 状 態	0	238	360	112	103	116	40
		0.522699	0.362927	0.000063	0.008934	0.057673	0.007641	0.109076
		0.9022915	0.0373669	0.0000214	0.0006426	0.0074189	0.0004998	0.0208367
	背 屈	238	0	287	61	34	62	2
		0.034324	0.000071	0.000103	0.989668	0.000139	0.735529	0.849914
		0.0058446	0.2993877	0.0000114	0.4415566	0.0000204	0.0609858	0.0459758
	掌 屈	360	287	0	92	152	100	109
		0.010374	0.000019	0.006980	0.669780	0.998220	0.819389	0.991433
		0.0038980	0.0000019	0.6980314	0.0324888	0.2548474	0.0695045	0.2153958
	右	112	61	92	0	29	3	34
		0.003534	0.510676	0.000141	0.939399	0.000002	0.968464	0.000213
		0.0012264	0.0546154	0.0000525	0.9878814	0.0000000	0.0831742	0.0000246
	左	103	34	152	29	0	27	14
		0.128854	0.259902	0.003644	0.000169	0.004600	0.969299	0.747402
		0.0149013	0.0160093	0.0004586	0.0000096	0.7541939	0.2233084	0.1524348
	回 内	116	62	100	3	27	0	33
		0.005379	0.995733	0.000856	0.000013	0.826568	0.034545	0.018347
		0.0006115	0.0826734	0.0001118	0.3895046	0.0534930	0.7410560	0.0010804
	回 外	40	2	109	34	14	33	0
		0.989655	0.981983	0.000061	0.052436	0.097033	0.400804	0.834527
		0.3478985	0.342976	0.000017	0.0030101	0.0162566	0.0175800	0.2183744

上段:マハラノビス距離

中段:対象パターン(対角上)の場合, 評価データ中の NN の最低発火値

対象外パターン(対角上以外)の場合, 評価データ中の NN の最大発火値

下段:NN の反応値の平均値

表 4.15 中の対角上の数値は同一パターンに対する値を示しており、距離 L_{ij} が 0 であることは式 (4.3) より自明である。また、NN の学習においては 6 パターンの識別教示を行うため、この対角上の並びの値が他のパターンとの反応値と比較して最大であることが理想である。さらに、NN の非線形識別能力が統計的距離による線形識別能力を包含するという観点から、すべての組み合わせにおいて距離が最小の場合、NN の反応値は最大であることが理想である。また、距離が最大の場合、NN の反応値は最小となるべきである。実験結果よりマハラノビス距離と誤認識しやすいカテゴリ間の距離の関係は目視による観測結果とおおよそ一致している。しかしながら、距離と NN の反応値の相関関係は検出できなかった。これはパターン間距離が大きい場合、発火を希望する NN の反応値が理想どおり高いパターンも存在するが、反応値が低いパターンも存在するためである。また、右動作において、背屈に発火する NN の反応値と、背屈動作において右動作に発火する NN の反応値が大きく異なることから理由付けられる。

また、学習データの解析の結果、一部に平均から極端に離れたデータが発見されている。これは、データ採取条件からアンプ特性がトランジスタの劣化により変動した時期に採取したデータであることがデータのタイムスタンプから判明している。これより、極端なデータはすべて目視によりクリーニングを行い、学習データの再編集を実施する。ここでの目視確認の目安はアンプ出力信号のレベルで飽和していないことに加え、1kHz 以上の周波数帯域のパワースペクトルが全体の 5% を超えないこととしている。

4.3.2 手首挙動の検討

上記にて表 4.15 より、入力値の統計解析と NN の出力値の関係は無相関であることが判明した。しかしながら、前述の結果は対象とするサンプルデータが少量 (1 パターンあたり 5 サンプル) であったことから信頼性の高い結果とはいえないと考えられる。なぜなら、距離算出の評価規範としたマハラノビス距離は入力データの分散値を考慮した距離値であるため

である。そこで、本節ではマハラノビス距離と同等であるユークリッド距離値を用いて、手首挙動とデータ分布を考慮した統計的解析を行い、認識対象パターンの選択について検討する。

前節にて、静止状態を含めた 7 パターン認識実験を行った。しかしながら、静止状態と回外動作は類似波形を示すため、認識対象パターンから静止状態を削除し、以降では 6 パターン認識実験を行う。これは手首挙動によりマウスの基本 6 動作の実用認識率 90%を実現することを第一目標としたためである。なお、待機信号の認識については EMG の合計値が一定値以内であれば、待機信号(静止状態)として認識するなどの処置を検討すれば実現可能であると考えられる。また今後、認識パターンとして静止状態を追加することも可能とするため、静止状態とのユークリッド距離を算出する。

選択する動作パターンは特徴空間上において、それぞれパターン間距離が大きいことに加え、動作の容易性が求められる。また、上述の通りポインティングデバイスの待機信号として手首の静止状態を認識パターンとして使用することも視野に入れ、静止状態からのパターン間距離が大きいことも考慮する。前述の条件と目視による判断から特定の被験者において、30 動作の中から前述の条件を満たす手首挙動を選択する。

図 4.10 に 30 パターン×5 サンプルの EMG (パワースペクトル) のばらつきと各パターンの距離を示す。距離値は手首の静止状態を基準とし、各パターンのユークリッド距離を算出する。横軸にユークリッド距離を縦軸に同パターンの中央値からのユークリッド距離を出力している。これまで、掌を閉じた状態での手首挙動を行ってきたが、選択した手首挙動は図 4.10 に示す通り、

- 掌を開いた状態で背屈
- 掌を閉じた状態で掌屈
- 掌を閉じた状態で回内
- 掌を開いた状態で回外
- 開き
- 握り

を認識対象パターンとして選択することとする. 図 4.11 に手首の挙動と計測信号を示す.




図 4.10 ユークリッド距離と手首挙動データの分布

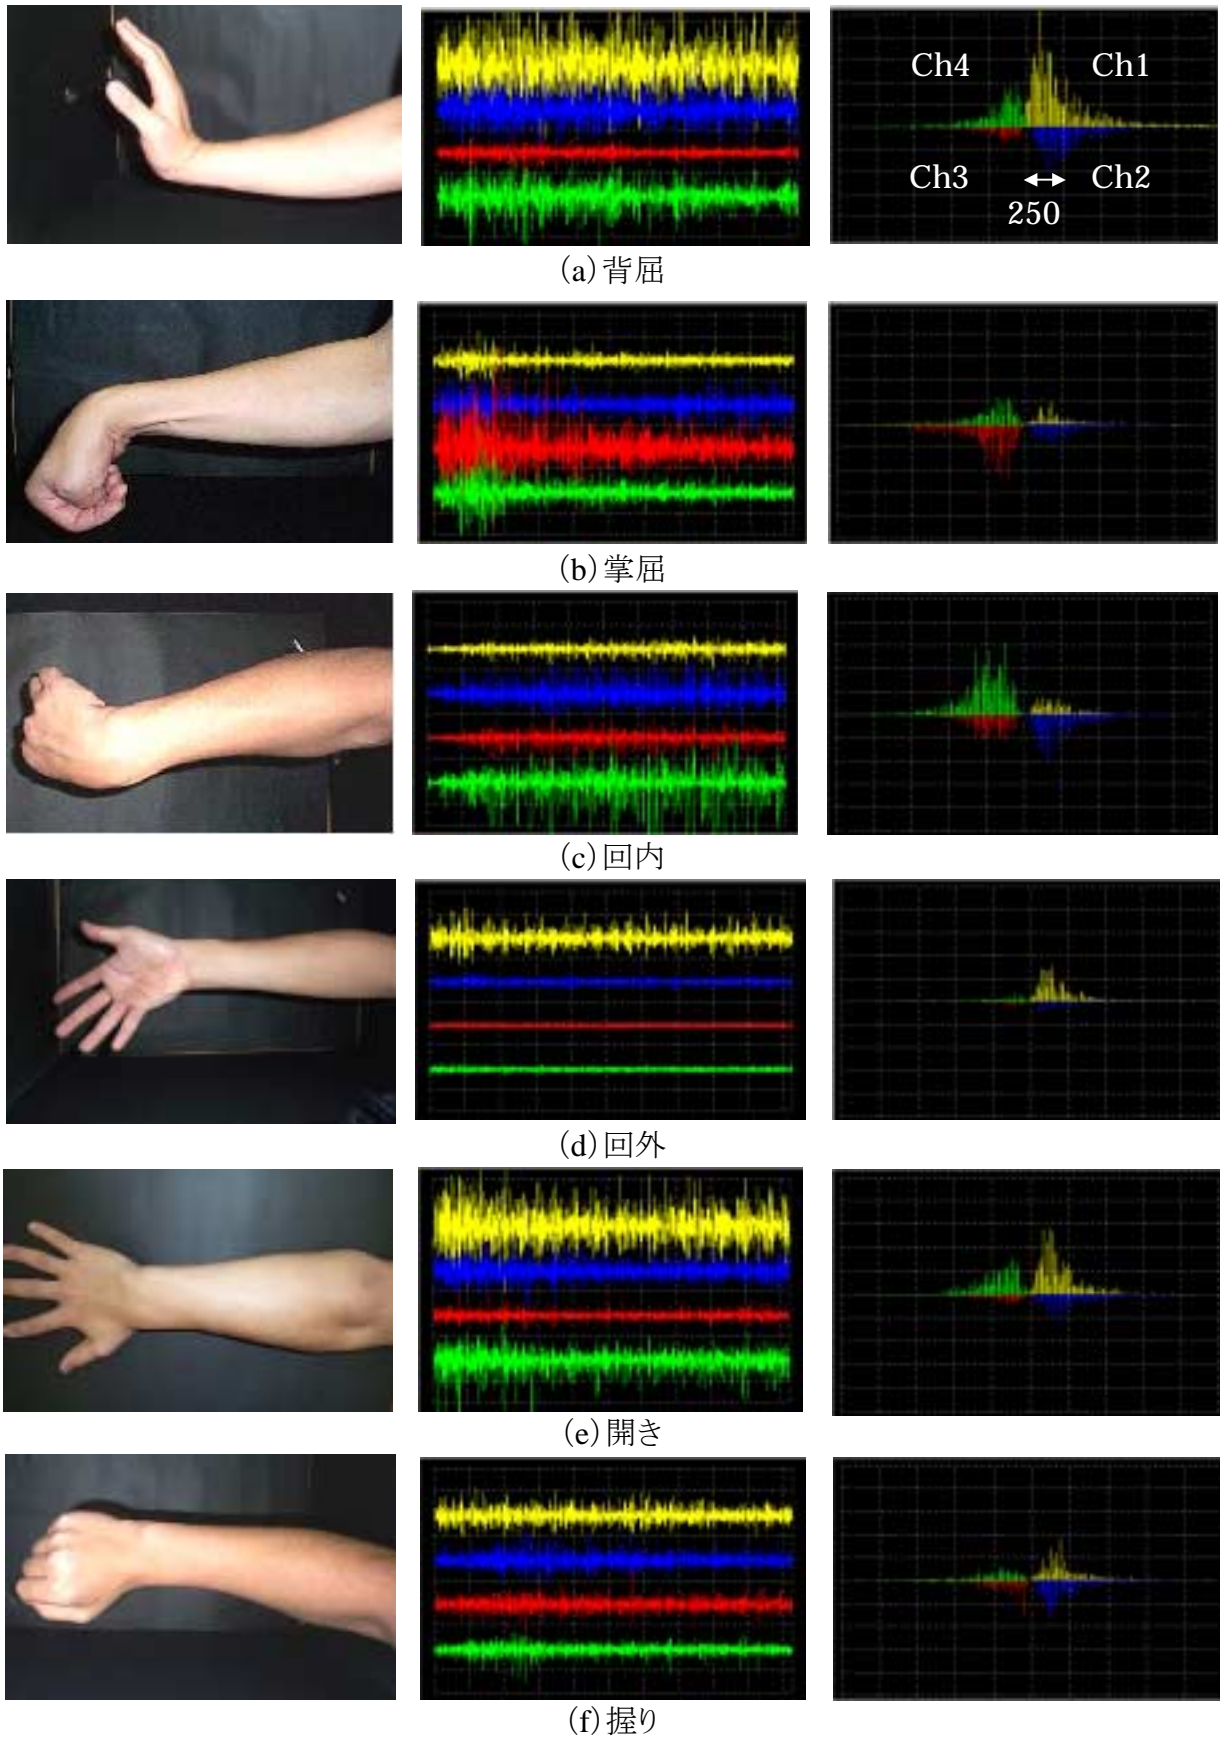


図 4.11 手首挙動と計測信号

これまで、実システムにおいて EMG の個人差が大きいことから特定個人により作成した NN ウェイトでは登録者以外の EMG データを対象とした汎化能力が十分に得られないことが判明している。したがって、特定個人に特化するシステムのチューニングを検討する。図 4.11 において決定した認識対象パターンを用い、計算機によるチューニングの基本性能確認実験を行う。上記にて決定した 6 動作を認識パターンとし、手首挙動認識実験を行う。また、NN への入力値作成手法は(手法 2)を用いる。本実験は DSP ユニットを用いたオンラインチューニングの基礎実験であるため、入力層細胞数は DSP のメモリ空間が許容する最大値である 50 とする。このため、NN 構成は $50 \times 25 \times 6$ と設定する。ここで、実験に使用する計算機 (Intel Celeron Processor 733 MHz) の性能向上に伴い学習時間の短縮が可能となったことから、最大学習回数を増加させる。

(実験 17) 被験者 F (21 歳男性健常者) の EMG データを学習データとし、同一被験者の未学習データを評価データとし、認識実験を行う。また、学習サンプル数を増加に伴う認識性能の変化を確認する。

実験条件、実験結果を表 4.16, 表 4.17 に示す。

表 4.16 実験条件(実験 17)

電極数	4
電極種類	乾式電極
学習アルゴリズム	改良型 BP 法 式(3.18)
学習定数 η	0.05
慣性定数 α	0.95
振動定数 β	-0.1
1 パターンあたりの 評価サンプル数	20
最大学習回数	20000
最終誤差判定値	1.0E-4

表 4.17 実験結果(実験 17)

認識率	学習サンプル数	
	5 サンプル	10 サンプル
背屈	35.0%	65.0%
掌屈	80.0%	70.0%
回内	40.0%	55.0%
回外	100.0%	95.0%
開き	100.0%	100.0%
握り	60.0%	90.0%
平均	69.2%	79.2%

この結果より、ある程度の実用域性能が登録時には得られる場合でも、電極の位置ずれ、経時変化、アンプのゲイン特性などを考慮するとシステムが使用される環境を何らかの形で登録パラメータ(NN ウェイト)にフィードバックする機構が必要となる。実システムにおいて、登録者を限定した場合、登録データを 50 サンプルまで随時増加させると同一使用者の未学習データに対する汎化能力は徐々に向上することが表 4.17 および図 4.12 より確認できる(55 サンプル以上は理想波形)。したがって、現在のアンプ特性ならびに、データ前処理法であっても、登録者だけの手首挙動を認識するのであれば、登録データを増加させることにより実用域(90%程度)に本システムの性能を展開することが可能であると考えられる。




図 4.12 学習サンプル数と認識率との関係

(7 パターン: 静止状態・背屈・掌屈・右・左・回内・回外の平均認識率)

4.4 個人差への適応

前節において EMG パターンの認識には継続学習が有効であることを示した。しかしながら、限定された学習用登録データでは NN の汎化能力だけでは十分な認識性能を得られないことも判明した。このため、EMG のパワースペクトルを隣接加算平均するだけの平滑処理では皮膚状態、性別、人種などの多様なデータのばらつきに対し、ロバストな EMG による手

首挙動のパターン識別は困難であると考えられる。したがって、登録時に限定された学習データによるオフライン的な学習は好ましくないと判断される。そこで、これまでのある程度のデータバラエティ(性別, 年齢, 皮膚状態など)を考慮した学習データによる NN を用いた学習結果を初期ウェイトとし, 本システムを使用する段階で個々の使用者がそれぞれ独自のオンラインでチューニングすることを提案する。本節では特定被験者 1 名により作成した初期 NN ウェイトに同一被験者より採取した NN データを追加し, オンラインチューニングのための基礎実験を行う。

4.4.1 NN ウェイトのオンラインチューニング

前章で示した実験結果より, 特定個人の NN ウェイトの学習登録では十分な汎化能力を得られないことを考慮し, 入手可能な学習データを用いた初期学習での NN ウェイトをベースとして, 使用者に実システムを装着した形での継続学習の実施を検討する。これにより, 個人毎の EMG データをオンラインで採取しながら, 初期ウェイトのチューニングが可能となり, 短時間のキャリブレーション動作で高性能な手首挙動パターン認識システムの実現が可能と予想される。この予想を具体化するために, 初期登録情報を用いて, 使用者毎にその登録情報をオンラインでチューニングする手法を提案する。その手順は学習済みの NN ウェイトをシステムが読み込み, これに手首を仮に動作させながらオンラインで学習データを採取する。さらに, このデータを NN ウェイトの修正 (チューニング) に直接使用するものである。特に, 使用者毎に手首挙動の差異はあるが, 個々の学習の結果がシステム固有の情報として NN ウェイトに集積され, 最終的には使用者に最もフィットした形で学習は収束するものと予想される。ただし, これを実現するには学習の高速性とシステムのポータビリティが必須条件となる。そこで, オンラインチューニングの可能性を確認するハードウェアとして, 著者らが既に紙幣識別分野で開発済みの DSP ユニットを用いたニューロ演算ユニットを導入する。オンラインチューニングの概念図は図 4.13 のようになる。

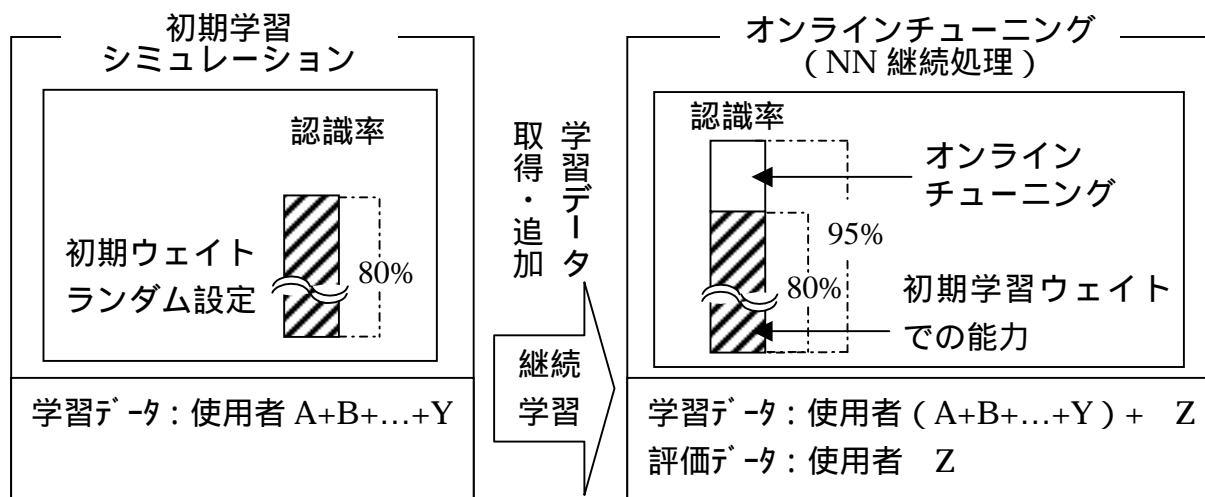


図 4.13 オンラインチューニングのシステムイメージ

4.4.2 DSP ユニットによる実験

図 4.14 に示す DSP ユニットは DSP を核として構成され、NN の前向き計算および学習計算を高速に行うものである。NN の計算は基本的に行列の掛け算として表現される。DSP は内部にハードウェア乗算器を有し、浮動小数点演算においても、一命令で演算可能であることから、汎用 CPU と比較し高速な演算が可能である。さらに、プログラムメモリとデータメモリを別々に格納するハーバード・アーキテクチャにより高速演算が可能である。また、アセンブラと同時に C コンパイラが提供されており、ソフトウェアの開発を従来の汎用 CPU と同様に容易にしている。DSP ユニットは単体で学習動作を可能とし、さらに、認識および制御などの各種使用に対応するために、モード設定スイッチ(学習、識別、計算機との通信)、LED、液晶表示板(LCD)、D / A 変換器、パラレル通信ポート、デュアルポートメモリ(DPM)への延長ポートなどを実装する。また、A / D 変換器およびシリアル通信ポートも実装する。LED および LCD には学習状況、動作モード、認識結果、さらに、エラーなどが表示される。学習アルゴリズムは式(3.18)の改良型の BP 法で学習させ、NN ウェイトおよび最終的な学習定数を得る。また、C 言語で記述された BP 法のプログラムはフラッシュメモリから SRAM に展開される。さらに、初期ウェイト、他のパラメータはフラッシュメモリに格納されるが、これらもすべ

て認識対象データとあわせて、SRAMに展開され、処理の高速化が図られている^{(20)~(26)}。また、これらは計算機で容易に更新でき、認識パターンの変更・追加に迅速かつ柔軟に対応可能となっている。DSPユニットの構成を図4.15に示す。



図 4.14 DSP ユニットの概観

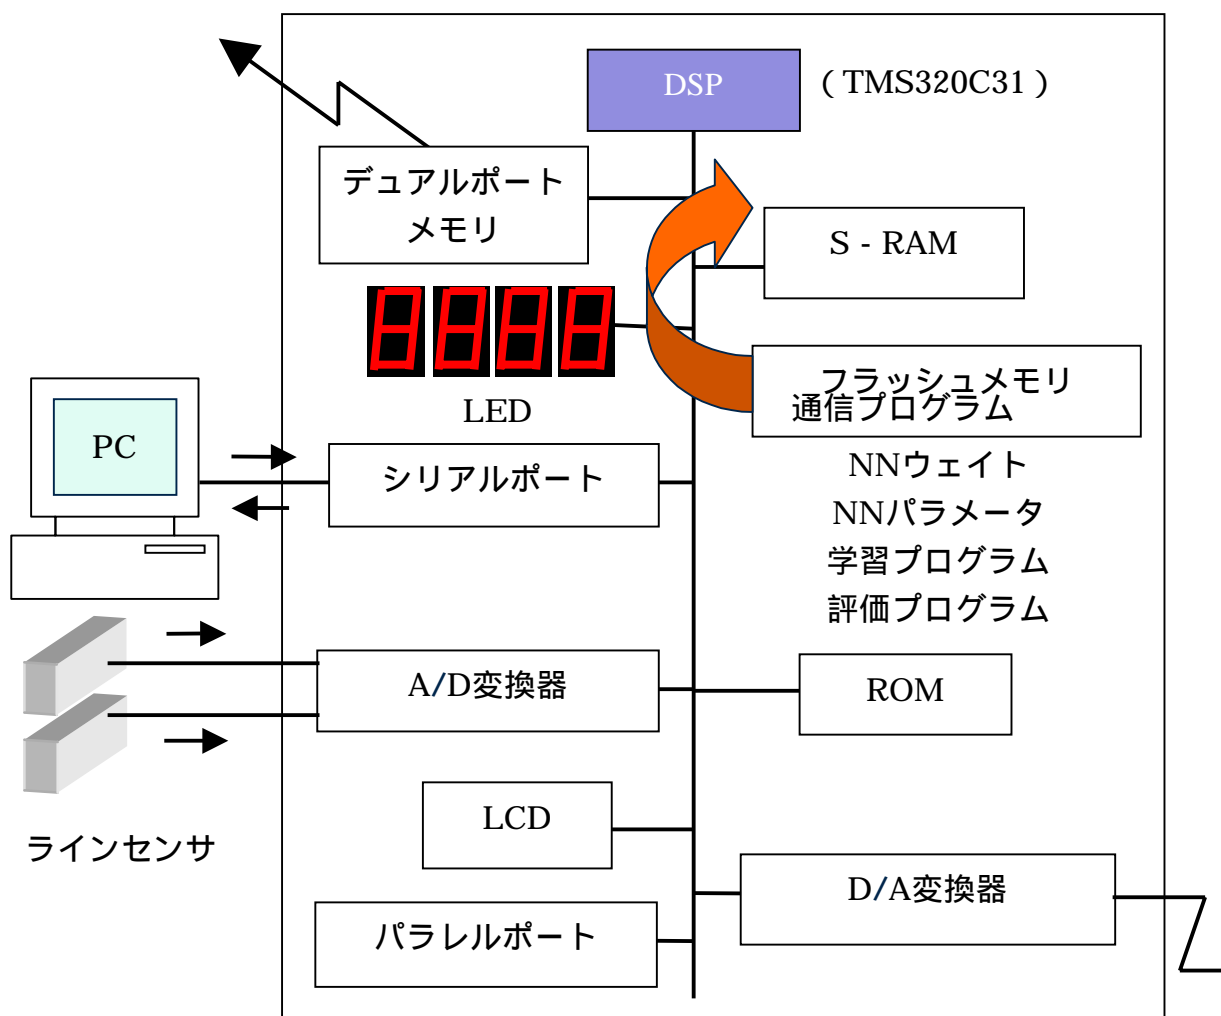
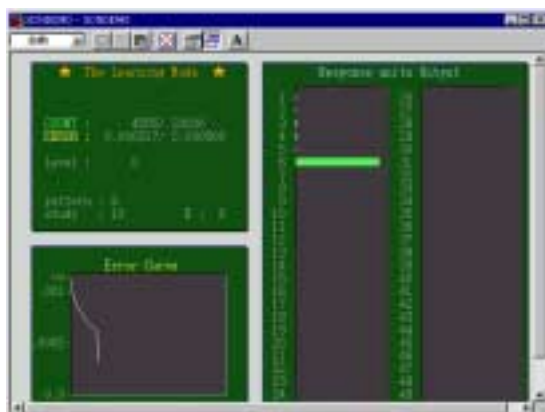


図 4.15 DSP ユニットの構成

4.3 節のシミュレーションで操作したのと同じ EMG データを計算機を介して DSP ユニットにロードし、オンラインチューニングのための基礎実験を行う。

(実験 18) 被験者 F の EMG データを学習データとし、同一被験者の未学習データを評価データとし、認識実験を行う。また、学習サンプル数を増加に伴う認識性能の変化を確認する。

PC 内部のモニタプログラムを通じ、DSP 内部の学習状態や評価結果を外部より容易に閲覧可能としている。図 4.16(a) に DSP ユニットを用いた学習画面を、図 4.16(b) に評価画面を示す。本実験の実験条件は実験 17 と同条件とする。実験条件を表 4.18 に、初期学習と継続学習結果を表 4.19 に示す。これにより、DSP ユニット上で EMG による継続学習が可能であることが判明した。ただし、ここでの実験は特定個人の学習データで既に十分学習した結果を初期 NN ウェイトとし、オフライン的に学習データを DSP ユニットに与えた継続学習である。ただし、完全なオンラインチューニングにおいては、手首を動作させながら既存の学習データに採取データを追加していくことが必要である。チューニング後の本システムを用いた登録者自身の手首挙動認識結果は図 4.12 の学習サンプル数を随時増やして得られる予想とほぼ一致した。



(a) DSP ユニットの学習状態画面



(b) DSP ユニットの評価状態画面

図 4.16 モニタプログラム

表 4.18 実験条件(実験 18)

電極数	4
電極種類	乾式電極
学習アルゴリズム	改良型 BP 法 式(3.18)
学習定数 η	0.05
慣性定数 α	0.95
振動定数 β	-0.1
1 パターンあたりの 評価サンプル数	20
最大学習回数	20000
最終誤差判定値	1.0E-4

表 4.19 DSP ユニットを用いた実験結果(実験 18)

認識率	学習サンプル数	
	5 サンプル	10 サンプル
背屈	20.0%	70.0%
掌屈	75.0%	60.0%
回内	65.0%	50.0%
回外	100.0%	100.0%
開き	100.0%	100.0%
握り	50.0%	75.0%
平均	68.3%	75.8%

4.4.3 ポータブル DSP システムの提案

前項にて提案したオンラインチューニングを具体化するためには機器の小型化が必須条件となる。図 4.17 に DSP システムでの継続学習をオンライン学習データ採取と共に具体化するためのポータブル DSP システムの構想図を示す。使用のコンセプトは使用者が使用前にシステムをキャリブレーションすることである。つまり、複数人により作成した初期ウェイトに使用者本人の学習データを追加することにより、短時間にて使用者本人に特化した最適ウェイトを作成することが可能である。使用者がスイッチを操作することにより機器に手首挙動パターンを学習させる。

DSP システム本体は使用者の腰ベルト付近に装着され、バッテリー駆動される。これにより、手首に装着した 4 チャンネルのセンサプローブにより EMG はオンラインで採取される。採取された EMG は増幅・デジタル化され、ユニット内の SRAM 上で学習データとして累積され、NN に供与される。学習の収束は従来の PC でのシミュレーションと同様に、目的の 2 乗誤差に達したか否かで判断され、学習が収束時に LED を介し、使用者に学習完了を伝達する。ただし、前述の要因で学習が収束に至らない場合においても、初期学習からの継続学習中止までの学習経過は NN ウェイトの定期的なフラッシュメモリへの書き込みで保存される。また、種々の要因(予想外のデータ変動, 手首の特異動作, 極端なインパルスノイズの混入, 電極の位置ずれ, 皮膚状態の変化, 筋疲労など)により認識率の低下が発生した場合にも再度学習を実行することにより認識率の回復を行うことが可能である。したがって、本ユニットの開発により、本格的なシステムの個人毎のオンラインチューニングが可能と予想される。現在、本システムのソフトウェア部, ハードウェア部, アンプ部を設計中である。




図 4.17 モバイルインタフェース用オンライン学習システムイメージ

5 まとめ

本論文では、健常者を対象とした新しい入力インタフェースの開発を行うために手首の動作識別において被験者の随意運動に伴い発生する生体信号である EMG を用いた手首挙動認識システムを検討した。その中で、EMG の登録・評価には階層型 NN を用い、認識システムとしての検証を行った。その結果、手首挙動の認識率向上には追加学習が有効であることを示した。また、実用化を前提としたシステム構築を行い、EMG の個体差を吸収するために DSP ユニットを用いたニューロオンラインチューニングのための基礎実験を行った。また、計算機シミュレーション結果との認識率の比較を行うことにより、提案システムについて実用性能を具現化することが可能であることを示した。

今後の課題として、実用機への提案手法の移植には性別、年齢、人種などを考慮した学習データによる NN の学習が必要であり、紙幣識別機と同様に製品用のプロトタイプによる 6 ヶ月以上に延べ、1000 件以上の市場テストが必要である。また、長時間の機器の使用に伴い、使用者に筋疲労が発生した場合での性能確認や安定した状態で EMG を計測可能なセンサの開発、携帯型小型アンプの開発、小型 DSP ユニットの開発、リアルタイムオンライン学習システムの開発についても今後の課題である。

謝辞

本研究の遂行ならびに本論文の執筆にあたり的確なるご指導とご校閲を賜りました高知工科大学情報システム工学科 竹田史章教授に深甚なる謝意を表します。先生には本研究の要諦である提案システムの DSP への応用に関し、多角的視点からのご考察を頂戴するとともに、論文構築上の構成規範や展開手法を論理的にご教示頂きました。先生のご尽力により、無事本論文を集成できましたことに対し、重ねて御礼申し上げる次第です。

また、実験機材の提供、実験データ採取、本システムの開発、研究の遂行にあたり有益なご助言とご指導を賜りましたシステムエルエスアイ株式会社 代表取締役社長 中浦一浩氏、山本祥弘氏に厚く御礼申し上げます。本システムの開発にあたり、ご指導頂きましたグローリー工業株式会社 西蔭紀洋氏、徳島大学知能情報工学科 福見稔助教授、博士前期課程 1 年 松村悠司氏に心より謝意を申し上げます。

さらに、本研究に関して、著者の研究室の院生、学部生にもお世話になりました。特に、実験データの採取や実験シミュレーションの補助にあたり学部 4 年佐藤公信氏、津末慎太郎氏、中島弘喜氏には多大な協力を頂きました。最後に本論文の執筆の機会を与えて頂きました高知工科大学に心から御礼申し上げます。

参考文献

- (1) 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”, 電気情報通信学会論文誌, Vol.J70-D, No.1, pp.207-215, 1987
- (2) 平岩明, 下原勝憲, 徳永幸生, “筋電動作ハンドの制御のための皮膚表面筋電のニューラルネットによる認識“, 電子情報通信学会春季全国大会, Vol.6, pp.188, 1991
- (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, Vol.112-C, No.8, pp.465-473, 1992
- (4) 平岩明, 内田典佳, 曾根原登, 下原勝憲, “ユーザ適応型筋電マニピュレーション技術, Human Interface, Vol.7, pp.281-287, 1992
- (5) 小池康晴, 川人光男, “神経回路モデルを用いた表面筋電信号からの人腕の軌道生成”電気情報通信学会論文誌 D-II, Vol.J77-D-II, No.1, pp.193-203, 1994
- (6) 奥野竜平, 吉田正樹, 赤澤堅造, “筋電制御によるバイオミメティック電動義手の開発”, 電気学会論文誌 C, Vol.114, No.11, pp.1090-1094, 1994
- (7) 内田雅文, 井出英人, 横山修一, “筋電によるロボットアーム制御 2“, 電気学会誌, Vol.114-C, No.1, pp.269-270, 1994
- (8) 内田雅文, 井出英人, 横山修一, “筋電によるロボットアームの制御”電気学会論文誌 C, Vol.115, No.3, pp.445-451, 1995
- (9) 栗林勝利, 谷口隆雄, 清水聖治, 小江則禎, “前腕の筋活動電位のコマンド識別に関する研究”, 日本機会学会誌, pp.25-34, 1995
- (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, Vol.117, No.10, pp.1490-1497, 1997
- (11) 福田修, 辻敏夫, 大塚彰, 金子真, “義手制御を目的とした EMG-Based Rehabilitation Aid(EBRA)の開発”電気・情報関連学会中国支部連合大会,

pp.397-398, 1998

- (12) 福田修, 辻敏夫, 金子真, “ニューラルネットを利用した筋電制御型ポインティングデバイス”第 19 回バイオメカニズム学会学術講演予稿集, pp.281-284, 1998
- (13) 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”, 電気情報通信学会論文誌, Vol.J82-D-II, No.9, pp.1510-1519, 1999
- (14) 西川大亮, 山口博紀, 兪文偉, 丸石正治, 渡辺一郎, 横井浩史, 眞野行生, 嘉数侑昇, “実時間学習型筋電義手装置による前腕 10 種の動作パターン識別”, 第 16 回バイオメカニズム・シンポジウム予稿集, pp.201-212, 1999
- (15) 西川大亮, 兪文偉, 丸石正治, 渡辺一郎, 横井浩史, 眞野行生, 嘉数侑昇, “個人の特性に適応する EMG 識別装置の開発”, 第 20 回バイオメカニズム学会学術研究会講演予稿集, pp.500-504, 1999
- (16) 西川大亮, 兪文偉, 横井浩史, 嘉数侑昇, “実時間学習型筋電義手における人間-機械間の相互作用に関する考察”, 日本機械学会ロボティクス・メカトロニクス講演会講演論文集, No.99-9, CD-ROM, 1999
- (17) 辻敏夫, 福田修, 大塚彰, 金子真, “義手制御を目的とした筋電操作トレーニングシステム”, 電気情報通信学会論文誌 D-II, Vol.J83, No.10, pp.2030-2039, 2000
- (18) 竹田史章, 大松繁, 井上卓, 尾波宰三, “フーリエ変換を前処理とするニューラルネットワークによる紙幣識別”, システム制御情報学会論文誌, Vol.5, No.7, pp.265-273, 1992
- (19) 竹田史章, 大松繁, 井上卓, 尾波宰三, 小西健一, “ニューラルネットワークを用いた高速搬送紙幣の識別”, 電気学会論文誌, Vol.112-C, No.4, pp.249-258, 1992
- (20) 竹田史章, 大松繁, “ニューロ紙幣識別ボードの開発”, 電気学会論文誌 C, 116, No.3, pp336-340 1996
- (21) F. Takeda and S. Omatu, “A Neruo-Tecognition Technology for paper Currency Using Optimized Masks by GA and Its Hardware”, Proceedings of International Conference on

- Information Systems Analysis and Syn-thesis, Orlando, USA, pp.147-152
- (22) F. Takeda, S. Omatu and T. Nishikage, “Neural Network Recognition System Tuned by GA and Design of Its Hardware by DSP”, Proceedings of International Symposium on Artificial Intelligence in Real-Time Control, Malaysia, pp.356-361, 1997
- (23) 竹田史章, 大松繁, 寺田兼吾, “遺伝的アルゴリズムとDSPによる紙幣識別用ニューロシステム技術とその応用”, 機械電気誌(C), 63, No.615, pp.3933-3940, 1997
- (24) F. Takeda and S. Omatu, “Neural Network Systems Technique and Applications In paper Currency Recognition”, Neural Network Syst., Techniq. and Appl, ACADEMIC Press5, Chapter 4, pp.133-160, 1998
- (25) F. Takeda, S.Omatu. and Y. matsumoto, “Development of High Speed Neuro-Recognition Board and Application for Paper Currency”, The InternationalWompshop on Signal Processing Application and Technology, pp.49-56, 1998
- (26) F. Takeda, M. Nakahara, Y. Ichiryu and H. Uchida, “Autonomic Neuro-Recognition Board for Paper Currency”, SPAT2000 Workshop Proceeding, pp.85-90, 2000
- (27) 竹田史章, 西蔭紀洋, 内田久也, 中原昌樹, “ニューロテンプレートによるパターンマッチング識別手法の開発とその紙幣への適用”, システム制御情報学会講演論文集, pp.415-416, 2000
- (28) 竹田史章, 西蔭紀洋, 藤田靖, ”自己学習型ニューロ紙幣識別ボードの開発とその汎用展開”, 電気学会論文誌 C, Vol.121, No.2, pp.357-365, 2001/2
- (29) Y. Ichiryu, F. Takeda, H. Uchida and M. Nakahara, “Development of Neuro-Templates Matching Recognition Method for Banknotes”, SCORED, pp.60-61, 2001
- (30) 竹田史章, 西蔭紀洋, “紙幣用ニューロテンプレートマッチング識別手法の開発”, 電気学会誌, Vol.121-C, No.1, pp.196-205, 2001
- (31) 竹田史章, 一柳賀子, 内田久也, 中原昌樹, ”米用色彩選別機へのニューロンテンプレートマッチング手法の適用”, システム制御情報学会講演論文集, pp.105-106,2001

- (32) Y. Ichiryu, F. Takeda, H. Uchida, M. Nakahara, T. Hamaguchi, T. Tsuzuki, H. Kadota and S. Shimanouchi, "Proposal of a Rice Grading System Using Neuro-Template Matching Method", Knowledge-Based Intelligent Information Engineering System & Allied Technologies 2001, pp.818-823, 2001
- (33) 竹田史章, 佐藤公信, "プログラム可変型DSPユニットの開発とそのニューラルネットワークへの応用", システムインテグレーション部門学術講演会, pp.489-490, 2001
- (34) 中原昌樹, 竹田史章, "ニューラルネットワークを用いた筋活動電位のパターン認識システムの構築", 高速信号処理応用技術学会春季研究会講演論文集, pp.46-51, 2001
- (35) 中原昌樹, 竹田史章, "ニューラルネットワークを用いた筋活動電位のパターン認識システムの開発", システム制御情報学会講演論文集, pp.109-110, 2001
- (36) F. Takeda, M. Nakahara, K. Nakaura and Y. Yamamoto, "Recognition System of Arm Behavior with Layered Neural Network", Knowledge-Based Intelligent Information Engineering System & Allied Technologies 2001, pp.1003-1008, 2001
- (37) 竹田史章, 中原昌樹, 中浦一浩, 山本祥弘, "ニューラルネットワークを用いた手首挙動識別システムの構築", Fuzzy, Artificial Intelligence, Neural Networks and Computational Intelligence Symposium'01, pp.523-528, 2001
- (38) M. Nakahara, F. Takeda, K. Nakaura and Y. Yamamoto, "Propose of an Arm Behavior Recognition System with EMG and Neural Network", The International Conference on Mechatronics and Information Technology '01, pp.400-405, 2001
- (39) 竹田史章, 中原昌樹, 中島弘喜, "ニューラルネットワーク応用による筋活動電位パターン識別", 高速信号処理応用技術学会春季研究会講演論文集, pp.67-68, 2002
- (40) 津末慎太郎, 竹田史章, 中原昌樹, "筋活動電位を用いたニューラルネットによる手首挙動パターンの識別", 電気学会研究会資料産業計測制御研究会, IIC-02-70~84, pp.5-10, 2002
- (41) 佐藤公信, 竹田史章, 中原昌樹, 津末慎太郎, "DSP ボードによるニューロオンライン

- 学習と筋活動電位によるパターン認識への応用”, 日本シミュレーション&ゲーミング学会秋季全国大会発表論文集, pp.92-97, 2002
- (42) 竹田史章, 中原昌樹, 中浦一浩, 山本祥弘, ”筋活動電位を用いた手首挙動のニューロパターン識別システム”, 高速信号処理応用技術学会論文誌, Vol.5, No.3, pp.17-24, 2002
- (43) 中原昌樹, 竹田史章, “筋活動電位によるモバイル端末用インターフェースの開発“, FAN’02, pp.245-250, 2002
- (44) 竹田史章, 中原昌樹, 中浦一浩, 山本祥弘, “EMGによる手首挙動パターン識別システムの開発とオンラインチューニングの検討”, 電気学会論文誌投稿中
- (45) 日野原重明, ”解剖生理学”, 医学書院, pp.89-94, 2001
- (46) 日本自動認識システム協会編, “これでわかったバイオメトリクス”, オーム社, pp.28-31, 2001
- (47) 三田勝己, “筋電図計測”, BME, Vol.5, No.1, pp.33-40, 1991
- (48) 赤澤堅造, “生体情報工学”, 東京電気学会出版局, pp.81-91, 2001
- (49) 佐鹿博信, “動作分析と表面筋電図”, 総合リハ, Vol.18, No.5, pp.347-355, 1990
- (50) 田頭功, “生体電子計測系インタフェースとしての銀-塩化銀電極の基本特性”, 電気学会論文誌 C, Vol.122, No.9, pp.1426-1432, 2002
- (51) 高橋修, 有田元英, 園田茂, 才藤栄一, 富田豊, 斎藤卓哉, “運動神経伝導検査における能動電極と塩化銀皿電極の比較”, 医学検査, No.49, pp.1134-1139, 2000
- (52) 藤原修, “インタフェースの電子回路入門”, pp.20-24, オーム社
- (53) 坂巻佳壽美, “見てわかるデジタル信号処理”, 工業調査会, 1998
- (54) 宇山靖政, “基礎からのデジタル信号処理”, 東京電機大学出版局, 1995
- (55) Hwei P. Hsu, “信号処理 II”, オーム社, 1998
- (56) S. Nagata, M. Sekiguchi and K. Asakawa, “Mobil Robot Control by Structured Hierarchical Neural Network”, IEEE Control System Magazine, April, pp.69-76, 1990

- (57) 石岡靖, ”顎口腔機能分析の基礎とその応用”, デンタルダイヤモンド社, pp.260-273, 1991
- (58) F. Rosenblatt, “Principles of Neurodynamics”, Spartan Books, 1962
- (59) 萩原将文, “ニューロ・ファジィ・遺伝的アルゴリズム”, 産業図書, pp.21-39, 2000
- (60) R. ビール, T. ジャクソン, 八名, ”ニューラルコンピューティング入門”, pp.77-79, 海文堂, 1995
- (61) 長尾真, “パターン情報処理”, コロナ社, 1983
- (62) 麻生英樹, “ニューラルネットワーク情報処理”, 産業図書, 1994
- (63) 石井健一郎, 上田修功, 前田英作, 村瀬洋, “パターン認識”, オーム社, 1998
- (64) B. Kermanshahi, “ニューラルネットワークの設計と応用”, 昭晃堂, 1999

付録

<基本ニューロンの動作>

ニューロンとは神経細胞のことで、ネットワークのノードのあたる処理要素である。ニューロンのモデルは 1943 年にマッカロとピッツ (McCulloch-Pitts) により提案されて以来、NN は人間の柔軟な識別能力を計算機により実現するため、さまざまな研究者に研究された。

NN は多様なニューロンの組み合わせにより形成され、複雑な処理を行うことが可能であるが、NN を構成するニューロンは単体では図 0.1 に示される単純な処理のみが可能な多入力一出力の素子である。つまり、ニューロンへの入力 x は式 (0.1) に示される前層ニューロンの出力値の総和である。ここで、 W はネットワークの結合荷重、 S は前層のニューロンの出力を示す。

$$x = \sum_{k=1}^K w_k s_k \tag{0.1}$$




図 0.1 基本ニューロンモデル

ニューロンの出力は式(0.2)に示す出力関数 f に基づいた出力を行い、ステップ関数やシグモイド関数が挙げられる。例として式(0.3)にステップ関数を式(0.4)にシグモイド関数を示す。本論文では出力関数としてシグモイド関数を採用する。式(0.4)中の T はネットワークの温度と呼ばれる正の数で、 T が大きくなるほどグラフはなだらかになる。

$$O = f(x) \tag{0.2}$$


$$f(x) = \begin{cases} 1 & x > TH \\ 0 & x < TH \end{cases} \tag{0.3}$$

$$f(x) = \frac{1}{1 + \exp\left(-\frac{x}{T}\right)} \tag{0.4}$$


<ネットワークの構成>

NNの構成には図0.2(a)に示す相互結合型NNと図0.2(b)に示す階層型NNに分類され、それぞれのネットワークは表0.1に示す特徴を持つ。表中の教師あり・なし学習とはNNに対し、ものを教える場合に正解パターンをネットワークに提示するか否かということである。本論文では階層型NNを使用する。

階層型NNの単純な構成であるパーセプトロンをローゼンブラット(Rosenblatt)が提案した。さらに、彼は「パーセプトロンは単純化されたネットワークであって、実際の神経系において、いくつかの特性が強調され、他の特性は全く無視されたものである。これはいかなる現実の神経システムのコピーも意図したものではない。」と述べている⁽⁵⁸⁾。したがって、図0.1に示されるニューロンモデルや図0.2(a), (b)に示されるNNの構成は人間のニューロンのコピーではなく、計算機にて脳と同等の効果を得ることを目的とし、単純化されたモデルである。人間の場合、脳のニューロンは約140億個存在し、それぞれのニューロンは他のニューロンと平均約1000個のつながりをもっており、NNは数百のニューロンを結合したものに過ぎないのである^{(59), (60)}。



(a) 相互結合型 NN




(b) 階層型 NN

図 0.2 NN の分類


表 0.1 分類別における NN の特徴⁽⁵⁹⁾

ネットワーク構造	階層型 NN	相互結合型 NN
学習アルゴリズム	教師あり学習	教師なし学習
入力信号の流れ	フィードフォワード	フィードバック
時間の取り扱い	連続(アナログ的)	不連続(デジタル的)
応用分野	パターン認識	自己想起

ニューロンの出力は ON または OFF の 2 出力である。つまり、閾値 (TH: Threshold) を 0 とするとニューロンの出力関数は図 0.3 (a) に示されるステップ関数であると考えられる。しかしながら、ステップ関数は重みの適切な修正量が出力されないという問題が考えられるため、ステップ関数の ON-OFF 特性を保存しながら、適切な重みの変化量を出力できるため、一般的な出力関数としてシグモイド関数が用いられる。図 0.3 (b) にシグモイド関数を示す。閾値と入力の重み付き総和が近似した値の場合、ニューロンの出力は中間値付近の出力値となる。これはステップ関数の特徴を保持しながら、ニューロンの出力が学習を行う際に有益な形で入力と関連付けられることを示す。また、このシグモイド関数は単調増加で微分可能であるため、後述する逆誤差伝播法 (Error Back Propagation Method) に適用できる^{(61)~(64)}。



(a) ステップ関数



(b) シグモイド関数

図 0.3 出力関数

4.3.1 項の実験 16 にて、入力値の統計解析を行った。その解析結果の一部(30 動作のうち 7 動作)を表 4.15 に示した。ここで 30 動作の全解析結果について示す。表 0.2 に(手法 2)を用いた場合のパターン間のマハラビス距離を示す。表内の()内の数値はパターン間距離の大きい上位 10 組の順位を表記している。表 0.3 に上位 10 組の集計結果を示す。なお、ここでの使用データは 4 極の電極に手首に配したデータである。

表 0.2 (手法 2)を用いた NN データの統計解析結果

パターン番号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
	握・静止状態	握・上	握・下	握・右	握・左	握・回内	握・回外	握・握り	握・開き	開・親指曲げ	開・人差指曲げ	開・中指曲げ	開・薬指曲げ	開・小指曲げ	開・静止状態
1	握・静止状態														
2	握・上	238													
3	握・下	360 (9)	287												
4	握・右	112	61	92											
5	握・左	103	34	152	29										
6	握・回内	116	62	100	3	27									
7	握・回外	40	2	109	34	14	33								
8	握・握り	90	56	50	14	36	16	40							
9	握・開き	161	89	120	0	36	3	38	15						
10	開・親指曲げ	40	345	361 (8)	104	93	109	33	85	154					

11	開・人差指曲げ	93	27	153	32	4	31	11	38	39	83					
12	開・中指曲げ	95	17	181	42	15	41	5	45	54	85	10				
13	開・薬指曲げ	99	29	157	32	4	31	12	38	40	89	1	11			
14	開・小指曲げ	52	0	144	43	20	42	1	47	50	44	16	9	17		
15	開・静止状態	16	683 (2)	388 (6)	117	111	123	42	93	174	127	100	105	107	56	
16	開・上	108	60	83	3	31	5	36	11	4	101	34	43	34	44	113
17	開・下	92	26	154	33	5	31	11	39	40	83	1	9	2	16	100
18	開・右	167	71	174	23	11	21	22	32	30	159	16	30	16	32	188
19	開・左	77	0	192	51	26	51	2	52	65	66	21	12	22	0	85
20	開・回内	63	26	86	14	7	13	17	24	16	57	10	16	9	21	66
21	開・回外	58	37	237	71	50	72	15	65	94	44	43	37	46	18	68
22	握・右上	99	61	59	12	37	15	41	2	14	94	39	48	39	49	103
23	握・右下	58	32	52	0	18	2	25	10	1	54	20	25	19	28	60
24	握・左上	153	135	316	78	58	81	15	68	115	186	49	44	54	18	377 (7)
25	握・左下	83	33	113	19	7	17	18	28	22	76	10	19	10	24	88
26	握・1本伸ばす	283	141	214	26	12	24	23	33	37	314	17	34	17	33	394 (5)
27	握・2本伸ばす	354 (10)	232	250	39	4	38	14	42	57	606 (3)	2	18	1	22	1570 (1)
28	握・3本伸ばす	74	19	136	31	6	30	9	38	37	66	2	6	3	13	79

29	握・4本伸ばす	287	148	210	24	15	22	24	32	34	318	20	38	20	35	398 (4)
30	握・親指立てる	268	176	114	20	66	24	55	2	27	268	69	91	71	75	300

パターン番号		16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
		開・上	開・下	開・右	開・左	開・回内	開・回外	握・右上	握・右下	握・左上	握・左下	握・1本伸ばす	握・2本伸ばす	握・3本伸ばす	握・4本伸ばす	握・親指立てる
1	握・静止状態															
2	握・上															
3	握・下															
4	握・右															
5	握・左															
6	握・回内															
7	握・回外															
8	握・握り															
9	握・開き															
10	開・親指曲げ															
11	開・人差指曲げ															
12	開・中指曲げ															
13	開・薬指曲げ															
14	開・小指曲げ															

15	開・静止状態															
16	開・上															
17	開・下	34														
18	開・右	25	17													
19	開・左	52	20	44												
20	開・回内	16	10	1	23											
21	開・回外	71	43	76	23	37										
22	握・右上	9	40	32	55	23	70									
23	握・右下	1	20	13	30	11	40	8								
24	握・左上	77	49	106	26	38	4	74	41							
25	握・左下	21	11	1	28	1	47	28	13	50						
26	握・1本伸ばす	28	18	2	50	1	93	35	14	207	0					
27	握・2本伸ばす	40	3	27	34	10	78	44	20	352	11	51				
28	握・3本伸ばす	33	2	17	16	11	35	39	20	38	12	17	5			
29	握・4本伸ばす	26	21	2	53	0	96	33	13	213	2	7	60	19		
30	握・親指立てる	15	71	70	103	31	145	1	10	212	43	94	130	62	89	

表 0.3 表 0.2 の結果から算出されたパターン間距離の大きい上位 10 組の組み合わせ

(() 内の数値は表 0.2 のパターン番号を示す.)

	最大距離組み合わせ		距離値
1	開・静止状態(15)	— 握・2 本伸ばす(27)	1570
2	開・静止状態(15)	— 握・上(2)	683
3	開・親指曲げ(10)	— 握・2 本伸ばす(27)	606
4	開・静止状態(15)	— 握・4 本伸ばす(29)	398
5	開・静止状態(15)	— 握・1 本伸ばす(26)	394
6	開・静止状態(15)	— 握・下(3)	388
7	開・静止状態(15)	— 握・左上(24)	377
8	開・親指曲げ(10)	— 握・下(3)	361
9	握・静止状態(1)	— 握・下(3)	360
10	握・静止状態(1)	— 握・2 本伸ばす(27)	354

表 0.2 に(手法 2)を用いた統計解析結果を示した. 表 0.4 では(手法 1)を用いた場合のマハラビス距離を示す. 表内の()内の数値はパターン間距離の大きい上位 10 組の順位を表記している. 表 0.5 に上位 10 組の集計結果を示す.

表 0.4 (手法 1:正規化定数k=1000)を用いた NN データの統計解析結果

パターン番号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
	握・静止状態	握・上	握・下	握・右	握・左	握・回内	握・回外	握・握り	握・開き	開・親指曲げ	開・人差指曲げ	開・中指曲げ	開・薬指曲げ	開・小指曲げ	開・静止状態
1	握・静止状態														
2	握・上	5020													
3	握・下	7671 (9)	6128												
4	握・右	2345	1274	1933											
5	握・左	2165	719	3211	604										
6	握・回内	2460	1304	2121	53	575									
7	握・回外	832	40	2288	712	301	688								
8	握・握り	1902	1184	1044	289	755	336	847							
9	握・開き	3397	1880	2531	3	749	60	787	318						
10	開・親指曲げ	850	7230	7710 (8)	2190	1966	2297	700	1788	3231					
11	開・人差指曲げ	1966	566	3236	673	92	648	237	806	829	1767				
12	開・中指曲げ	1990	352	3819	883	309	870	112	954	1124	1768	205			
13	開・薬指曲げ	2095	626	3324	669	74	643	254	802	832	1892	21	234		
14	開・小指曲げ	1096	4	3038	900	423	883	30	988	1053	921	340	188	364	
15	開・静止状態	330	14408 (2)	8289 (5)	2463	2343	2595	890	1964	3655	2684	2127	2196	2274	1187

16	開・上	2262	1264	1749	61	643	114	744	233	74	2114	709	907	705	926	2366
17	開・下	1946	546	3251	685	106	660	228	815	843	1747	14	190	34	329	2107
18	開・右	3519	1505	3699	483	241	446	464	665	642	3357	343	637	331	662	3964
19	開・左	1618	8	4052	1074	545	1072	40	1092	1363	1385	436	254	472	8	1801
20	開・回内	1321	540	1808	301	145	266	355	504	330	1194	205	344	193	438	1383
21	開・回外	1215	761	5011	1490	1039	1518	315	1374	1959	926	909	766	965	369	1428
22	握・右上	2095	1280	1238	258	775	309	856	48	290	1969	831	1000	828	1022	2172
23	握・右下	1235	667	1086	9	370	43	519	205	12	1141	415	523	407	592	1277
24	握・左上	3256	2841	6738	1638	1215	1699	304	1424	2415	3954	1044	916	1130	370	8119 (7)
25	握・左下	1758	697	2387	395	147	358	381	595	459	1596	221	402	208	496	1860
26	握・1本伸ばす	5948	2959	4553	543	250	510	471	703	778	6586	364	722	354	698	8298 (4)
27	握・2本伸ばす	7463	4907	5339	807	81	798	297	876	1192	12709 (3)	49	375	22	464	33111 (1)
28	握・3本伸ばす	1561	401	2862	660	130	633	191	800	781	1383	47	130	66	271	1672
29	握・4本伸ばす	6011	3079	4460	496	310	460	504	672	710	6625	422	788	414	742	8283 (6)
30	握・親指立てる	5650	3710	2420	415	1394	513	1143	43	564	5646	1465	1904	1497	1569	6341

	パターン番号	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
		開・上	開・下	開・右	開・左	開・回内	開・回外	握・右上	握・右下	握・左上	握・左下	握・1本伸ばす	握・2本伸ばす	握・3本伸ばす	握・4本伸ばす	握・親指立てる
1	握・静止状態															

2	握・上														
3	握・下														
4	握・右														
5	握・左														
6	握・回内														
7	握・回外														
8	握・握り														
9	握・開き														
10	開・親指曲げ														
11	開・人差指曲げ														
12	開・中指曲げ														
13	開・薬指曲げ														
14	開・小指曲げ														
15	開・静止状態														
16	開・上														
17	開・下	720													
18	開・右	529	358												
19	開・左	1088	422	916											
20	開・回内	343	214	12	493										

21	開・回外	1478	893	1593	483	780									
22	握・右上	198	841	681	1154	489	1477								
23	握・右下	31	422	278	636	225	849	173							
24	握・左上	1602	1025	2237	548	800	85	1554	856						
25	握・左下	441	232	25	593	26	978	592	266	1055					
26	握・1本伸ばす	586	382	38	1047	27	1939	730	295	4348	7				
27	握・2本伸ばす	831	68	556	724	206	1635	928	426	7488 (10)	238	1069			
28	握・3本伸ばす	696	35	348	334	227	734	819	428	793	244	360	101		
29	握・4本伸ばす	543	440	49	1112	6	2010	694	271	4436	52	142	1237	408	
30	握・親指立てる	312	1480	1483	2174	659	3032	19	218	4463	912	1969	2731	1305	1868

表 0.5 表 0.4 の結果から算出されたパターン間距離の大きい上位 10 組の組み合わせ

(()内の数値は表 0.2 のパターン番号を示す.)

	最大距離組み合わせ		距離値
1	開・静止状態(15)	— 握・2本伸ばす(27)	33111
2	開・静止状態(15)	— 握・上(2)	14408
3	開・親指曲げ(10)	— 握・2本伸ばす(27)	12709
4	開・静止状態(15)	— 握・1本伸ばす(26)	8298
5	開・静止状態(15)	— 握・下(3)	8289
6	開・静止状態(15)	— 握・4本伸ばす(29)	8283
7	開・静止状態(15)	— 握・左上(24)	8119
8	開・親指曲げ(10)	— 握・下(3)	7710
9	握・静止状態(1)	— 握・下(3)	7671
10	握・左上(24)	— 握・2本伸ばす(27)	7488