

平成 20 年 9 月修了
博士 (工学) 学位論文

ニューラルネットワークによる
オンラインチューニングシステムの
研究

Research of the Online Tuning System
using Neural Networks

平成 20 年 6 月 13 日

高知工科大学大学院 工学研究科 基盤工学専攻 (基盤工学コース)

学籍番号 1098101

佐藤公信

Hironobu SATOH

要 旨

ニューラルネットワークによる オンラインチューニングシステムの研究

佐藤公信

これまでに著者は、いりこ選別、起床検知などのパターン認識の分野でニューラルネットワーク (NN:Neural Network) による識別システムの提案を行ってきた。一般に NN は、人間の脳の情報処理の一部を模倣しており、柔軟な識別が可能であることが知られている。現在、NN を使用した識別および検査機器の製品化のニーズは高い。しかしながら、次の問題点が指摘されている。つまり、NN を使用したアプリケーションは、パラメータの設定などが経験に依存する部分が多い。さらには、想定外の環境において、極端に学習時と異なる識別データを扱う場合には、NN の汎化能力を用いたとしても、正しく識別することができない危険性が想定される。

この問題に対処する方法として、すべての学習データを学習に使用する方法が考えられるが、メモリの容量などに制限があり、無限に近いデータを扱うことができない。さらに、工場出荷後の製品は、予測できないデータに対してもある程度識別率を維持する必要がある。しかしながら、市場では学習時から大きく外れるデータが存在することが想定され、現状の識別システムでは、これらの対応が未だ不十分である、

そこで、本研究では、これらの問題の一つの解決方法として、オンラインチューニングシステムを提案する。オンラインチューニングシステムとは、NN の学習機能を利用して、学習用のデータをリアルタイムで追加しながら、初期学習後の NN に対し、継続学習を実施するものである。これにより、識別システムの自律的なブラッシュアップを図ることが期待で

きる。

具体的には、まず、学習データに対して一定の識別率を有する初期ウェイトを作成する。次に、初期学習時より少数のデータを順次学習データに追加していくことで、初期ウェイトに対し継続学習を行う。この方法を、目的とする識別性能が得られるまで繰り返す。

提案するオンラインチューニングシステムにより、NNの継続学習を有効に機能させることが可能であると予想される。さらに、対象の動特性が変化した場合もオンラインチューニングシステムを実施することで、その都度特性の変動に合わせた学習が可能となる。

本論文では、オンラインチューニングシステムの有効性確認として、まず、筋活動電位(EMG:Electromyogram)を用いた手首動作識別システムにおいて検証を行う。手首動作識別システムは、マウスと同等の操作が可能な新たなマシンインタフェイスを目的として研究が進められてきた。このシステムは、手首に装着した4個の乾式センサより測定された情報を特徴抽出後にNNに入力し、手首動作(静止、背屈、掌屈、回内、回外、開き、握り)を識別するシステムである。しかしながら、EMGは個人差があり、NNの汎化能力だけでは、個人差の吸収が難しいことが判明している。提案システムの有効性確認実験では、はじめに、初期学習を行い識別率の確認を行った。その後、オンラインチューニングを行いオンラインチューニング前後の識別率を比較することで、その有効性を示した。

次に、起床検知システムにおいてオンラインチューニングシステムの有効性確認を行った。起床検知システムは、画像を用いた検知対象者のベッドからの転落の予測検知を目的としたシステムである。このシステムは、検知対象者の全体画像をNNへの入力とし、被験者の予測検知を行う。これに対しても、検知対象者のベッドにおける振る舞いには、個人差があり、ベッドから転落するまでの行動は個人により異なることが知られている。提案システムの有効性確認実験では、はじめに、初期学習を行い検知率の確認を行った。その後、オンラインチューニングを行いオンラインチューニング前後の識別率を比較することで、その有効性を示した。

キーワード オンラインチューニング, ニューラルネットワーク, パターン認識

目次

第 1 章	はじめに	1
第 2 章	オンラインチューニングシステムの提案	12
2.1	背景	12
2.2	オンラインチューニングシステム	14
2.2.1	オンラインチューニングの適用	18
第 3 章	オンラインチューニングシステムの適用	20
3.1	筋活動電位を用いた手首動作識別システムへの適応	20
3.1.1	システム概要	20
3.1.2	EMG	21
	DSP ユニット	23
3.1.3	システム構成	30
	入力部	30
	信号処理部	31
	特徴抽出部	33
	FFT	33
	NN 入力値の算出	34
3.1.4	学習および識別部	37
	データファイルの作成	37
	学習用データファイルの抽出	39
	NN 入力値の並び替え	39
	教師ファイルの作成	40
	NN	41

目次

3.1.5	NNの重み調整	41
	識別	43
	オンラインチューニング	44
3.2	手首動作識別システムにおけるオンラインチューニング実験	45
3.2.1	実験概要	45
3.2.2	実験	45
3.3	起床検知システムへの適応	48
3.3.1	起床検知システム概要	48
3.3.2	ハードウェア	52
3.3.3	ソフトウェア	55
	特徴抽出部	55
	学習	59
	検知部	59
	オンラインチューニング	60
3.4	起床検知システムにおけるオンラインチューニング実験	60
3.4.1	実験概要	60
3.4.2	起床検知システムの個人差の検証	60
3.4.3	オンラインチューニングの有効性検証実験	66
第4章	オンラインチューニングシステムの考察	76
第5章	おわりに	78
	謝辞	82
	参考文献	83
付録A	本件に関する業績	88

目次

2.1	オンラインチューニングイメージ	16
2.2	オンラインチューニングのフローチャート	16
2.3	学習データの追加に伴う識別率の変化	17
2.4	6人の被験者のEMG	18
3.1	システム構成	20
3.2	EMG発生の順序機構	22
3.3	細胞の興奮と筋活動電位	22
3.4	DSPユニットブロック図	23
3.5	DSPユニット	26
3.6	ソフトウェアフローチャート	28
3.7	LCD	28
3.8	7セグLED	29
3.9	センサ	30
3.10	オペアンプの実装	32
3.11	手首挙動（掌屈の波形）	34
3.12	NNへの入力データモデル	35
3.13	データファイルの構成	39
3.14	NN入力値の並び替え	40
3.15	教師ファイル作成イメージ	40
3.16	シグモイド関数	41
3.17	慣性定数と振動定数の範囲	42
3.18	同一被験者によるNN入力値	44
3.19	起床検知システム検査フロー	49

図目次

3.20 起床検知システム実験環境	50
3.21 5 行動のクラス分け (就床)	50
3.22 5 行動のクラス分け (起床途中)	50
3.23 5 行動のクラス分け (起床)	51
3.24 5 行動のクラス分け (落下途中)	51
3.25 5 行動のクラス分け (落下)	51
3.26 起床検知システム実験筐体	53
3.27 WEB カメラ	53
3.28 選定カメラを用いて撮像した画像	54
3.29 選定カメラを用いて撮像した画像のヒストグラム	54
3.30 静的情報と動的情報の撮像画像	56
3.31 起床検知システムの撮像画像	57
3.32 検知対象者の切り出し	57
3.33 特徴抽出処理のイメージ	58
3.34 動的情報の特徴抽出	58
3.35 NN 構成	59
3.36 NN ウェイト A の検知率の変化	74
3.37 NN ウェイト B の検知率の変化	74
3.38 NN ウェイト C の検知率の変化	75

表目次

3.1	NN 入力値算出表	36
3.2	バイナリファイルのフォーマット	37
3.3	ヘッダ情報のフォーマット	38
3.4	手首動作識別システムにおけるオンラインチューニングシステム有用性確認 実験条件	46
3.5	オンラインチューニングシステム有用性確認実験識別結果	47
3.6	起床検知システムにおけるオンラインチューニングシステム有用性確認実験 条件	62
3.7	初期学習後の NN ウェイト A における検知結果	63
3.8	初期学習後の NN ウェイト B における検知結果	64
3.9	初期学習後の NN ウェイト C における検知結果	65
3.10	オンラインチューニング 1 回目の NN ウェイト A における検知結果	68
3.11	オンラインチューニング 1 回目の NN ウェイト B における検知結果	69
3.12	オンラインチューニング 1 回目の NN ウェイト C における検知結果	70
3.13	オンラインチューニング 2 回目の NN ウェイト A における検知結果	71
3.14	オンラインチューニング 2 回目の NN ウェイト B における検知結果	72
3.15	オンラインチューニング 2 回目の NN ウェイト C における検知結果	73

第 1 章

はじめに

現在、高齢化社会による働き手の不足、また、企業の経営状況改善のための人員削減、さらに検査精度の向上を目的として、成形プラスチック製品などの検査や、いりこに加工するための魚種の選別といった選別および検査システムを人手によるシステムから機械化するニーズが高まっている。さらに、人手だけの検査を行った場合、選別および検査を実施している労働者の集中力の低下による誤選別、また、見落としの抑制は難しい。そのため、人手による検査を行った後、選別および検査ミスを未然に防止するため、ダブルチェックを行うことが必要とされている。それ故、ダブルチェックを行うシステムを実現するため、人手による検査後の補助的役割を果たす検査装置のニーズも高い。

これまでの通常のテンプレートマッチング識別部として使用していない識別アプリケーションでは、識別ルールを決定する際に経験的勘にパラメータ調整をゆだねるなどがあり、その識別ルールを決定することを容易に行うことが不可能であった。しかし、ニューラルネットワーク (NN:Neural Network) により識別部を構成する NN 識別アプリケーションは、それぞれのクラス分類の対象となるパターンの学習データがサンプリングされている場合、学習を行うことで、その識別ルールを自己形成することが可能である。また、NN は未知のデータに対して正しい識別が可能な汎用能力を有することが知られている。さらに、NN は区分的線形識別関数と極限において等価であることが証明されており [1]、区分的線形識別関数は非線形識別関数を任意の精度で近似できるため、非線形な識別が可能であることが判明している。これら有用な特徴を利用可能であると共に学習による識別ルールの決定と柔軟な識別を行うことが可能な NN の汎用能力を利用した識別および検査機器の製品化が望まれている。

現在、NN 識別アプリケーションの例としては、画像からの顔検出や男女の顔特徴の抽出などが挙げられる [2, 3]. 著者もこれまでに、手首動作識別 [4, 5], いりこ選別 [6, 7], 起床検知 [8, 9, 10, 11], 医療画像診断システム [12, 13] などのパターン認識の分野で NN による識別アプリケーションの提案を行ってきた.

しかしながら、NN 識別アプリケーションには、次の問題点が指摘されている. NN 識別アプリケーションでは、パターン分類の対象となる学習データが必要であり、個々のパターンにおいてパターン内の範囲全てを含むデータが必要である. つまり、学習データは、識別範囲となる 1 つのパターン内のデータとして、他パターンとの境界近くデータを包括する必要がある. そこで、このデータを学習データとして学習を行うことにより、NN の汎化能力を十分に得ることが可能である. そのため、NN 識別アプリケーションは、想定外の環境において、つまり、極端に学習時と異なる識別データを扱う場合には、NN の汎化能力を用いたとしても、正しく識別することが不可能である危険性が想定される [14, 15]. 例えば、筋活動電位 (EMG:Electromyogram) を用いた手首動作識別システムにおいては、EMG の個人差が識別結果に影響を与えていることが報告されている [4, 5].

この問題に対処する方法として、すべての学習データを学習に使用する方法が考えられる. つまり、パターン内に存在すると予測される全てのパターンのデータを想定し、さらに他パターンとの境界を特定しデータをサンプリングし学習データとすることである. しかし、この手法による問題解決は次の理由により難しい. つまり、手首動作識別システムが識別対象としている EMG は、乾式表面電極で測定され湿度や温度また外部からの電磁波の影響、筋の量や脂肪の量などのさまざまな影響の組み合わせがあり、これらをすべて想定しサンプリングすることを容易に行うことはできない. また、起床検知システムの識別対象としている人の挙動において、その挙動には腕や手を曲げる角度や足を曲げる角度、布団の形状などの考慮すべき条件が数多く存在し、これらすべての挙動を想定し網羅するデータをサンプリングすることは難しい. さらに、すべてのデータが揃ったとしても、現在、普及している PC は内部の処理および 32bit で表現された OS であり、32bit で定義可能なメモリアドレス空間は 2Gbyte と制限されるため、特殊な演算装置または 64bit の OS を使用すること

を除き、無限に近い数のデータを学習時に扱うことは難しい。このメモリアドレス空間の制限の問題を解消する方法としては、PCにおいてはハードディスクドライブ上に仮想メモリを確保し、それをメモリとして使用しての学習も考えられるが、ハードディスクドライブへのアクセス時間はメモリへのアクセス時間に比べ遅く、演算時間が増加する問題を避けることができない。さらに、これらに加えてNN識別アプリケーションが製品化された場合、工場出荷後の製品は、予測できないデータに対しても、ある程度の識別率を維持する必要がある。ここで、NNの汎化能力により学習データ範囲内のデータのばらつきが存在したとしても正しく識別することは可能である。しかしながら、市場では予測することが難しい学習時のデータから大きく外れるデータが存在することが想定される。その原因として、例えば、使用環境特有の電波ノイズや湿度や温度、ほこり、静電気などにより、データが大きく変動することが考えられる。この原因により、現状入手可能なデータから学習データを選定し、初期学習を行ったNNを識別部とするNN識別アプリケーションでは、これらへの対応が未だ不十分であると言える。

そこで、本研究では、これらの問題の一つの解決方法として、オンラインチューニングシステムを提案する。未知のデータへの対応方法として、人間の脳においては新しいデータへの順応および記憶は学習により行われる。人間の脳における学習とは、シナプスの結合の強さを調整することにより行われる[16]。そこで、新しいデータを取得し、シナプスの結合の強さを再調整するアルゴリズムをNN識別アプリケーション上で模倣し構築する。このシステムをオンラインチューニングシステムとして提案する。オンラインチューニングシステムとは、NNの学習機能を利用して、学習用のデータをリアルタイムで追加しながら、初期学習後のNNに対し、継続学習を実施するものである。NNのバックプロパゲーションアルゴリズムを用いた学習や前向き行列演算は、高速な中央演算装置(CPU:Central Processing Unit)やデジタルシグナルプロセッサ(DSP:Digital Signal Processor)などの演算装置の演算能力を用いることにより、入力細胞数および中間細胞数を1000を超える細胞数を設定したり、もしくは、大量の学習データを使用しない限り、短時間で追加学習が可能である。また、現在の数多く普及しているPCでは、最大で2Gbyteの物理メモリを使用

可能であるため、新しく取得したデータを物理メモリ空間にストアすることが可能で、短時間での学習が可能であると考えられる。

提案手法の具体的内容は、まず、識別対象となるデータをサンプリングし、学習データを選定し学習を行う。ここで、予想範囲内の未知のデータに対して一定の識別率を有する初期 NN を作成する。次に、使用者本人の少数のデータを順次学習データとしてサンプリングするとともに、このデータを用いて初期 NN に対し継続学習を行う。この手順を、目的とする識別性能が得られるまで繰り返す。

提案するオンラインチューニングシステムにより、NN の継続学習を有効に機能させることが可能であると予想される。そのため、識別アプリケーションの自律的なブラッシュアップおよび識別率の維持が期待できる。さらに、対象の動特性が変化した場合もオンラインチューニングシステムを実施することで、その都度特性の変動に合わせた学習が可能となる。つまり、個人差を伴うバイオメトリックスや挙動を識別対象とする NN 識別システムでは、オンラインチューニングを実行することにより、使用者本人に特化する NN 識別システムに容易にカスタマイズ可能である。

現在、追加学習が可能な大規模ニューラルネットの研究 [17, 18] も行われている。この研究では、学習済みのデータを含めて再学習を必要としないために初期学習時より短時間での学習が可能である。また、識別率も初期学習時に比べて向上することが確認されている。しかし、NN 識別アプリケーションの使用者本人へのカスタマイズおよび最適化については検討が行われていない。つまり、多数の被験者のデータをサンプリングし継続学習を行い識別率の上昇を検証のみに止まっている。また、多数の被験者からデータをサンプリングしたために、個人差などの影響により大きくばらつくデータを扱っての検討が行われていないと言える。

本論文では、使用者本人への NN 識別アプリケーションのカスタマイズおよび最適化、また、個人差などの影響により大きくばらつくデータを識別対象としてオンラインチューニングシステムの有効性確認実験を行う。そこで、以下に示す 2 つの異なる特徴を有する識別対象を扱う NN 識別アプリケーションにオンラインチューニングシステムを導入し、オンライ

ンチューニングシステムの有効性を検証する。2つの NN 識別アプリケーションの扱う識別対象は、乾式表面電極で計測される EMG と WEB カメラで撮像された画像と異なる。さらに、前者のデータは 1 次元の時系列データであり、後者のデータは、それぞれが 2 次元で表現される 5 枚の画像である。また、これら 2 つの NN 識別アプリケーションの識別結果は、共に個人差の影響を受けることで知られている [8, 9, 10, 11].

手首動作識別システムの識別対象とする EMG は、年齢、性別、筋の量、温度、湿度などにより想定されるデータは多種多様であり、想定外のデータも数多く存在することが予測される。つまり、使用者毎の EMG データをサンプリングすることは容易であるが、未学習の使用者の汎化能力を得ることが可能な学習データをサンプリングすることは難しい。過去の研究より、手首動作識別システムは学習の対象となった被験者の識別に有効であることが判明している [19, 20]. そこで、手首動作識別システムにオンラインチューニングシステムを導入し、使用者の EMG を対象としてオンラインチューニングすることにより、使用者本人の識別に特化した識別システムに NN を再調整することが可能であると考え。また、未学習者のデータをサンプリングし追加学習が可能で、容易に未学習者を学習者として追加することが可能な NN 識別アプリケーションにアップグレードすることが可能である。ここで、未学習の使用者の識別率は、学習対象となった使用者の識別率より低くなることが予測される。しかし、未学習の使用者が手首動作識別システムを使用する場合、その都度オンラインチューニングを実行し、使用者に合わせた手首動作識別システムに再調整を行うことが可能で、使用者本人に対して有効な識別率を得る、つまり、特定の使用者に特化した識別システムに再調整が可能であると考え。さらに、起床検知システムにおいては、ベッド上での使用者の動きは多種多様な挙動の個人差が存在し、個人により画像のばらつきが大きいことが予測される。この実証については、第 4 章の実験にて行う。起床検知システムにおいても、全ての想定可能なデータをサンプリングすることは、考慮すべき条件が数多く存在するため難しい。さらに、パターン間の境界線を特定することは容易ではない。つまり、使用者毎にベッド上での画像をサンプリングすることは可能であるが、未学習の使用者の汎化能力を得る学習データを作成することは困難である。過去の研究により、学習対象となった使用者の

検知率は有効であることが、確認されている [10]. そこで、オンラインチューニングシステムを導入することにより、使用者毎にばらつく画像を扱う場合においても、未学習の使用者から学習データをサンプリングし追加することが可能で、容易に未学習の使用者を学習者としてシステムに追加することが可能である。そのため、未学習の使用者の識別率は低い状態は続くが、学習を行った使用者の識別率は有効な識別率を得ることが可能であると考えられる。つまり、起床検知システムも特定の使用者の検知に特化したシステムに容易に識別ルールの再調整が可能な識別システムにアップグレードが可能であると考えられる。

これら 2 つの特性の異なるデータを識別対象とする NN 識別アプリケーションにおいて、オンラインチューニングシステムを導入し、有効性が確認されたならば、オンラインチューニングシステムには汎用性を有することが推測される。また、これら 2 つの NN 識別アプリケーションにおいて、有効性が確認されたならば、個人差ならびに経年変化を伴う種々の産業アプリケーションの性能維持などに、特にその威力を発揮するものと思われる。例えば、心電図ノイズフィルタリングへのオンラインチューニングシステム適応が、その応用例として挙げられる。また、時系列的に変動するデータを扱う NN 識別アプリケーションへの導入も検討の余地を残す。例えば、その時々々の社会情勢により大きく左右される、金融市場予測へのオンラインチューニングシステムの適応である。金融市場予測では、その時々々にオンラインチューニングを行い、市場予測への追従が可能ではないかと考える。さらに、環境の変化により、大きく影響を受けるデータを扱う NN 識別アプリケーションへの導入も期待される。これは、音声信号や映像信号を含む電気信号のノイズフィルタリングへのオンラインチューニングシステムの導入が挙げられ、オンラインチューニングにより、ノイズフィルタリングの使用環境に合わせてフィルタリングの高精度化が可能ではないかと考える。

オンラインチューニングシステムの有効性確認として、まず、EMG を用いた手首動作識別システムにおいて検証を行う。手首動作識別システムは、マウスと同等の操作が可能な新たなマシンインタフェースを目的として研究が進められてきた。このシステムは、手首に装着した 4 個の乾式表面電極より測定された情報を特徴抽出後に NN に入力し、手首動作 (静止, 背屈, 掌屈, 回内, 回外, 開き, 握り) を識別するシステムである。表面電極により計

測可能な EMG は、微弱な電気信号であり、1次元の時系列データで計測される。計測された EMG は、特徴抽出として高速フーリエ変換を用いパワースペクトルが算出される。この値を NN への入力値として NN へ入力を行い、NN からの最大発火の細胞に対応するパターンを判定結果とし、手首動作の判定が行われる。しかしながら、乾式表面電極により計測される EMG は個人差があり、NN の汎化能力だけでは、個人差の吸収が難しいことが判明している [4, 5, 19, 20, 21, 22]。提案システムの有効性確認実験では、はじめに、初期学習を行い識別率の確認を行う。その後、オンラインチューニングを行い、オンラインチューニング前後の識別率を比較することで、その有効性を示す。

次に、起床検知システムにおいてもオンラインチューニングシステムの有効性確認を行う。起床検知システムは、画像を用いた検知対象者のベッドからの転落の予測検知を目的としたシステムである。このシステムは、検知対象者の 5 枚の全体画像から特徴抽出としてブロック化および 2 値化を行い、NN への入力値として NN へ入力し、NN からの最大発火の細胞に対応するパターンを検知結果とし、被験者の予測検知を行う。これに対しても、検知対象者のベッドにおける振る舞いには、個人差があり、ベッドから転落するまでの行動は個人により異なることが考えられている。そこで、まず検知対象者のベッド上での行動の個人差が、起床検知システムの検知結果に影響を与えるか確認を行う。提案システムの有効性確認実験では、はじめに、初期学習を行い識別率の確認を行う。その後、オンラインチューニングを 2 回を行い、検知率の変化を確認することにより、その有効性を示す。

本論文は、6つのパーツから構成されており、以下にそれぞれの概要を示す。

第 1 章では、研究の背景とこれまでの NN を識別部に用いた NN 識別アプリケーションの問題点を述べる。さらに、オンラインチューニングシステムは NN 識別アプリケーションに導入が可能であることについても述べる。特に二つのアプリケーション題材についての概要を示す。1つは筋活動電位による手首動作識別システムであり、もう一つは、起床検知システムである。手首動作識別システムは、マウスと同等の操作が可能な新たなマンマシンインタフェースを目的として研究が進められてきた。このシステムは、手首に装着した 4 個の乾式センサより計測された情報を前処理後に NN に入力し、手首の動作 (静止, 背屈, 掌屈,

回内, 回外, 開き, 握り) を識別するシステムである。しかしながら, 筋活動電位は個人差があり, NN の汎化能力だけでは個人差の吸収は難しいことが判明している。一方, 起床検知システムは, 検知対象者のベッドからの転落の予測検知を目的としたシステムである。このシステムは, 被験者の全体画像を NN への入力とし, 被験者の予測検知を行う。これに対しても, 行動には個人差があると考えられ, ベッドから転落するまでの行動は個人により異なることが知られている。本章では, これら二つの識別対象が大きく個人差の影響を受ける NN 識別アプリケーションにおいて, オンラインチューニングシステムの有効性の確認を行うことを示す。

第 2 章では, NN を用いたアプリケーションの問題点について示す。一般に, NN の特徴の一つとして汎化能力が挙げられる。汎化能力とは未学習のデータに対しても適切にパターン識別が可能な能力である。NN は提示されたデータを学習することにより, パターンに含まれる特徴を検出可能となるように NN を調節する。そこで, 重要となる特徴量を未学習のデータでもパターンを分類することができ, ある程度の汎化能力を示している。しかし, これまで提示されたデータの入力範囲を超えるものが入力された場合に, NN が学習により記憶した特徴量と類似する特徴量が検出できず識別が不可能である。この問題により, 識別データが個人差や環境の影響によりデータが大きく変化する場合, NN 識別アプリケーションの識別能力は不十分となる。この問題の解決方法として, オンラインチューニングシステムを提案する。オンラインチューニングシステムの目的は, 大きな変動の無い, つまり, 限定された識別データで初期学習を行い, このデータに対して識別能力を有する NN を, 個人差および経時変化などの要因により動的に変化する識別データに適応させることである。オンラインチューニングシステムのアルゴリズムは, まず, 初期学習として限定されたデータで識別能力を有するように初期学習を行う。オンラインチューニングシステムにより, 新たに変化したデータを初期学習データに追加し, NN の継続的な学習を行う。目標とする十分な識別率が得られるまで, この継続学習および学習データの順次追加を繰り返す。このアルゴリズムの実現により, 識別システムは, 識別データの変動に対応することが可能で, 個人差や環境の変化により大きく変動したデータに対しての識別率の向上あるいは維持が可能で

あると予測される。

第3章では、オンラインチューニングシステムの有効性の確認に用いる手首動作識別システムと、その識別対象であるEMGについて述べる。一般に、EMGは個人差が大きいことが報告されている。手首動作識別システムの識別アルゴリズムは次の手順で行われる。まず、EMG信号（時系列データ）を手首に装着した電極で測定する。次に、測定されたEMG信号は、増幅器を用いて増幅される。増幅されたEMG信号は、デジタルシグナルプロセッサ(DSP:Digital Signal Processor)のA/D変換器よりA/D変換される。EMG信号より特徴量を抽出するため、EMG信号は高速フーリエ変換が行われNN入力値へと変換される。NNの構成は、出力細胞が手首のパターンを識別するように構成されており、最大発火パターンを識別結果とする。また本章では、オンラインチューニングシステム有効性確認実験を実施し、その有効性を定量的に示す。まず、被験者のEMG信号をDSPユニットに入力し、DSPユニット上で初期学習を実行する。初期学習が終了後、識別に用いるEMG信号をDSPユニットに入力し、初期学習終了時の識別率の算出を行う。次に、被験者は、新たにオンラインチューニングシステムに用いるEMG信号をDSPユニットに入力し、DSPユニット上でオンラインチューニングシステムを実行する。その後、さらにオンラインチューニング後の識別率算出に用いるEMG信号を入力し、識別率の算出を行う。最後に、初期学習後およびオンラインチューニング後の識別率を比較し、識別率の向上を確認する。結論として、オンラインチューニングシステムは、手首動作識別システムで有効であると言えた。

第4章では、オンラインチューニングシステムの有効性の確認に用いる起床検知システムについて示す。起床検知システムの検知方法は、まず、対象者を実験筐体に取り付けられているWEBカメラを使用して、被験者の撮影を行う。その後、撮像した画像からは人物部分の切り出しが行われる。切り出された画像は、特徴抽出が行われNN入力値へと変換される。NNは対象者の状態を就床、起床途中、起床、落下途中、落下の5状態にクラス分けをするように構成されており、最大発火パターンを検知結果とする。また、本章では、まず、起床検知システムの検知結果が個人差の影響を受けることを次の実験により示す。実験は、被験者それぞれのデータを学習し、未学習の被験者の検知率と比較することにより個人差の

影響を検証する。実験手順は、まず、それぞれの被験者の学習および検知用データを撮像する。次にそれぞれの学習データを用いて初期学習を行う。その後、学習済みおよび未学習の被験者の検知データを使用し検知率の算出を行う。実験の結果より、未学習の被験者の検知率は、学習済み被験者の検知率に比べて低いことが確認され、起床識別システムは個人差の影響を受けることを示す。次に、先の実験で学習した NN に対して、学習と同一の被験者のデータを使用してオンラインチューニングシステムを実行し、検知率を算出する。最後に、初期学習後とオンラインチューニング後の検知結果を比較する。実験の結果より、オンラインチューニング後の検知率が初期学習の検知率より向上したことを示す。

第 5 章では、これら 2 つの特徴が 1 次元と 2 次元と異なるデータを識別対象とするオンラインチューニング有効性確認実験は、共にオンラインチューニングを行うことにより、識別率が向上したことが分かる。また、起床検知システムにおいてはオンラインチューニングの回数を重ねる毎に識別率は向上することが判明した。これらの検証より、オンラインチューニングを用いることにより、NN 識別アプリケーションの識別率の向上および維持、個人ユーザへのカスタマイズが可能であることが判明した。EMG や人の挙動以外に特徴の異なるデータを識別対象とした場合もオンラインチューニングを行うことにより、学習対象者に合わせた NN 識別アプリケーションのカスタマイズを行い、識別率の維持向上が可能ではないかと考えられる。本実験では、学習データを選択することなくオンラインチューニングを行った。そこで、オンラインチューニングに用いるデータを選択するシステムを構築することにより、オンラインチューニング実行時にさらなる識別率の向上が期待できる。例えば、ユーザ個人を限定している場合、識別に失敗したデータをストアしておき、ある程度ストアされた時点でオンラインチューニングを開始するシステムである。

第 6 章では、これまでの NN を用いた入力データの想定外の変動に関する NN 識別アプリケーションの問題点を示した。また、その問題点を解決するため、著者はオンラインチューニングシステムを提案した。さらに、オンラインチューニングシステムの有効性確認に用いる EMG を用いた手首動作識別システムおよび起床検知システムについて示した。その二つの NN アプリケーションに対して、オンラインチューニングシステムの有効性を定量的に確

認した。本研究により，オンラインチューニングシステムは，NN アプリケーションで有効であると想定され，今後，個人差ならびに経年変化を伴う種々の産業アプリケーションの性能維持などに，特にその威力を発揮するものと思われる。

以上により，本論文で提案する NN によるオンラインチューニングシステムの有効性を実験的に示す。また，本手法を用いた，個人に特化したシステムの構築についても，実験科学の域で言及する。

第 2 章

オンラインチューニングシステムの 提案

2.1 背景

現代のノイマン型計算機上での知的情報処理は、存在するデータが完全に与えられた状態で、処理手順をルール化しプログラムとして記述する方式で実現しようとしてきた。例えば、エキスパートシステムがその一例である。しかし、本来の情報処理技術は人間の様に高度で柔軟性に富む情報処理技術の実現を目標としている [23, 24]。そこで、人間の脳を模倣した単層ニューラルネットワークの研究により、この目標への到達が期待された。しかし、Minsky や Papert の研究により単層 NN ではいくつかの簡単な問題を解くことが出来ないことが証明された [25]。この研究を発端として、多層 NN やバックプロパゲーションアルゴリズム [14] の研究に繋がり、これらの新たな研究により不完全なデータに対しても識別ルールを構築する手法として用いられることとなった。

一般に、NN の特徴の一つとして汎化能力が挙げられる。ここで、汎化能力とは、未学習のデータに対しても適切にパターン識別が可能な能力である。現在、NN は、未知の学習データに対し汎化能力を有するがうえに、パターン識別の分野での利用がなされている。例えば、いりこ選別および紙幣識別、起床検知システム、EMG を用いた手首動作識別システムなどである。いりこ選別は、いりこに加工を行う原材料となる魚の魚種を選別するシステムである。紙幣識別システムは、紙幣金種を識別するシステムである。これら NN アプリケーションは、識別対象となるデータをサンプリングし、このデータを学習データとして

2.1 背景

学習を行う。ただし、未知の学習データに対して汎化能力を得るためには、存在する未知のデータすべてを包括する学習データを作成する必要がある。ここで、紙幣識別では紙幣の劣化および汚れなどが発生し、多様な紙幣が存在する。また、いりこ選別では同一魚種内においても大きさや斑点の数、模様といった個体差が存在する。さらに、起床検知システムでは、ベッドでの行動は個人によって異なる [26, 27, 28, 29, 30, 31]。手首動作識別システムでは、乾式表面電極によって計測できる EMG は個人差が存在する。このため、学習に用いられるデータは存在するすべての学習データを用いることは不可能である。

NN は、提示されたデータを学習することにより、パターンに含まれる特徴を検出可能となるように、NN の結合の強さ、つまり、細胞間の重みを調整し保存する。この細胞間の重みを保存したものを NN ウェイトと呼ぶ。また、未学習のデータでは、重要となる特徴量を検出し、パターンを分類することができ、ある程度の汎化能力を示している。この NN の汎化能力により、紙幣識別システムでは、未学習の状態の紙幣に対する識別が可能である。しかし、これまで提示されたデータの入力範囲を超えるものが入力された場合に、NN が学習により記憶した特徴量と類似する特徴量が検出できず識別が不可能となる。具体例としては、手首動作識別システムや起床検知システムにおいて、識別データが個人差や環境の影響によりデータが大きく変化する場合、NN を用いたアプリケーションの識別能力は不十分となる [14, 15]。

この問題を解決するため、NN の学習アルゴリズムの研究がなされている [32, 33] が高速な学習は可能なものの、汎化能力については未だ不十分である。

この問題の解決方法の一つとして、すべての環境や個人差を網羅するデータを学習に用いることが考えられる。ここで、すべての環境や個人差を網羅するデータは、学習後に入力される未知のデータの変動範囲より広い必要がある。しかし、想定されるデータを事前に完備することは、識別対象の体格やさまざまな環境といった組み合わせのバリエーションがあり、相当数のデータのサンプリングを必要とするため難しい。さらに、想定されるデータを完備できたとしても、学習を行う計算機のメモリの制限により学習が困難である。また、これらに加え、膨大な演算と長い演算時間が必要とされることが予測される。

2.2 オンラインチューニングシステム

この問題の解決方法として、オンラインチューニングシステムを提案する。オンラインチューニングシステムの目的は、大きな変動の無い、つまり、限定された識別データで学習を行い、このデータに対して識別能力を有する NN を、個人差および経時変化などの要因により動的に変化した識別データに適応させ識別率の向上、または維持することである。

図 2.1 にオンラインチューニングのイメージを示す。目標とする識別能力を有するように多数学習対象者のデータを使用して学習する。さらに、 ΔZ として使用者を学習対象として学習データを用いて継続学習を行う。これにより、初期学習時終了時点からして、使用者本人に特化した識別が可能になると考える。また、使用者本人に特化した識別率の維持および向上が可能であると考えられる。

提案システムのフローチャートを図 2.2 に示す。オンラインチューニングシステムのアルゴリズムは、まず、初期学習として限定されたデータで識別能力を有するように学習を行う。ここで、目標とする識別結果を得られる学習データを選択し学習を行う。オンラインチューニングシステムにより、新たに变化したデータサンプリングおよび学習データとして追加し、NN の継続的な学習を行う。目標とする十分な識別率が得られるまで、この継続学習および学習データの順次追加を繰り返す。このアルゴリズムの実現により、識別システムは、識別データの変動に対応することが可能で、個人差や環境の変化により大きく変動したデータに対しての識別率の向上、あるいは維持が可能であると予測される。

図 2.3 に EMG を用いた手首動作識別システムにおける学習サンプリング数の追加に伴う識別率の変化を示す。図 2.3 の横軸は、学習に用いたデータ数である。また、縦軸は、学習後の未知の学習データに対する識別率を表す。学習サンプリング数が増加するにつれて、識別率が増加することが分かる。NN のこの特性を利用することにより、オンラインチューニングによって学習データの追加および継続学習を行い、識別率の向上または維持が可能であると予想される。

オンラインチューニングのメリットは、固定的な識別システムに比べ容易に識別システム

2.2 オンラインチューニングシステム

を使用者本人に特化した識別システムにカスタマイズすることが可能であると考えられる。例えば起床検知では、1台の固定カメラからの動画により人体部位の動きから行動の特徴を検出し、行動検知のルールを設定し行動検知する研究も進められている [34]。しかしながら、一般に検知対象者の行動には個人差が存在することが医療従事者により指摘されており、行動検知を行うシステムには個人差に対応する機能が必要である。しかし、このシステムでは行動検知のルールを個人毎に設定する必要があるため、個人差に容易に対応することができないと考えられる。そこで、この問題の解決方法として、使用者の特有の挙動を撮像し、オンラインチューニングを行うことによって簡単に使用者に合わせて検知システムをカスタマイズ可能であると考えられる。さらに、従来の NN 識別アプリケーションでは、学習データが増える毎に演算量が増加したが、少ないデータ数でオンラインチューニングをすることが可能であれば、初期学習時と比較し少ない演算量で NN 識別アプリケーションの性能維持および向上、使用者へのカスタマイズが可能であると考えられる。

本論文では、OS に WindowsXP を搭載した市販されている一般的な PC を用いオンラインチューニングを導入した NN 識別アプリケーションを構築すると共に、DSP を演算部に用いた NN 識別アプリケーションを構築し、2つのプラットフォームにてオンラインチューニングの有効性を示す。

2.2 オンラインチューニングシステム

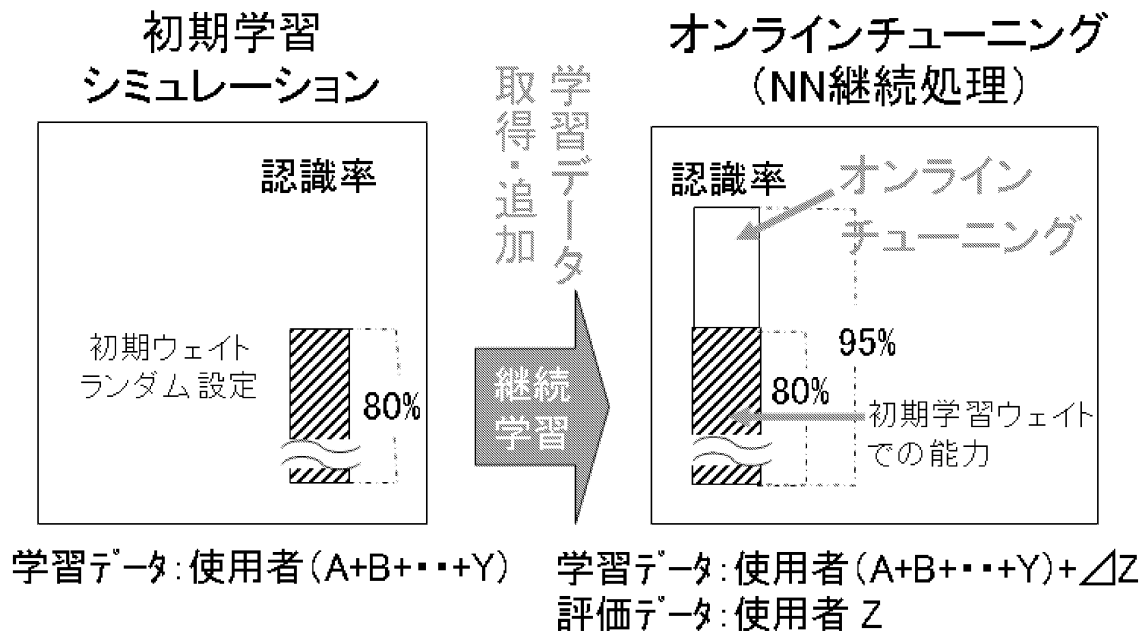


図 2.1 オンラインチューニングイメージ

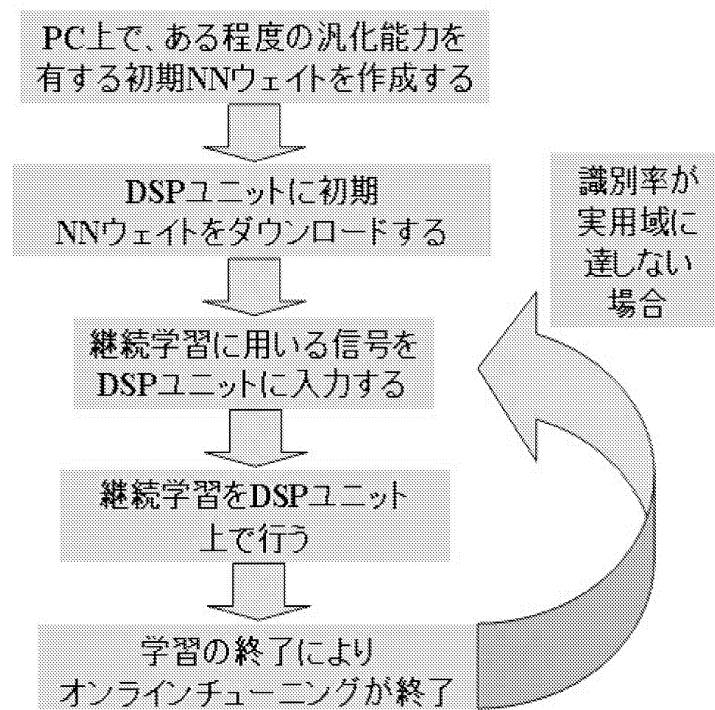


図 2.2 オンラインチューニングのフローチャート

2.2 オンラインチューニングシステム




図 2.3 学習データの追加に伴う識別率の変化

2.2 オンラインチューニングシステム

2.2.1 オンラインチューニングの適用

本研究では、2つの異なるデータを使用してオンラインチューニングシステムの有効性の確認を行う。1つは1次元のデータであり、さらにバイオメトリックスであるEMGが識別対象の手首動作識別システムである。もう1つは、ベッドでの起床という人の挙動を識別対象とする起床検知システムである。このシステムは画像を用いて検知を行う。つまり、2次元のデータを識別対象としている。

手首動作識別システムの識別対象であるEMGは、個人差があることが知られている。図2.4に乾式表面電極を用いて、6人の被験者が同じ手首動作を行った際に計測したEMGを示す。ここで、サンプリングレートは20KHzである。図2.4は時系列のデータであり、縦軸は電圧を示す。解析の結果、最大標準偏差は7.81であった。ここで、理想としては、波のパターンが一致することである。しかし、この図では、個人により大きく計測されるEMGが異なることが示されている。つまり、個人によりEMGが大きくばらつくことが分かる。




図 2.4 6人の被験者のEMG

2.2 オンラインチューニングシステム

起床検知システムのベッドでの行動は、個人差があることが医療関係者より指摘されている。そこで、起床検知システムにおいては、個人差が検知に影響を及ぼすかオンラインチューニングの有効性の確認前に検証を行う。

オンラインチューニングシステムは、個人差の存在する識別対象を扱う NN 識別アプリケーションの識別率の向上および維持、また、個人へのカスタマイズを目的としたシステムであるために、個人差の存在するデータを識別対象とするこれら 2 つの NN 識別アプリケーションにおいて有効性を確認することは妥当であると考えられる。以降、手首動作識別システムおよび起床検知システムのシステム構成を示すと共に、オンラインチューニングの有効性確認を行う。

第 3 章

オンラインチューニングシステムの適用

3.1 筋活動電位を用いた手首動作識別システムへの適応

3.1.1 システム概要

本章では、オンラインチューニングの有効性確認に用いる手首動作識別システムの構成および識別対象について示す。

本システムは、入力部、信号処理部、特徴抽出部、学習および識別部より構成され（図 3.1）、[EMG データ採取] [信号増幅] [特徴抽出] [初期学習] [識別] [オンラインチューニング] という流れで処理される。

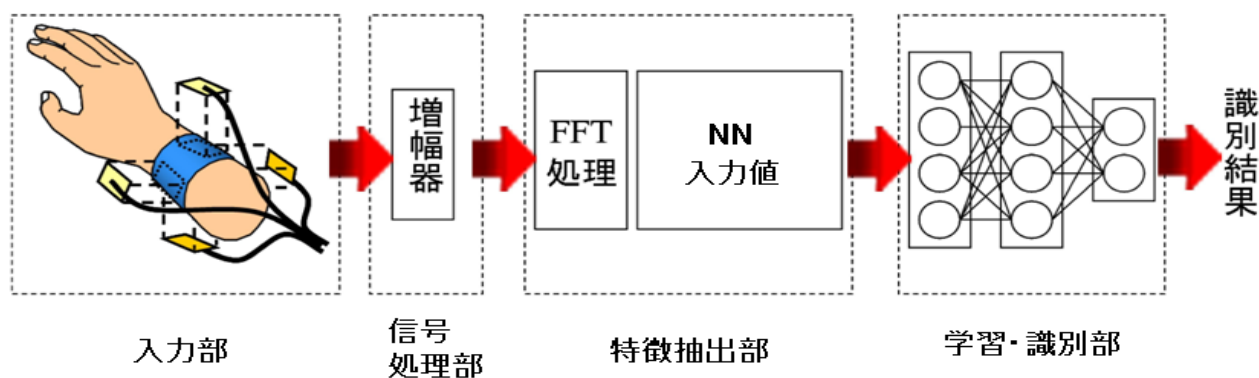


図 3.1 システム構成

まず入力部では、電極から EMG 信号（時系列データ）を採取する。次に、信号処理部で

3.1 筋活動電位を用いた手首動作識別システムへの適応

採取した EMG 信号を増幅器を用いて増幅する。これは、採取した EMG 信号が微弱な電気信号であり、入力に耐えうる信号ではないためである。増幅された EMG 信号は DSP ユニット [35, 36, 37, 38, 39, 40, 41] のアナログ入力ポートの A/D 変換器より DSP ユニットに取り込まれる。特徴抽出部では、前処理として EMG データに高速フーリエ変換処理 (FFT : Farst Fourier Transform) を行い NN 入力値 (パワースペクトル) へと変換する。学習および識別部では、個々のパターン毎のデータを NN で学習および識別を行う。識別に用いる NN は、竹田らが紙幣識別分野での利用を目的として開発したものを応用する [42, 43]。また、DSP ユニットでオンラインチューニングシステムの機能として、オンラインによりデータを取得し学習済みの NN ウェイトに対して追加継続学習を実現する。さらに、学習時間の短縮を図り、A/D 変換器を有しデータを直接演算装置に入力可能な DSP ユニットを手首動作識別システムには用いている。

3.1.2 EMG

EMG の発生の仕組みを図 3.2 に示す。また、図 3.3 に筋活動電位発生時の電位波形のイメージを示す。神経や筋肉の細胞は主に 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。そのため膜内部の静止電位は $-80mV$ 程度に保たれている (図 3.3 参照)。脳からの刺激や反射により脊髄内の運動神経細胞 (図 3.2 中 ○) が興奮すると、その信号は運動神経軸索 (図 3.2 中 ○) を通じ、神経と筋肉の接点である神経筋接合部 (図 3.2 中 ○) に達する。神経筋接合部では受容体にアセチルコリンが結合すると受容体は活性化し、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 (図 3.3 脱分極)。このときの発生した電位差 (約 $100mV$) を EMG と呼ぶ。神経一筋興奮の最小単位電位を測定するには、針電極が必要であるが、本システムでは装着の容易さを考慮し、皮膚表面で固定した乾式表面電極で EMG の測定を行う。

表面で測定される電位差を表面電位と呼ぶ。表面電位は、発生源より距離がある体表面で測定しているために、無数の運動単位の筋活動電位が時空間的に加算された筋全体の総合的

3.1 筋活動電位を用いた手首動作識別システムへの適応




図 3.2 EMG 発生の順序機構




図 3.3 細胞の興奮と筋活動電位

な活動状況を測定している。そのため、測定可能な電位は連続的に発生する雑音の様な電位として計測される。表面電位は、様々な電気・周波数・位相の交流信号が加算されており、平均電位は数 μ V～数 mV、周波数成分は数 Hz～数 100KHz である。

また、表面で計測される電位は、脂肪の厚さにより変化が起こることが分かっている。これらの理由により、EMG は個人差が大きいことが一般的に知られている [44, 45, 46]. EMG の個人差が大きいことは前章にて示した。

3.1 筋活動電位を用いた手首動作識別システムへの適応

DSP ユニット

手首動作識別システムにおいて、オンラインチューニングを実現するための DSP ユニットについて述べる。手首動作識別システムは、オンラインチューニングには短時間での学習終了およびリアルタイムでの識別結果の表示の実現が求められる。そこで、NN は行列の乗算により表現可能であるため、乗算器を有する DSP ユニットを用いて手首動作識別システムを構築している。このユニットを使用することにより、少ない計算時間での学習の収束および識別結果を得ることが可能になると考える。DSP ユニットは、Texas Instruments 社製の DSP を演算部に採用する。DSP ユニットは、スタンドアローンで手首動作識別システムの実行を可能にする。本ユニットは、採取した EMG データより、NN に入力するための前処理を行い、学習および識別に用いるための NN に入力する値である NN 入力値 (識別対象から抽出した特徴量) の作成を、DSP ユニット上で全て行うことが可能である。つまり、DSP ユニット単体で入力データを取得し、学習および識別を行うことが可能である。

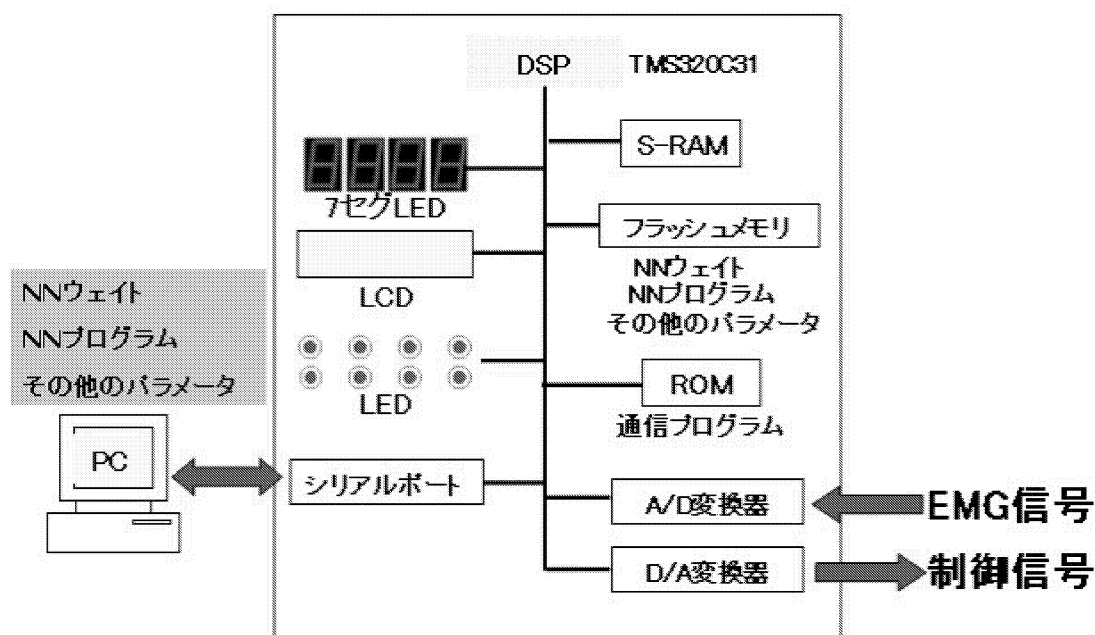


図 3.4 DSP ユニットブロック図

また、DSP は消費電力、発熱量が少なくモバイルにも適する。採用する DSP の特徴と

3.1 筋活動電位を用いた手首動作識別システムへの適応

しては、内部データは 32 ビットの浮動小数点型で処理を行うことが可能である [47]。また、この DSP はアセンブラ言語と言語の C コンパイラが提供されているため、ソフトウェアの開発を従来の CPU 同様に行うことが可能である [48]。DSP ユニットにおいて使用する DSP のスペックを以下に示す [49]。

- 60ns(1 マシン・サイクル) の命令実行時間
- 33.3MFLOPS
- 16.7MIPS
- 40/32 ビットの浮動小数点/整数の乗算器と ALU
- 単一サイクルで ALU と乗算器で並列処理


性能は、50/60ns という命令実行サイクルと共に、命令用キャッシュ・メモリの内蔵、パイプライン処理と命令の同時実行という 2 種類の並列処理によって達成される。さらに、メモリ空間は 16M ワードである。外部バスも 2 系統独立で設けられており、外部メモリなどに対しても並列的なアクセスが可能である。システムを低コストで実現するため、周辺デバイスの制御のための DMA コントローラ、シリアルポート、タイマなどのペリフェラルが内蔵されている。浮動小数点の基本的なデータ形式は、指数部 87 ビット、仮数部 24 ビットである。この精度は、IEEE の単精度データの規格とデノーマル (非正規化) 表現を除くと同じである。また、DSP の内部の ALU や演算用のレジスタは、仮数部が 32 ビットに拡張され、乗算の切り捨て誤差の発生を減らすように工夫がなされている。さらに、DSP は内部データをすべて 4 ビット長で表現し、浮動小数点型の変数を扱うことが可能である [50][51]。これらの特徴を利用することにより、行列の前向き計算で表すことが可能である NN の処理を高速に行うことが可能である。

オンラインチューニングを実現するための DSP ハードウェアのブロック図を図 3.4 に示す。DSP ユニットの特徴としては、実装するシリアルポートを使用することにより、PC との通信が可能で NN プログラムおよび NN ウェイトの変更が容易に可能となる。また、フラッシュメモリおよび S-RAM また EPROM をボード上に配置してある。DSP ユニット上


3.1 筋活動電位を用いた手首動作識別システムへの適応

部には，内部の処理を確認するための LED，7セグメント LED，LCD を装備する．図 3.5 に DSP の (a) 外観，(b) 内部，(c) DSP 背面をそれぞれ示す．


3.1 筋活動電位を用いた手首動作識別システムへの適応



(a) DSP ユニット外観



(b) DSP ユニット内部



(c) DSP ユニット背面

図 3.5 DSP ユニット
- 26 -

3.1 筋活動電位を用いた手首動作識別システムへの適応

学習および識別さらに PC との通信の切り替えは、前面に配置されたモード選択スイッチで行う。選択したモードに従い図 3.6 に示すプロセスが実行される。通信モードを選択した際の PC との通信機能としては、コマンドレスポンス方式で通信を行う。PC 側では、新たに製作した専用のソフトを実行して通信を行う。通信モードの主な機能は、フラッシュメモリの初期化と NN ウェイトまたパラメータのアップロードおよびダウンロードを行うことである。フラッシュメモリに保存された識別プログラムは S-RAM に展開し実行される。学習が収束した NN ウェイトはフラッシュメモリに保存される。識別モードを選択した際の識別結果は、LCD(図 3.7 参照) に文字情報として、また 7 セグメント LED(図 3.8 参照) にパターン数として表示する。図 3.8 中 7 セグメント LED の示す 4 桁の数字において、下 2 桁が識別結果を表す。

さらに、本ユニットは分解能 8bit の 4ch アナログ入力ポート (図 3.5(c) 中入力ポート) を実装し、データの入力を行う。また、識別結果に応じて制御信号としてのアナログ出力を行うために、分解能 8bit の 8ch アナログ出力ポート (図 3.5(c) 中出力ポート) を装備している。

3.1 筋活動電位を用いた手首動作識別システムへの適応

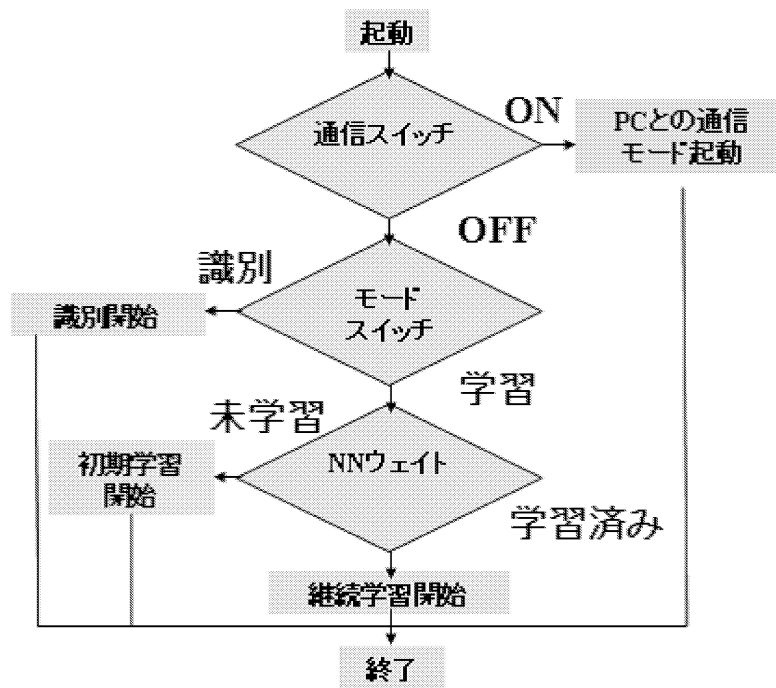


図 3.6 ソフトウェアフローチャート




図 3.7 LCD

3.1 筋活動電位を用いた手首動作識別システムへの適応



図 3.8 7セグ LED

3.1 筋活動電位を用いた手首動作識別システムへの適応

3.1.3 システム構成

入力部

次に、個々の処理部についての説明を行う。本節では、入力部の構成を示す。本研究では使用者の抵抗が少なく、脱着が容易に行え、特定の筋ではなく複数の筋から EMG 信号を計測できる表面電極を採用している。さらに、手首動作識別システムはヒューマンインタフェースとしての利用を目的としているため、専門的な知識が無く、脱着の容易な乾式表面電極を用いている。センサの配置は、手首の上下左右に1つずつ配置する。本システムで使用するセンサを図 3.9 に示す。しかし、表面電極は EMG が表面に伝達するまでの、筋肉や脂肪などの伝達特性が個人により異なり、測定値は個人差の影響を受ける。




図 3.9 センサ

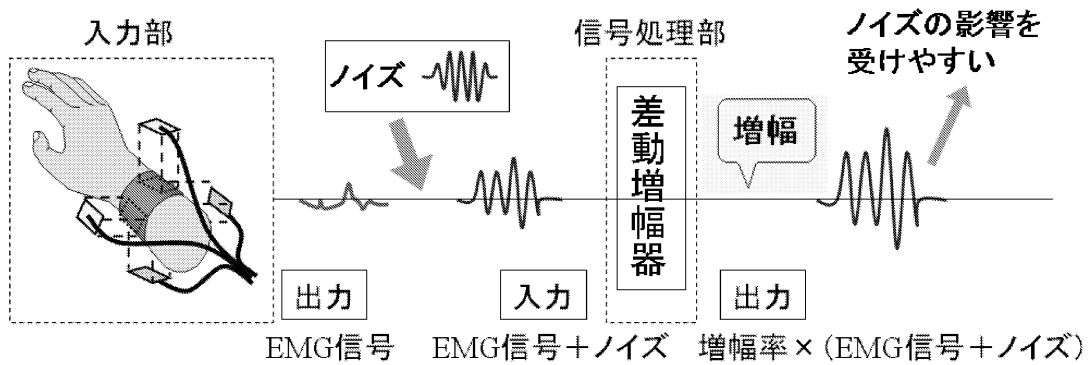
3.1 筋活動電位を用いた手首動作識別システムへの適応

信号処理部

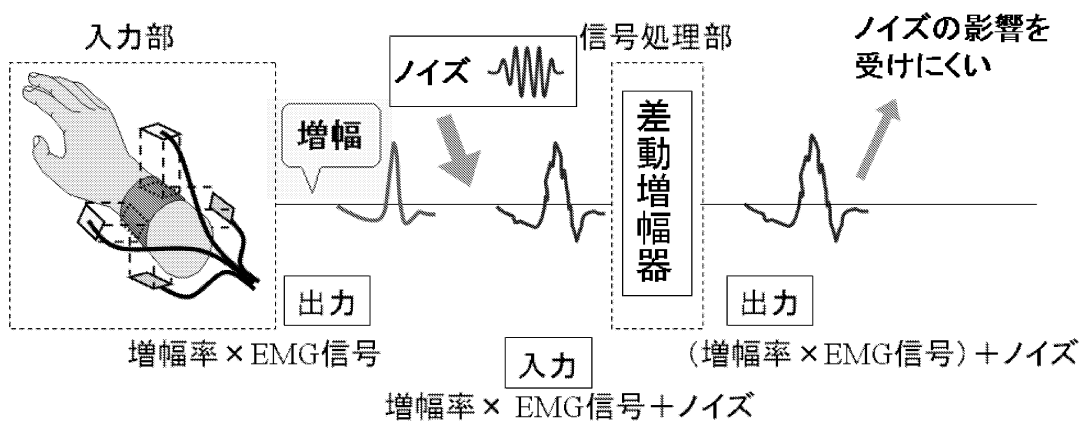
本節では信号処理部について示す。電極により測定される信号は、低周波成分が大きく影響するため測定許容量を超える。そこで、ハイパスフィルタを使用し、低周波部分の信号を押しやることにより、この問題の解決を図る。

次に、EMG の入力部から信号処理部までのノイズの影響について図 3.10 に示す。図 3.10(a) で示すように、ノイズはセンサから DSP ユニットの A/D 変換器までの間で混入する。その結果、センサでは「EMG 信号」のみであったが信号処理部へ到達時にはノイズが混入してしまい「EMG 信号+ノイズ」となる。そのデータを信号処理部で増幅するためノイズも同等に増加してしまい、データがノイズの影響を大きく受けてしまう。そこで図 3.10(b) で示すように信号を採取した直後にオペアンプを実装し増幅を行い、入力に適した信号を得る。EMG 信号のみの段階で増幅を行うことにより、データ転送時に混入するノイズの影響を最小限に抑えることができる [52]。

3.1 筋活動電位を用いた手首動作識別システムへの適応



(a) オペアンプ無しの場合



(b) オペアンプ有りの場合

図 3.10 オペアンプの実装

3.1 筋活動電位を用いた手首動作識別システムへの適応

特徴抽出部

FFT

特徴抽出部では、増幅された EMG 信号を A/D 変換し DSP ユニットに取り込み、DSP ユニットに格納された前処理プログラムにより FFT 処理を施す。その後、算出したパワースペクトルから NN への入力値を算出する。FFT とは、離散フーリエ変換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、ある任意の時間信号を周波数領域で表したものである。フーリエ級数展開を式 3.1 で示す。

$$x(t) = a_0 + \sum_{n=1}^{\infty} \{a_n \cos(n\omega_0 t) + b_n \sin(n\omega_0 t)\} \quad (3.1)$$

$$\text{ただし, } \omega_0 = 2\frac{\pi}{T_0}$$

a_n , b_n はフーリエ係数と呼び、 a_0 は直流成分を示す。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。式 3.2 に直流成分、式 3.3、式 3.4 にフーリエ係数を示す。

$$a_0 = \frac{1}{T_0 \int_{-\frac{T_0}{2}}^{\frac{T_0}{2}} f(t) dt} \quad (3.2)$$

$$a_n = \frac{2}{T_0 \int_{-\frac{T_0}{2}}^{\frac{T_0}{2}} f(t) \cos(n\omega_0 t) dt} \quad (3.3)$$

$$b_n = \frac{2}{T_0 \int_{-\frac{T_0}{2}}^{\frac{T_0}{2}} f(t) \sin(n\omega_0 t) dt} \quad (3.4)$$


FFT 処理を施し、算出されたフーリエ係数 a_n , b_n より式 3.5 に示すパワースペクトルを求めらる。

$$X_n^2 = a_n^2 + b_n^2 \quad (3.5)$$

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。手首挙動を計測した際の時系列波形とパワースペクトル波形を図 3.11(a), 図 3.11(b) に示す。時系列表示のグラフは 1 目盛りが x 軸方向で 0.2 秒, y 軸方向では 0.05V となってい

3.1 筋活動電位を用いた手首動作識別システムへの適応

る. パワースペクトル波形では x 軸方向が 250Hz, y 軸方向はパワースペクトルで 25 (約 0.061V) である. NN への入力値 (NN 入力値) となる EMG 信号は安定状態の EMG 信号を使用するため, 手首挙動開始後 1.0 秒~1.1 秒間に発生する EMG 信号を使用する. パワースペクトルは式 3.5 に示すように整数となる. チャンネル 2, 3 のパワースペクトルについてはチャンネル 1, 4 と波形が重複するため, 出力される波形に -1 を掛けグラフを反転させて表示している.



(a) 時系列波形

(b) パワースペクトル波形

図 3.11 手首挙動 (掌屈の波形)

NN 入力値の算出

手首挙動より得られたパワースペクトルから NN への入力値を算出する手法について記述する. 本システムでは, 4 チャンネルの入力に合わせて入力層細胞数を 48 と設定し, 各チャンネルに 12 個ずつの NN 入力値を入力する. 図 3.12 に NN 入力値の NN への入力モデルを示す.

FFT は, 1024 点のデータで算出される (アナログ入力ポートサンプリングレートは 1KHz). 次に, FFT で周波数領域に変換された値より, 表 3.1 に示す領域内の和を求め, 領域内の平均を求める. ここで, 周波数ポイント領域は, 重なりを持たせている.

3.1 筋活動電位を用いた手首動作識別システムへの適応

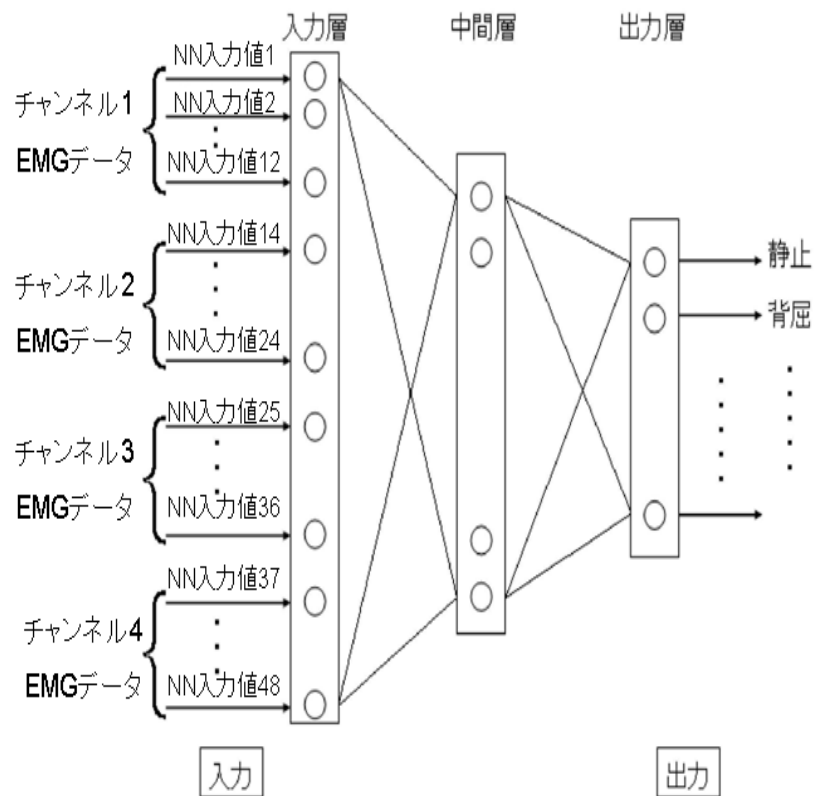


図 3.12 NN への入力データモデル

同様の処理を各センサの EMG 信号毎に行う。その後、NN 入力値の最大が 2.0 となるように正規化を行う。これは NN の学習時に NN の出力を飽和させないためである。正規化を行わない場合、NN の入力細胞から中間細胞への出力は飽和し、学習を正しく行うことができない。

3.1 筋活動電位を用いた手首動作識別システムへの適応

表 3.1 NN 入力値算出表

1-70 ポイント	未使用
71-120 ポイント	NN 入力値 1
106-155 ポイント	NN 入力値 2
141-190 ポイント	NN 入力値 3
176-225 ポイント	NN 入力値 4
211-260 ポイント	NN 入力値 5
246-295 ポイント	NN 入力値 6
281-330 ポイント	NN 入力値 7
316-365 ポイント	NN 入力値 8
351-400 ポイント	NN 入力値 9
386-435 ポイント	NN 入力値 10
421-470 ポイント	NN 入力値 11
456-505 ポイント	NN 入力値 12

3.1 筋活動電位を用いた手首動作識別システムへの適応

3.1.4 学習および識別部

データファイルの作成

本システムで使用する NN は、紙幣識別用に開発された学習および識別システムである。そのため、NN 入力値はパターン毎にバイナリファイルとして保存される。ここで、このバイナリファイルは、金種および国情報などを記述したヘッダ情報、紙幣画像データの 3 種類の情報で構成される。しかしながら、本システムでは、画像データが不要であることから、ダミーデータを使用して領域の確保のみを行う。1 つのバイナリファイルの構成は、ヘッダ情報が 64byte、ダミーデータが 400byte となっている。NN 入力値はプログラム中 float 型 (4byte) で宣言されているため 50 個 × 4byte で 200byte となっている。表 3.2 に NN データのフォーマットを示す。さらに、表 3.3 にヘッダ情報の詳細なフォーマットを示す。

表 3.2 バイナリファイルのフォーマット

ヘッダ情報	64byte
ダミーデータ	400byte
NN 入力値データ	200byte

表 3.3 のフォーマット中、本システムで必要とするのは、以下の項目である。

- 予約領域

学習システムを拡張するために用意する

- 画像の X サイズ, Y サイズ (画素数)

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

- NN 入力値のオフセット

3.1 筋活動電位を用いた手首動作識別システムへの適応

表 3.3 ヘッド情報のフォーマット

データ 1 枚分の総サイズ	4byte	664	予約領域 1	4byte	0
画像の X サイズ (画素数)	2byte	20	予約領域 2	2byte	0
画像の Y サイズ (画素数)	2byte	20	予約領域 3	6byte	0
センサ有効域 Ch 番号 (H)	2byte	201	予約領域 4	4byte	0
センサ有効域 Ch 番号 (L)	2byte	4	予約領域 5	5byte	0
センサ分解能 (X 方向)	1byte	10	予約領域 6	4byte	0
センサ分解能 (Y 方向)	1byte	40	国情報	1byte	1
紙幣の中心画素の X 座標	2byte	0	金種	1byte	1
紙幣の中心画素の Y 座標	2byte	0	通し番号	2byte	1
画像のデータのオフセット	4byte	64	方向	1byte	1
NN 入力値の種類数	1byte	1	種別	1byte	0
NN 入力値のオフセット	4byte	464	パターン番号	1byte	1
1 種類目の NN 入力値のマスク ID	1byte	1	センサ番号	1byte	0
1 種類目の NN 入力値の個数	1byte	50	機種	1byte	1
			号機	1byte	1

ヘッダの先頭を 0 バイト目と設定する場合、NN 入力値の先頭からのバイト数

- 1 種類目の NN 入力値の個数

NN の入力細胞数

ここで作成した手首挙動パターン毎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 つのファイルで管理する。データファイルの構成を図 3.13 に示す。

3.1 筋活動電位を用いた手首動作識別システムへの適応

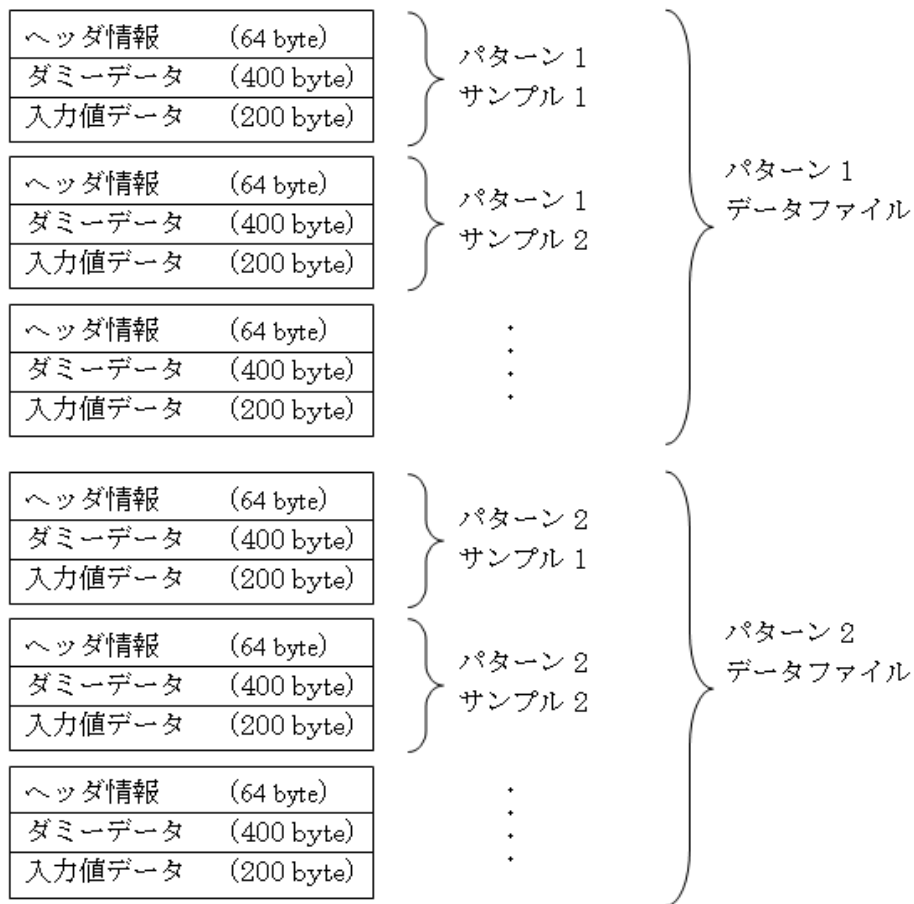


図 3.13 データファイルの構成

学習用データファイルの抽出

設定されている 1 パターンの学習サンプル数の数だけデータファイル（図 3.13 参照）の先頭から抽出し、学習用データファイルを作成する。

NN 入力値の並び替え

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データファイルの NN 入力値を並び替える。これを学習ファイルとする。図 3.14 に 2 パターン分離で、各パターンのサンプル数が n 個の場合の NN 入力値の並び替えについて示す。

3.1 筋活動電位を用いた手首動作識別システムへの適応

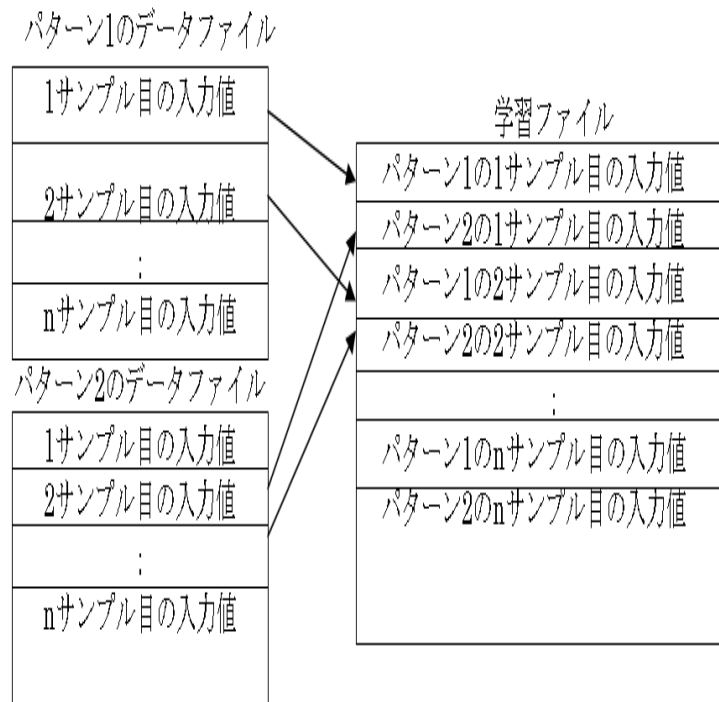


図 3.14 NN 入力値の並び替え

教師ファイルの作成

NN のパラメータ設定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 を示す行列を作成する．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 3.15 に認識パターンを 2 としたときの教師ファイルの具体例を示す．




図 3.15 教師ファイル作成イメージ

3.1 筋活動電位を用いた手首動作識別システムへの適応

NN

手首動作識別システムの NN について説明を行う。NN は、3 層の階層型 NN である。

中間層および出力層の各ユニットの入出力関数としては、式 3.6 に示すシグモイド関数を使用する。式 3.6 において、 x は各細胞への入力値である。また、 $f(x)$ はそのユニットへの出力値である。 T はネットワークの温度と呼ばれる正の数で、図 3.16($\theta=0$) に示すように T が大きくなるほど出力値の勾配はなだらかになる。 θ は、細胞単位の閾値を示す。また、 T は後述する総合誤差に比例して、1.3 から 0.7 まで変化させる。

$$F(x) = \frac{1}{1 + \exp\left(\frac{-x+\theta}{T}\right)} \quad (3.6)$$




図 3.16 シグモイド関数

3.1.5 NN の重み調整

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（教師ファイルの期待値に近い値）をするように、NN の重みを調整する作業である [53, 54].

手首動作識別システムでは、式 3.7 の改良型 BP 法を NN の学習アルゴリズムとして採用する。この式は、 t 回目の学習における $k-1$ 層の第 i 細胞から k 層の第 j 細胞へのウェイト

3.1 筋活動電位を用いた手首動作識別システムへの適応

W_{ij} の修正量 $\Delta W_{ij}^{k-1,k}(t)$ を求める式である.

$$\Delta W_{jk}^{k-1,k}(t) = -\eta \delta_k^k O_j^{k-1} + \alpha \Delta W_{jk}^{k-1,k}(t-1) + \beta \Delta W_{jk}^{k-1,k}(t-2) \quad (3.7)$$

ここで, η は学習定数, α は慣性定数, β は振動定数, O は NN 出力値を示す.

また, δ_k^k は k 層の第 j 細胞の一般化誤差で, k 層が出力層の場合と中間層の場合によって算出方法が異なる. 以下に一般化誤差の算出方法を示す. k 層が出力層の場合, 式 3.8 で表される.

$$\delta_j^k O_j = (T_j - O_j^k) f'(I_j^k) \quad (3.8)$$

また, k 層が中間層の場合, 式 3.9 で表される.

$$\delta_j^k O_j = \left(\sum_m W_{jm}^{k,k-1} \delta_m^{k-1} \right) f'(I_j^k) \quad (3.9)$$

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にも変化が起こり, その後, 全体的な最小値へ向かうことが期待できる. また, 振動項は極小値から抜け出す働きをする. これは Asakawa らがバネ-ダッシュポッド系として振動項を導出し, 図 3.17 に示す慣性項・振動項の境界条件を設定した [55].




図 3.17 慣性定数と振動定数の範囲

従って, 慣性項および振動項の値は, 線形計画法を用いて選択すればよい. 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

3.1 筋活動電位を用いた手首動作識別システムへの適応

性項と振動項の最適な組み合わせ ($\alpha = 0.95$, $\beta = -0.1$) を算出したことを報告している [42]. 本システムでは, 任意に選択した 10 種類の組み合わせを試した結果, 最も学習の収束が安定していた前述の組み合わせを採用している. この学習アルゴリズム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 のパラメータ設定で指定した最終誤差判定値, 学習回数のうち一方の条件を満たした段階で終了する.

ある入力パターンを与えたときの出力層の第 j 細胞の出力を O_j とする. このときの出力層の第 j 細胞の教師値を T_j とすると, 第 j 細胞の誤差 E_j は, 式 3.10 で表される.

$$E_j = \frac{1}{2} (T_j - O_j)^2 \quad (3.10)$$

従って, 1 つの学習パターン p における出力層の誤差 E_p は式 3.11 ので求められる.

$$E_p = \frac{1}{2} \sum_j (T_j - O_j)^2 \quad (3.11)$$

ここで, 全学習パターンの誤差の総和を E とし, これを総合判定誤差と呼ぶ.

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_j (T_j - O_j)^2 \quad (3.12)$$

この総合判定誤差が最終判定誤差以下になった場合に学習を終了させる.

識別

学習により作成した NN ウェイトを用いて, 未学習データより算出される NN 入力値を NN に入力し, NN 前向き計算を行い最大の出力値を示すパターンを識別結果とする. 図 3.18 は, 一人の被験者が同じ動作を 11 回行い計測し, さらに特徴抽出を行い NN 入力値として算出された値をグラフ化したものである. 横軸は, NN の入力細胞番号を示し, 縦軸は入力値を表す. 図 3.18 より, 一人の被験者が同じ動作をしたとしても, データが大きくばらつくことが確認できる.

NN によって識別することにより, このようなデータの識別も可能である. しかし, 学習データより大きく外れたデータが入力された場合 NN の汎化能力を用いたとしても, 目標とする識別率が得られなかった. そこで, オンラインチューニングを導入する.

3.1 筋活動電位を用いた手首動作識別システムへの適応




図 3.18 同一被験者による NN 入力値

オンラインチューニング

オンラインチューニングは、DSP ユニットのスイッチをオンラインチューニングモードに切り替えることにより実行可能である。オンラインチューニングでは、各手首動作を 3 回ずつ行い EMG を計測する。その後、計測された EMG は FFT での前処理を行い、NN 入力値へと変換される。さらに、フラッシュメモリに保存されている NN ウェイトを対象として、継続学習を行う。学習の収束は、DSP ユニットのフラッシュメモリに保存されたパラメータファイルを変更しない限り、初期学習時と同じ設定となる。また、学習が収束した場合、NN ウェイトは DSP ユニットのフラッシュメモリに保存される。

以降、手首動作識別システムにおいてオンラインチューニングの有効性確認を行う。

3.2 手首動作識別システムにおけるオンラインチューニング実験

3.2.1 実験概要

本章では、EMG のデータを用いた手首動作識別システムにおけるオンラインチューニングシステムの有用性を示す実験を行う。本実験の目的は、オンラインチューニング前後の識別率を比較することにより、オンラインチューニングの有用性を示すことである。

3.2.2 実験

実験手順としては、手首にセンサを装着し EMG 信号を DSP ユニットのアナログポートより入力する。その後、初期学習を実行する。初期学習が終了後、EMG 信号を識別データとして DSP ユニットに入力し、ユニット上で識別を行い識別率の算出を行う。次に、オンラインチューニングとして継続学習に用いる EMG 信号を DSP ユニットに入力し、継続学習を実行する。その後、新たに EMG 信号を識別データとして DSP ユニットアナログポートに入力し、ユニット上で識別を行い識別率の算出を行う。また、オンラインチューニングを 1 回行い、識別率の算出を行う。

次に、実験条件を示す。

- 識別は 7 パターン分離とする。
- 手首の動作は 7 パターン (静止, 背屈, 掌屈, 回内, 回外, 開き, 握り) である。
- 初期学習およびオンラインチューニングに使用するデータは、各パターンに対し 5 サンプルングとする。
- 初期学習およびオンラインチューニングの識別は、手首動作各パターン 20 回ずつ行う。
- 識別結果は、NN よりの出力値が最大のパターンとする。

その他実験条件を表 3.4 に示す。

3.2 手首動作識別システムにおけるオンラインチューニング実験

表 3.4 手首動作識別システムにおけるオンラインチューニングシステム有用性確認実験条件

最終誤差判定値	0.001
最大学習回数	20000
学習アルゴリズム	改良型 BP 法
NN 入力層	48
NN 中間層	25
NN 出力層	7
学習定数 (式 3.7)	0.05
慣性定数 (式 3.7)	0.95
振動定数 (式 3.7)	-0.1

3.2 手首動作識別システムにおけるオンラインチューニング実験

表 3.5 オンラインチューニングシステム有用性確認実験識別結果

動作	初期学習 (成功数/識別母数)	オンラインチューニング (成功数/識別母数)
静止	80% (16/20)	90% (18/20)
背屈	70% (14/20)	95% (19/20)
掌屈	90% (18/20)	70% (14/20)
回内	20% (4/20)	55% (11/20)
回外	15% (3/20)	20% (4/20)
開き	60% (12/20)	80% (16/20)
握り	65% (13/20)	90% (18/20)
平均	57% (80/140)	71% (100/140)

3.3 起床検知システムへの適応

初期学習終了後およびオンラインチューニング終了後の識別率を、表 3.5 に示す。

実験結果より、初期学習で 20%と低い識別率を示していた回内の動作において、オンラインチューニング後では 55%と上昇が確認できた。しかしながら、掌屈においては、識別率が 90%から 70%へと下降している。この原因としては、継続学習データに大きな変動があり、掌屈のパターンのみ学習が不十分だと考えられる。また、オンラインチューニング前後の平均識別率は、それぞれ 57%から 71%と上昇が確認できた。これにより、個人差の存在する EMG を識別対象として扱う手首動作識別システムにおいて、オンラインチューニングシステムの有用性を確認することができた。

3.3 起床検知システムへの適応

3.3.1 起床検知システム概要

本章では、起床検知システムについて示す。システム筐体は、ベッドの足下に設置する(図 3.20 参照)。ここで、ベッド足下に検査筐体を設置する理由は、介護士からの意見を元に、医療機関での運用を考慮した場合、病室はベッドの頭側を壁側に向け設置するレイアウトとなっている。そこで、ベッド横方向から撮像できる位置に筐体を設置する場合、介護者および介護士の行動の障害となり、設置することは難しい。さらに、ベッドの足下に設置する理由は、検知対象および介護者の動線を遮らない。これらに加え、検知にはベッドとその周辺を撮像する必要があるためである。これら筐体の設置方法については、過去の研究により検証を行った [8]。

図 3.19 に検知フローを示す。起床検知システムの検知方法は、まず、対象者を実験筐体に取り付けられている WEB カメラを使用して、1 秒間隔で被験者を撮影する。その後、撮像した画像から人物周辺の切り出しが行われる。切り出された画像は、特徴抽出が行われ NN 入力値へと変換される。検知結果は、検知対象者の状態を就床、起床途中、起床、落下途中、落下の 5 状態にクラス分けされる。

図 3.25 に 5 状態それぞれの実写画像とモデル画像を示す。就床は、ベッドで検知対象者

3.3 起床検知システムへの適応

が寝ている状態である。起床途中は、検知対象者が就床状態からベッドの上で起き上がり座ろうとするまでの状態である。起床は、検知対象者がベッドの上で起き上がり座った状態である。落下途中は、検知対象者がベッドから落ちかけている状態である。落下は、検知対象者が完全にベッドより落下した状態である。ここで、落下途中および落下を危険行動と定義し、これらの行動が検知された場合に警報を発する。

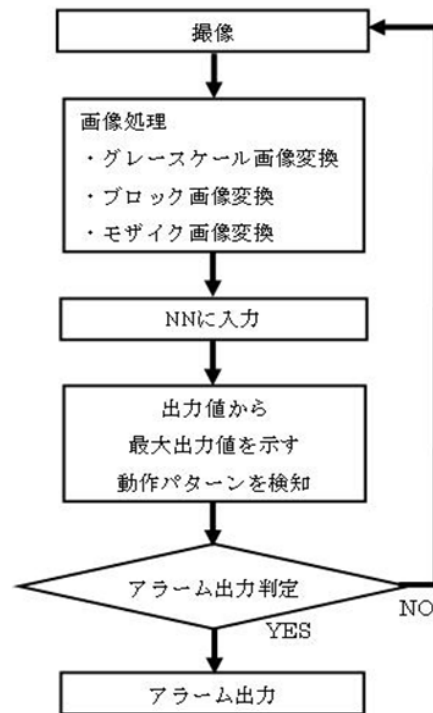



図 3.19 起床検知システム検査フロー

3.3 起床検知システムへの適応



図 3.20 起床検知システム実験環境




(a) 就床 (モデル)



(b) 就床 (実写)

図 3.21 5 行動のクラス分け (就床)




(a) 起床途中 (モデル)




(b) 起床途中 (実写)

図 3.22 5 行動のクラス分け (起床途中)

3.3 起床検知システムへの適応




(a) 起床 (モデル)



(b) 起床 (実写)

図 3.23 5 行動のクラス分け (起床)




(a) 落下途中 (モデル)



(b) 落下途中 (実写)

図 3.24 5 行動のクラス分け (落下途中)



(a) 落下 (モデル)



(b) 落下 (実写)

図 3.25 5 行動のクラス分け (落下)

3.3 起床検知システムへの適応

3.3.2 ハードウェア

実験装置を図 3.26 に示す。実験筐体は、カメラ部、台座部で構成される。カメラ部にはセンサが Charge Coupled Device であり、視野角 76 度の WEB カメラを使用している。図 3.27 に WEB カメラを示す。本カメラは、安価であり夜間での撮像能力を有するカメラを選定している。また、このカメラの解像度は 640(ピクセル) × 480(ピクセル) である。

起床検知システムは、夜間でも検知を行う必要がある。そこで、夜間の明るさを再現した暗所での撮像能力確認を行う。暗所での撮像画像を図 3.28 に示す。さらに、図 3.28 のヒストグラムを、図 3.29 を示す。図 3.29 の横軸は輝度値を示し、縦軸は出現頻度を示す。この図 3.29 より、低輝度から高輝度まで輝度が分布していることが確認できる。これにより、このカメラは暗所に対しても有効であることが確認できた。

提案システムは、画像により検知を行うためベッドおよびその周辺を撮像する必要がある。そこで、WEB カメラの位置は、床からの高さが 120cm から 175cm の間で調整可能とする。また、カメラの高さが高い場合、筐体が転倒しやすくなる可能性が考えられる。それに加え、WEB カメラの高さが 120cm の場合であってもカメラを用いて撮像した画像は十分な撮像範囲が確保できる。そこで、WEB カメラの高さは 120cm とする。

さらに、高齢者および介護者の行動の障害となることを避けるために、台座部は小型化しさらに実験筐体単体で検知を行う必要がある。そこで、台座部に Personal Computer(PC) を格納し、筐体単体にて検知が可能なシステムである。また、PC の CPU は VIA 社製 Eden ESP6000 (動作クロックは 600MHz) で、OS が使用可能な物理メモリは 224MB である。OS には、Windows XP Professional SP2 を使用している。PC とカメラの接続には、ユニバーサルシリアルバス (USB:Universal Serial Bus) ポートを用いている。

3.3 起床検知システムへの適応

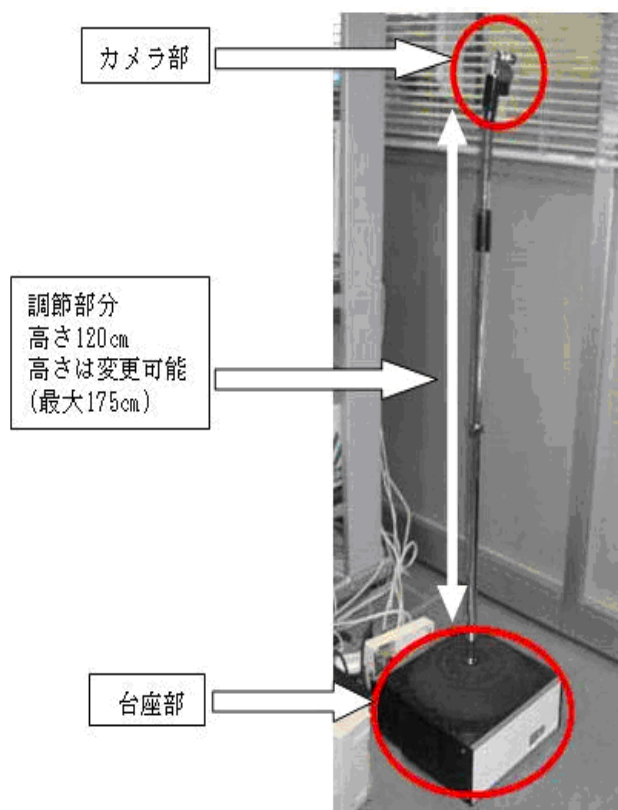


図 3.26 起床検知システム実験筐体



図 3.27 WEB カメラ

3.3 起床検知システムへの適応



図 3.28 選定カメラを用いて撮像した画像

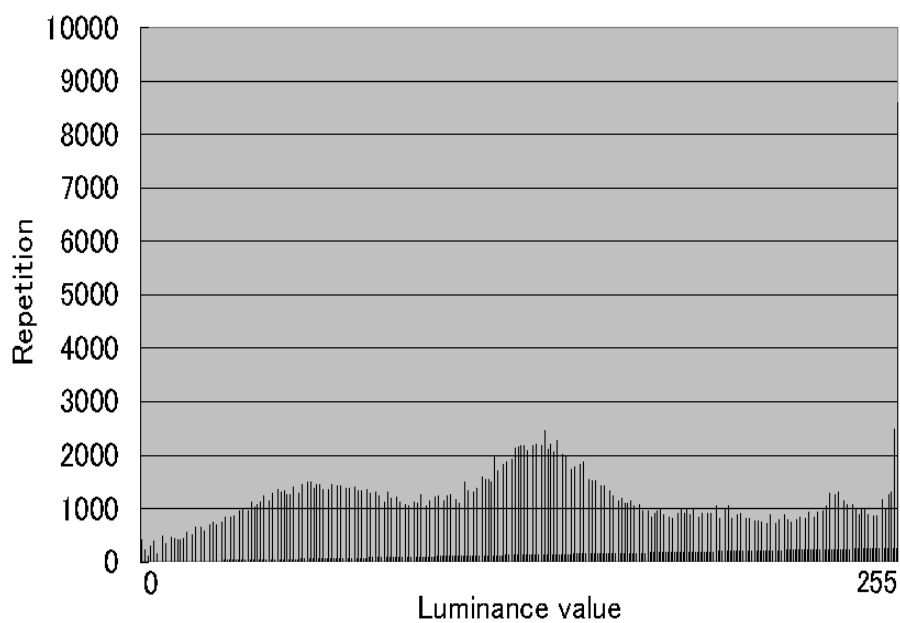


図 3.29 選定カメラを用いて撮像した画像のヒストグラム

3.3 起床検知システムへの適応

3.3.3 ソフトウェア

特徴抽出部

本項では、起床検知システムの検査プログラムについて示す。起床検知システムの検査プログラムは、Borland C++言語で記述する。Borland C++を使用することにより、容易にグラフィックユーザインタフェースを構築することが可能である。

次に、特徴抽出方法についての説明を行う。図 3.30 に示すように、1 回の検知では連続する 5 枚の画像が使用される。これら 1 回の検知に必要とされる 5 枚の画像を 1 データセットと定義する。図 3.30 の tmp0~tmp4 までの画像は、等間隔で撮像された画像である。tmp0~tmp3 の画像は、動的情報の特徴抽出に使用する。さらに tmp4 の画像は、静的情報の抽出に使用する。ここで、1 秒間隔で撮像する理由は、大きな動き情報を撮像し特徴量として NN に入力するためである。1 データセットのそれぞれの画像には、図 3.31 に示すようにベッドと検知対象者以外の家具などの外乱が含まれる。この外乱を取り除くために、図 3.32 に示すように検知対象者の顔を中心とし左右対称に検知対象者とベッドを含む画像を切り出す。現在のシステムでは、この処理を手作業にて行っている。

次に、1 データセットのそれぞれの画像は、式 3.13 を用いてグレースケール画像へと変換される [56]。ここで、式中 V は変換後の輝度値を示す。また、 R 、 G 、 B はそれぞれ赤色、緑色、青色の輝度値を示す。

$$V = (R \times 30 + G \times 59 + B \times 11) / 100 \quad (3.13)$$

ここからの処理は、静的情報の特徴量と動的情報の特徴量を抽出する処理の 2 つの処理に分かれる。図 3.33 に静的情報の特徴抽出のイメージを示す。まず、静的情報の特徴量抽出方法は、1 枚目のグレースケール画像を縦 10、横 20 の計 200 ブロックにブロック化する。次に、各ブロックに対して輝度値の加算平均を行う。さらに、ブロックの平均輝度値が 127 未満なら「0」、127 以上であるならば「1」とする。最後に各ブロックから算出される値「0」または「1」を NN 入力値とする。ビットマップ画像は 2 値化され、さらに、ブロック化し

3.3 起床検知システムへの適応




図 3.30 静的情報と動的情報の撮像画像

200 個の NN 入力値としている。これは、被験者の服装，男女差，布団の模様，色等に影響を受けない入力情報とすることを目的とする。

動的情報の特徴量抽出方法は、残り 4 枚のグレースケール画像を、それぞれ縦 6 横 6 に分割する。次に各行列毎に輝度値を加算平均する (図 3.34 参照)。さらに、平均輝度値が 127 未満なら「0」、127 以上であるならば「1」とし、1 枚の画像より計 12 つの NN 入力値を作成する。動的情報の特徴量の NN 入力値の個数は計 24 個となる。これは、検知対象者の服装，男女差，布団の模様および色等の影響を受けず、人の大まかな動きを NN への入力値とするためである。

3.3 起床検知システムへの適応



図 3.31 起床検知システムの撮像画像




図 3.32 検知対象者の切り出し

3.3 起床検知システムへの適応

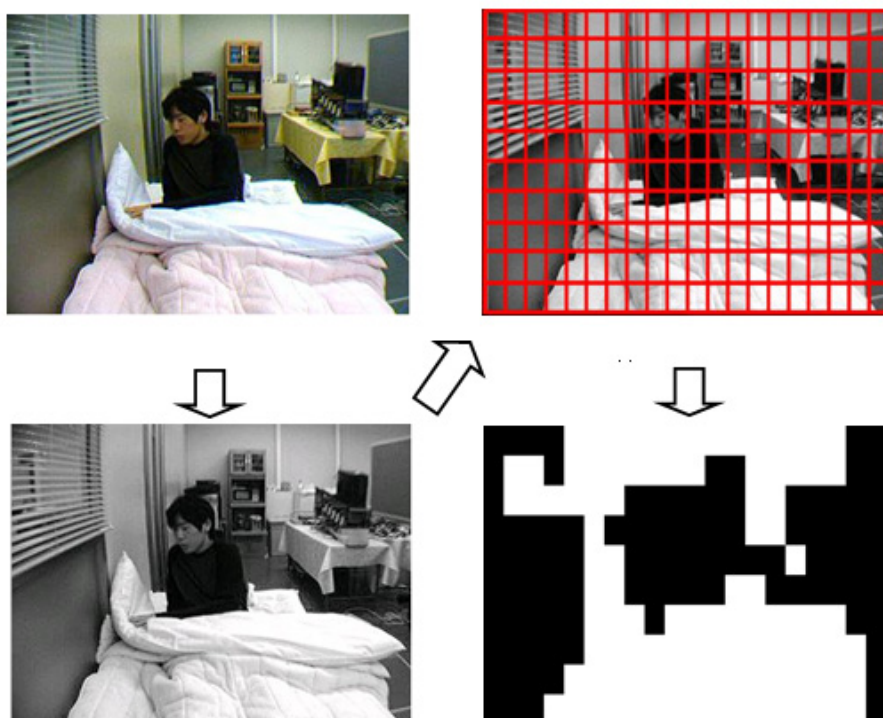


図 3.33 特徴抽出処理のイメージ




図 3.34 動的情報の特徴抽出

3.3 起床検知システムへの適応

学習

特徴抽出されてデータは、前章で示したデータファイルへと変換される。学習には手首動作識別システムの学習にて記述した学習システムを用いる。そのため NN ウェイトのフォーマットおよび NN 構成の設定、データファイルのフォーマットにおいて互換性が保証されている。そのため DSP ユニットへの移植も容易に行うことが可能である。学習アルゴリズムは、式 3.7 に示したバックプロパゲーションアルゴリズムを用いる。また、慣性項と振動項の最適な組み合わせ ($\alpha = 0.95$, $\beta = -0.1$) についても、手首動作識別システムと同様である。学習収束条件および NN 構成はパラメータファイルに記述する。

検知部

特徴抽出において作成した NN 入力値を NN に入力する。検知結果は NN からの発火値が最大のパターンとする。図 3.35 に起床検知システムの検知部の模式図を示す。

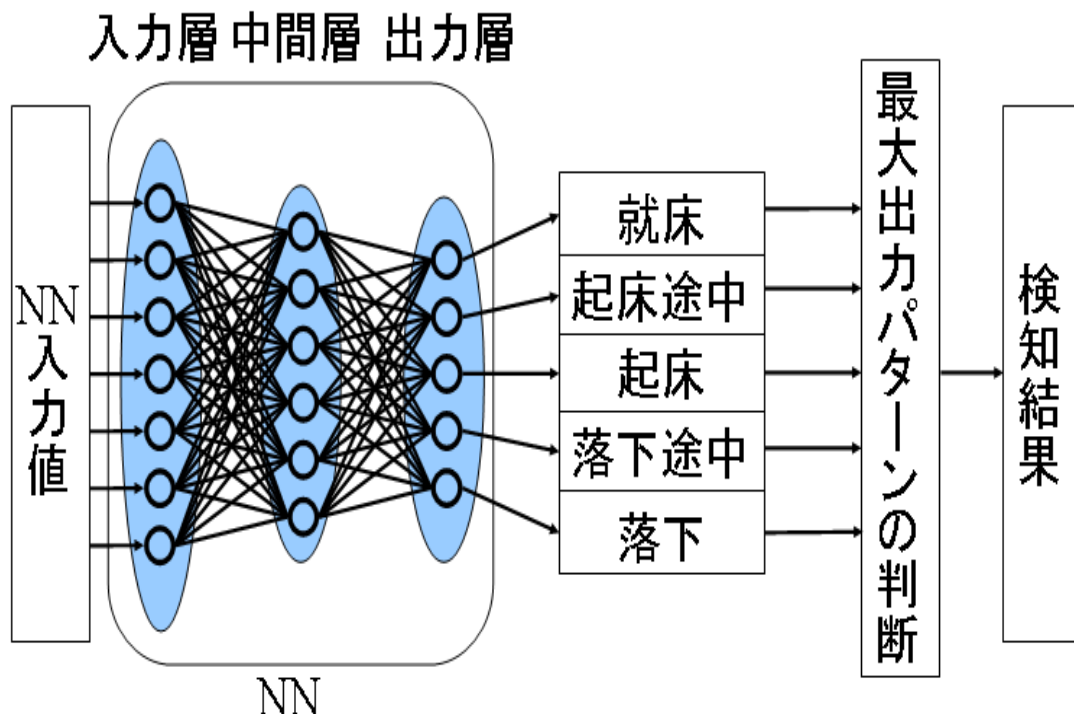


図 3.35 NN 構成

3.4 起床検知システムにおけるオンラインチューニング実験

オンラインチューニング

オンラインチューニングシステムを実現するために、学習プログラムにオンラインチューニング機能を追加した。学習プログラムは、撮像した画像を使用して学習を行うプログラムである。学習プログラムの継続学習ボタンをチェックするとにより、オンラインチューニングが可能である。学習の収束条件はパラメータファイルに記述された内容が適用される。

このプログラムにより学習が行われた NN ウェイトは、ファイルとして保存される。保存を行うことにより、オンラインチューニングを再度行うことが可能である。また、オンラインチューニング前への復元も容易に行うことが可能である。

3.4 起床検知システムにおけるオンラインチューニング実験

3.4.1 実験概要

本実験では、オンラインチューニングの有効性確認を起床検知システムにおいて行う。まず、起床検知システムの個人差の検証として、3名の被験者におけるベッドでの振る舞いの個人差が、起床検知システムの検知結果に与える影響を検証する。さらに、オンラインチューニングを2回行い、初期学習終了時とオンラインチューニング終了時の検知率を比較することにより、その有用性を確認する。

3.4.2 起床検知システムの個人差の検証

本項の実験は、学習済みおよび未学習の被験者の検知率を検証することを目的としている。実験により、ベッド上での振る舞いの違いが、起床検知システムの検知率への影響について確認を行う。そこで、被験者3名(被験者Aおよび被験者B, 被験者C)のそれぞれのデータを学習した NN ウェイトを作成し、検知を行う。

実験手順は、まず、被験者3名が、それぞれ学習および検知用データを撮像する。ここで、被験者の服の色の違いを避けるために、それぞれの被験者が決まった回数、白色および黒色

3.4 起床検知システムにおけるオンラインチューニング実験

の服を着用することとする。次に、被験者 A および被験者 B、被験者 C のそれぞれの学習データを用いて学習を行い、3つの NN ウェイトを作成する。ここで、被験者 A の学習データを用いて、学習した NN ウェイトを NN ウェイト A とする。また、被験者 B の学習データで学習したウェイトを NN ウェイト B とする。さらに、被験者 C の学習データで学習したウェイトを NN ウェイト C とする。その後、初期学習終了後の検知率を未学習のデータを使用して算出する。

次に、実験条件を示す。

- 検知は、5 パターン分離とする。
- 被験者のベッドでの挙動は、5 パターン (就床、起床途中、起床、落下途中、落下) とする。
- カメラの解像度は、640(ピクセル) × 480(ピクセル) とする。
- 初期学習に使用するデータは、各パターンに対し 3 セットとする。
- 検知用データは、各パターン 60 セットを使用する。
- 検知用データの各パターンにおいて、白服および黒服の着用は 30 セットとする。

その他実験条件を表 3.6 に示す。

初期学習の結果、学習済みのデータを用いて検知率を算出したところ、NN ウェイト A および NN ウェイト B、ウェイト C のそれぞれの検知率は、100%であった。NN ウェイト A および NN ウェイト B、NN ウェイト C に対して、被験者 A および被験者 B、被験者 C の検知用データでの検知率を、それぞれ表 3.7 および表 3.8、表 3.9 に示す。

実験の結果より、NN ウェイト A および NN ウェイト B、NN ウェイト C において、学習対象以外の平均検知率は、学習対象者の平均検知率より 30%以上低い値を示すことが分かる。これは、学習により NN の識別空間が、学習対象となった被験者の行動を検知可能に調整されたためである。つまり、被験者の振る舞いには、個人差が存在し、特徴的な振る舞いを検知可能になるよう NN が調整されたと言える。結論として、起床検知システムは、個人差が存在し、この個人差が検知結果に影響を与えることが分かった。

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.6 起床検知システムにおけるオンラインチューニングシステム有用性確認実験条件

最終誤差判定値	0.001
最大学習回数	5000
学習アルゴリズム	改良型 BP 法
NN 入力層	248
NN 中間層	30
NN 出力層	5
学習定数 (式 3.7)	0.05
慣性定数 (式 3.7)	0.95
振動定数 (式 3.7)	-0.1

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.7 初期学習後の NN ウェイト A における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	90.0% (54/60)	58.3% (35/60)	0.0% (0/60)
起床途中	95.0% (57/60)	0.0% (0/60)	3.3% (2/60)
起床	43.3% (26/60)	55.0% (33/60)	96.6% (58/60)
落下途中	60.0% (36/60)	40.0% (24/60)	11.6% (7/60)
落下	90.0% (54/60)	91.6% (55/60)	100.0% (60/60)
平均	75.6% (227/300)	49.0% (147/300)	42.3% (127/300)

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.8 初期学習後の NN ウェイト B における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	30.0% (18/60)	85.0% (51/60)	91.6% (55/60)
起床途中	6.6% (4/60)	75.0% (45/60)	5.0% (3/60)
起床	35.0% (21/60)	63.3% (38/60)	11.6% (7/60)
落下途中	53.3% (32/60)	58.3% (35/60)	35.0% (21/60)
落下	0.0% (0/60)	100.0% (60/60)	83.3% (50/60)
平均	25.0% (75/300)	76.3% (229/300)	45.3% (136/300)

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.9 初期学習後の NN ウェイト C における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	6.6% (4/60)	71.6% (43/60)	95.0% (57/60)
起床途中	65.0% (39/60)	0.0% (0/60)	61.6% (37/60)
起床	51.6% (31/60)	70.0% (42/60)	61.6% (37/60)
落下途中	16.6% (10/60)	0.0% (0/60)	98.3% (59/60)
落下	100.0% (60/60)	100.0% (60/60)	100.0% (60/60)
平均	48.0% (144/300)	46.3% (139/300)	83.3% (250/300)

3.4 起床検知システムにおけるオンラインチューニング実験

3.4.3 オンラインチューニングの有効性検証実験

本項の実験では、オンラインチューニングの有効性検証実験を行う。実験手順は、先の実験で作成した NN ウェイト A に対し、初期学習時の検知に未使用の未学習データを使用し、オンラインチューニングを行う。ここで、NN ウェイト B および NN ウェイト C に対しても同様方法でオンラインチューニングを行う。オンラインチューニング終了後、被験者 A および被験者 B、被験者 C の未学習データを使用し、それぞれの NN ウェイトに対して、検知率を算出する。ここで、本項実験での検知に使用するデータは、先の実験で使用した検知データを使用する。

さらに、1 回目のオンラインチューニングが終了した NN ウェイト A に対して、検知に未使用の未学習データを使用し、2 回目のオンラインチューニングを行う。NN ウェイト B および NN ウェイト C に対しても、同様方法でオンラインチューニングを行う。また、検知データを使用し、検知率を算出する。

バックプロパゲーションアルゴリズムに使用されるパラメータは、初期学習時と同値とする。次に、実験条件を示す。

- 検知は 5 パターン分離とする。
- カメラの解像度は 640(ピクセル) × 480(ピクセル) とする。
- オンラインチューニングに使用するデータは、各パターンに対し 3 セットとする。
- オンラインチューニングの検知用データは、初期学習の検知時と同じ 60 セットとする。

1 回目のオンラインチューニング後の NN ウェイト A および NN ウェイト B、NN ウェイト C における検知結果を、表 3.10 および表 3.11、表 3.12 に示す。さらに、2 回目のオンラインチューニング後の NN ウェイト A および NN ウェイト B、NN ウェイト C における検知結果を、表 3.13 および表 3.14、表 3.15 に示す。

実験結果より、NN ウェイト A の被験者 B、また、NN ウェイト B の被験者 C の検知結果においては、オンラインチューニング後の検知率がわずかながら低下していることが確認

3.4 起床検知システムにおけるオンラインチューニング実験

できる。これは、オンラインチューニングにより、学習対象となった被験者の振る舞いに特化した検知が可能となるよう、NN が調整された結果と言える。

図 3.36 および図 3.37, 図 3.38 に NN ウェイト A および NN ウェイト B, NN ウェイト C の初期学習から 2 回目のオンラインチューニングの検知率までを示す。これらの図の横軸は、左から初期学習, 1 回目のオンラインチューニング, 2 回目のオンラインチューニングを示す。また、縦軸は、それぞれの行動の検知率の平均を示す。NN ウェイト A および NN ウェイト B, NN ウェイト C において、1 回目のオンラインチューニングの対象となった被験者の検知率が、それぞれ 9.7% および 9.3%, 7.3% と向上していることが確認できる。さらに、2 回目のオンラインチューニング後の検知率は、初期学習終了時と比較すると、それぞれ 15.0% および 14.0%, 10.0% と向上していることが確認できる。この結果より、オンラインチューニングシステムは個人差を吸収し、起床検知システムの検知率を向上させたことが確認できる。本実験の結果より、起床検知システムにおいてオンラインチューニングは有効であると言える。

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.10 オンラインチューニング 1 回目の NN ウェイト A における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	98.3% (59/60)	58.3% (35/60)	0.0% (0/60)
起床途中	100.0% (60/60)	0.0% (0/60)	83.3% (50/60)
起床	48.3% (29/60)	75.0% (45/60)	83.3% (46/60)
落下途中	95.0% (57/60)	50.0% (30/60)	38.3% (23/60)
落下	85.0% (51/60)	46.6% (28/60)	61.6% (37/60)
平均	85.3% (256/300)	46.0% (138/300)	52.0% (156/300)
初期学習終了時らかの変化	+9.7%	-3.0%	+9.7%

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.11 オンラインチューニング 1 回目の NN ウェイト B における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	21.6% (13/60)	90.0% (54/60)	31.6% (19/60)
起床途中	0.0% (0/60)	55.0% (33/60)	6.0% (1/60)
起床	86.6% (52/60)	88.3% (53/60)	50.0% (30/60)
落下途中	95.0% (57/60)	95.0% (57/60)	25.0% (15/60)
落下	31.6% (19/60)	100.0% (60/60)	100.0% (60/60)
平均	47.0% (141/300)	85.6% (257/300)	41.6% (125/300)
初期学習終了時からの変化	+22.0%	+9.3%	-3.7%

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.12 オンラインチューニング 1 回目の NN ウェイト C における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	5.0% (3/60)	53.3% (32/60)	93.3% (56/60)
起床途中	95.0% (57/60)	0.0% (0/60)	76.6% (46/60)
起床	81.6% (49/60)	60.0% (36/60)	83.3% (50/60)
落下途中	20.0% (12/60)	1.6% (1/60)	100.0% (60/60)
落下	73.3% (44/60)	100.0% (60/60)	100.0% (60/60)
平均	55.0% (165/300)	43.3% (129/300)	90.6% (272/300)
初期学習終了時からの変化	+7.0%	-3.3%	+7.3%

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.13 オンラインチューニング 2 回目の NN ウェイト A における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	98.3% (59/60)	41.6% (25/60)	0.0% (0/60)
起床途中	100.0% (60/60)	0.0% (0/60)	35.0% (21/60)
起床	88.3% (53/60)	85.0% (51/60)	95.0% (57/60)
落下途中	86.6% (52/60)	66.6% (40/60)	43.3% (26/60)
落下	80.0% (48/60)	41.6% (25/60)	46.6% (28/60)
平均	90.6% (272/300)	47.0% (141/300)	44.0% (132/300)
初期学習終了時からの変化	+15.0%	-2.0%	+1.7%

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.14 オンラインチューニング 2 回目の NN ウェイト B における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	1.6% (1/60)	78.3% (47/60)	26.6% (19/60)
起床途中	0.0% (0/60)	83.3% (50/60)	0.0% (0/60)
起床	91.6% (55/60)	91.6% (55/60)	50.0% (30/60)
落下途中	100.0% (60/60)	98.3% (59/60)	38.3% (60/60)
落下	45.0% (27/60)	100.0% (60/60)	100.0% (60/60)
平均	47.6% (143/300)	90.3% (271/300)	44.0% (132/300)
初期学習終了時からの変化	+22.6%	+14.0%	-1.3%

3.4 起床検知システムにおけるオンラインチューニング実験

表 3.15 オンラインチューニング 2 回目の NN ウェイト C における検知結果

	被験者 A 検知 検知成功率 (検知成功数/母数)	被験者 B 検知 検知成功率 (検知成功数/母数)	被験者 C 検知 検知成功率 (検知成功数/母数)
就床	13.3% (8/60)	76.6% (46/60)	96.6% (58/60)
起床途中	100.0% (60/60)	0.0% (0/60)	91.6% (55/60)
起床	78.3% (47/60)	60.0% (36/60)	78.3% (47/60)
落下途中	18.3% (11/60)	1.6% (1/60)	100.0% (60/60)
落下	98.3% (59/60)	100.0% (60/60)	100.0% (60/60)
平均	61.6% (185/300)	48.6% (146/300)	93.3% (280/300)
初期学習終了時からの変化	+13.6%	+2.3%	+10.0%

3.4 起床検知システムにおけるオンラインチューニング実験

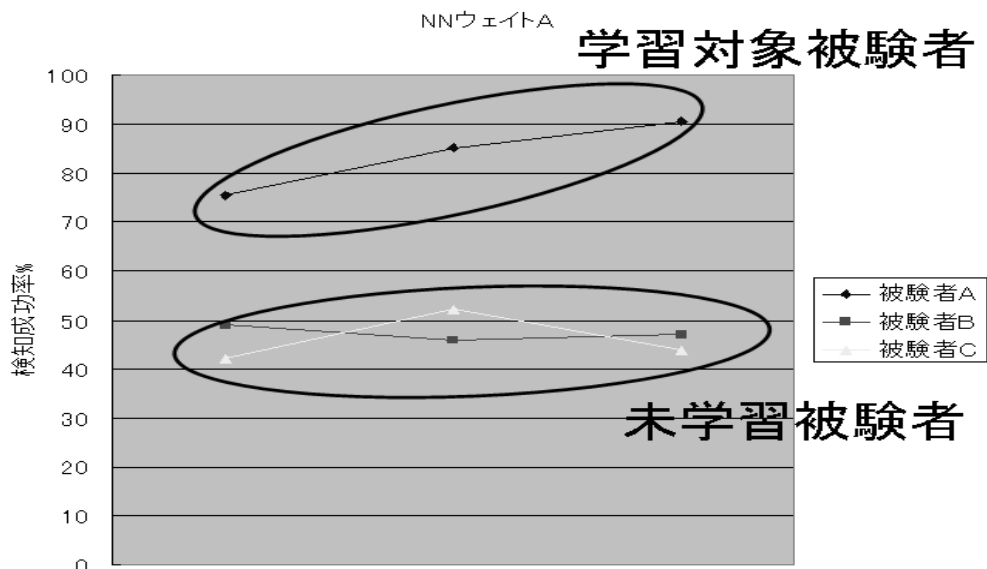


図 3.36 NN ウェイト A の検知率の変化

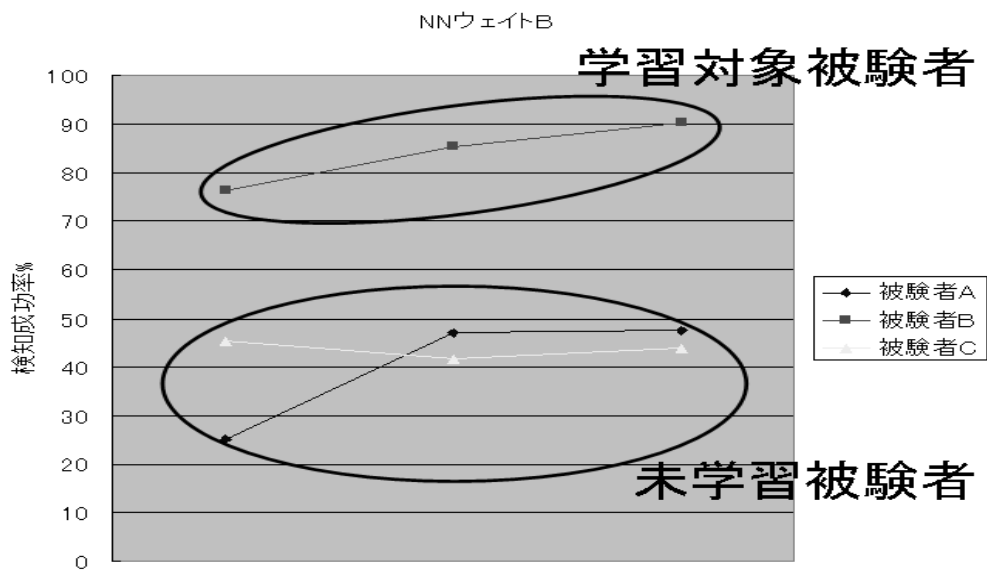


図 3.37 NN ウェイト B の検知率の変化

3.4 起床検知システムにおけるオンラインチューニング実験

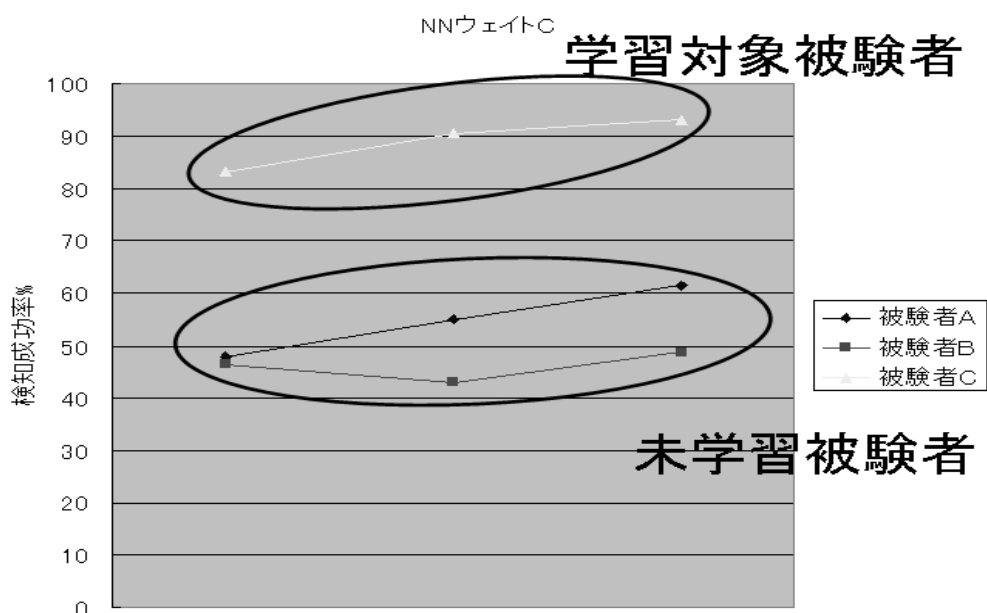


図 3.38 NN ウェイト C の検知率の変化

第 4 章

オンラインチューニングシステムの 考察

本論文では、手首動作識別システムおよび起床検知システムにおいて、オンラインチューニングの有効性の確認を行った。手首動作識別システムは、EMG という 1 次元のデータであり、さらにバイオメトリックスを対象としている。さらに EMG は、個人差が在ることが知られている。また、6 人の被験者を用いて検証を行ったところ、個人により計測される EMG は大きくばらつくことが判明した。起床検知システムは、ベッドから起床するという、人の挙動を識別対象としている。起床検知システムのベッドでの挙動は、個人差が在ることが医療関係者より指摘されている。そこで、起床検知システムにおいて、個人差が検知に影響を及ぼすか実際に検証をおこなった。結果、学習対象者の検知率は、学習対象以外の平均検知率より、30%以上低い値を示すことが判明した。この結果より、起床検知システムでは個人差が検知に影響を及ぼすことがわかった。

これら、特徴の異なる 2 つのデータを識別対象とする NN 識別アプリケーションにてオンラインチューニングの有効性を確認した。まず、手首動作識別システムでは、初期学習終了時とオンラインチューニング終了時の識別率を比較することによりオンラインチューニングの有効性を示した。実験結果より、初期学習で 20%と低い識別率を示していた回内の動作において、オンラインチューニング後では 55%と上昇が確認できた。しかしながら、掌屈においては、識別率が 90%から 70%へと下降している。この原因としては、継続学習データに大きな変動があり、掌屈のパターンのみ学習が不十分だと考えられる。また、オンライン

チューニング前後の平均識別率は、それぞれ 57%から 71%と上昇が確認できた。これにより、個人差の存在する EMG を識別対象として扱う手首動作識別システムにおいて、オンラインチューニングシステムの有用性を確認することができた。

起床検知システムにおいては、被験者毎に学習を行った NN ウェイトを作成し、オンラインチューニングを 2 回行い、初期学習時と比較することにより、オンラインチューニングの有効性を示した。NN ウェイト A および NN ウェイト B, NN ウェイト C において、1 回目のオンラインチューニングの対象となった被験者の検知率が、それぞれ 9.7%および 9.3%, 7.3%と向上していることが確認できた。さらに、2 回目のオンラインチューニング後の検知率は、初期学習終了時と比較すると、それぞれ 15.0%および 14.0%, 10.0%と向上していることが確認できた。この結果より、オンラインチューニングシステムは個人差を吸収し、起床検知システムの検知率を向上させたことが確認できる。本実験の結果より、起床検知システムにおいてオンラインチューニングは有効であると言える。

これら 2 つの特徴が 1 次元と 2 次元と異なるデータを識別対象とするオンラインチューニング有効性確認実験は、共にオンラインチューニングを行うことにより、識別率が向上したことが分かる。また、起床検知システムにおいてはオンラインチューニングの回数を重ねる毎に識別率は向上することが判明した。これらの検証より、オンラインチューニングを用いることにより、NN 識別アプリケーションの識別率の向上および維持、個人ユーザへのカスタマイズが可能であることが判明した。

EMG や人の挙動以外に特徴の異なるデータを識別対象とした場合もオンラインチューニングを行うことにより、学習対象者に合わせた NN 識別アプリケーションのカスタマイズを行い、識別率の維持向上が可能ではないかと考えられる。

本実験では、学習データを選択することなくオンラインチューニングを行った。そこで、オンラインチューニングに用いるデータを選択するシステムを構築することにより、オンラインチューニング実行時にさらなる識別率の向上が期待できる。例えば、ユーザ個人を限定している場合、識別に失敗したデータをストアしておき、ある程度ストアされた時点でオンラインチューニングを開始するシステムである。

第 5 章

おわりに

NN 識別アプリケーションは、次の問題が指摘されている。NN 識別アプリケーションでは、パターン分類の対象となる学習データが必要であり、個々のパターンにおいてパターン内の範囲全てを含むデータが必要である。つまり、学習データは、識別範囲となる 1 つのパターン内のデータとして、他パターンとの境界近くのデータを包括する必要がある。それ故、このデータを学習データとして学習を行うことにより、NN の汎化能力を十分に得ることが可能である。そのため、NN 識別アプリケーションは、想定外の環境において、つまり、極端に学習時と異なる識別データを扱う場合には、NN の汎化能力を用いたとしても、正しく識別することが不可能である危険性が想定される。例えば、EMG を用いた手首操作識別システムにおいては、EMG の個人差が識別結果に影響を与えていることが報告されている。

この問題に対処する方法として、すべての学習データを学習に使用する方法が考えられる。つまり、パターン内に存在すると予測される全てのパターンのデータを想定し、さらに他パターンとの境界を特定しデータをサンプリングし学習データとすることである。しかし、この手法による問題解決は次の理由により難しい。例えば、手首動作識別システムが識別対象としている EMG は、乾式表面電極で測定され湿度や温度また外部からの電磁波の影響、筋の量や脂肪の量などのさまざまな影響の組み合わせがあり、これらをすべて想定しサンプリングすることを容易に行うことはできない。また、起床検知システムの識別対象としている人の挙動において、考慮すべき条件が数多く存在し、これらすべての挙動を想定し網羅するデータをサンプリングすることは難しい。さらに、すべてのデータが揃ったとしても、現在、普及している PC は内部の処理および 32bit で表現された OS であり、32bit で定義可能なメモリアドレス空間は 2Gbyte と制限されるため、特殊な演算装置または 64bit

の OS を使用することを除き、無限に近い数のデータを学習時に扱うことは難しい。このメモリアドレス空間の制限の問題を解消する方法として、PC においてハードディスクドライブ上に仮想メモリを確保し、それをメモリとして使用しての学習も考えられるが、ハードディスクドライブへのアクセス時間はメモリへのアクセス時間に比べ遅く、演算時間が増加する問題を避けることができない。さらに、これらに加えて NN 識別アプリケーションが製品化された場合、工場出荷後の製品は、予測できないデータに対しても、ある程度の識別率を維持する必要がある。ここで、NN の汎化能力により学習データ範囲内のデータのばらつきが存在したとしても正しく識別することは可能である。しかしながら、市場では予測することが難しい学習時のデータから大きく外れるデータが存在することが想定される。その原因として、例えば、使用環境特有の電波ノイズや湿度や温度、ほこり、静電気などにより、データが大きく変動することが考えられる。この原因により、現状入手可能なデータから学習データを選定し、初期学習を行った NN を識別部とする NN 識別アプリケーションでは、これらへの対応が未だ不十分であった。

そこで、本論文では、これらの問題の一つの解決方法として、オンラインチューニングシステムを提案した。オンラインチューニングシステムとは、NN の学習機能を利用して、学習用のデータをリアルタイムで追加しながら、初期学習後の NN に対し、継続学習を実施するものである。具体的には、まず、識別対象となるデータをサンプリングし、学習データを選定し学習を行う。ここで、予想範囲内の未知のデータに対して一定の識別率を有する初期ウェイトを作成する。次に、使用者本人の少数のデータを順次学習データとしてサンプリングするとともに、このデータを用いて初期ウェイトに対し継続学習を行う。この手順を、目的とする識別性能が得られるまで繰り返す。

本論文では、以下に示す 2 つの異なる識別対象を扱う NN 識別アプリケーションにオンラインチューニングシステムを導入し、オンラインチューニングシステムの有効性を検証を行った。2 つの NN 識別アプリケーションの扱う識別対象は、乾式表面電極で計測される EMG と WEB カメラで撮像された画像と異なる。前者のデータは、1 次元の時系列データであり、後者のデータは 5 枚の画像である。また、これら 2 つの NN 識別アプリケーション

の識別結果は、共に個人差の影響を受けることで知られている。これら 2 つの異なる特徴を有するデータを識別対象とする NN 識別アプリケーションにおいて、オンラインチューニングシステムを導入し、オンラインチューニングシステムの有効性および汎化性について確認を行った。

オンラインチューニングシステムの有効性確認として、まず、EMG を用いた手首動作識別システムにおいて検証を行った。乾式表面電極により計測される EMG は個人差があり、NN の汎化能力だけでは、個人差の吸収が難しいことが判明している。提案システムの有効性確認実験では、はじめに、初期学習を行い識別率の確認を行った。その後、オンラインチューニングを行い、オンラインチューニング前後の識別率を比較した。その結果、オンラインチューニング後の識別率が初期学習終了時より 57% から 71% と上昇が確認できた。手首動作識別システムの識別対象とする EMG は、年齢、性別、筋の量、温度、湿度などにより想定されるデータは多種多様であり、想定外のデータも数多く存在することが予測される。そこで、手首動作識別システムにオンラインチューニングシステムを導入し、使用者の EMG を対象としてオンラインチューニングすることにより、使用者本人の識別に特化した識別システムに NN を再調整することが可能であることを確認した。また、未学習者のデータをサンプリングし追加学習が可能で、容易に未学習者を学習者として追加することが可能な NN 識別アプリケーションにアップグレードすることが可能であると言える。ここで、未学習の使用者の識別率は、学習対象となった使用者の識別率より低くなることが予測される。しかし、未学習の使用者が手首動作識別システムを使用する場合、その都度オンラインチューニングを実行し、使用者に合わせた手首動作識別システムに再調整を行うことが可能で、使用者本人に対して有効な識別率を得る、つまり、特定の使用者に特化した識別システムに再調整が可能である。

次に、起床検知システムにおいてもオンラインチューニングシステム有効性確認を行った。起床検知システムは、画像を用いた検知対象者のベッドからの転落の予測検知を目的としたシステムである。ここで、検知対象者のベッドにおける振る舞いには、個人差があり、ベッドから転落するまでの行動は個人により異なると考えられている。そこで、まず検知対

象者のベッド上での行動の個人差が、起床検知システムの検知結果に影響を与えるか確認を行った。実験の結果、学習対象以外の平均検知率は、学習対象者の平均検知率より 30%以上低い値を示すことが分かった。この結果より、挙動には個人差が存在し、起床検知システムにおいて検知に影響を与えていることが分かる。提案システムの有効性確認実験では、はじめに、初期学習を行い識別率の確認を行った。その後、オンラインチューニングを 2 回行い、検知率の変化を確認することにより、その有効性の確認を行った。実験の結果、1 回目のオンラインチューニングの対象となった被験者の検知率が、それぞれ 9.7%および 9.3%、7.3%と向上していることが確認できた。さらに、2 回目のオンラインチューニング後の検知率は、初期学習終了時と比較すると、それぞれ 15.0%および 14.0%、10.0%と向上していることが確認できた。実験の結果より、起床検知システムにおいては、ベッド上での使用者の動きは、多種多様な挙動の個人差が存在し、個人により画像のばらつきが大きいことが分かった。起床検知システムにおいても、全ての想定可能なデータをサンプリングすることは、考慮すべき条件が数多く存在するため難しい。さらに、パターン間の境界線を特定することは容易ではない。そこで、オンラインチューニングシステムを導入することにより、使用者毎にばらつく画像を扱う場合においても、未学習の使用者から学習データをサンプリングし追加することが可能で、容易に未学習の使用者を学習者としてシステムに追加することが可能と判明した。そのため、未学習の使用者の識別率は低い状態は続くが、学習を行った使用者の識別率は有効な識別率を得ることが可能であると判明した。つまり、起床検知システムもオンラインチューニングシステムを導入することにより、特定の使用者の検知に特化したシステムに容易に識別ルールの再調整が可能な識別システムにアップグレードが可能であると言える。

これら 2 つの NN 識別アプリケーションにおいて、オンラインチューニングシステムの有効性について確認されているため、工場から出荷後の製品において、予測できないデータに対しても識別率の維持を必要とするさまざまなアプリケーションへの導入が可能であると考えられる。例えば、個人差ならびに経年変化を伴う種々の産業アプリケーションの性能維持などに、特にその威力を発揮するものと思われる。

謝辞

本論文に対して，ご指導頂きました高知工科大学知能機械システム工学科竹田史章教授，ご尽力に感謝しております．また，論文執筆にあたりご尽力頂きました皆様の繁栄を心より願っております．最後に，本研究を行う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] Nilsson N., “Learning Machines”, McGraw-Hill, 1995
- [2] 満倉靖恵, 福見稔, 赤松則男, “唇検出 NN と肌色識別 NN による顔画像検索”, 映像情報メディア学会技術報告, Vol.24, No.39, pp.1-6, 2005
- [3] 官野恒男, 長橋宏, 安居院猛, “ニューラルネットワークによる男女顔特徴抽出”, 電子情報通信学会論文誌, Vol.J81-D-2, No.11, pp.2645-2652, 1998
- [4] Hironobu Satoh, Fumiaki Takeda, “Development of a Intelligent input Interface using EMG for MobileTerminal”, International Simulation and Gaming Association , pp.1078-1088 , 2003, Chiba, Japan
- [5] Hironobu Satoh, Fumiaki Takeda, “ Development of DSP unit for Online Tuning and Application to Neural Pattern Recognition System”, 8th International Conference on Knowledge-Based Intelligence Information & Engineering Systems, pp.866-873, 2004, Wellington, New Zealand
- [6] 佐藤公信, 竹田史章, 香川真也, “知的高速選別システムの独立駆動系による搬送系の実現”, 高速信号処理応用技術学会誌, 第 9 巻第 1 号, pp.42-47, 2005
- [7] 佐藤公信, 竹田史章, 東幸靖, 西蔭紀洋, “2 次元高速フーリエ変換を特徴抽出に用いた知的高速選別システムの開発”, 高速信号処理応用技術学会誌, 第 9 巻第 1 号, pp.48-54, 2005
- [8] 佐藤公信, 竹田史章, 白石優旗, 池田理恵, “ニューラルネットワークを用いた起床検知システムの開発”, 電気学会論文誌 C, 11 月号掲載決定
- [9] Hironobu Satoh, Fumiaki Takeda, Yoshihiro Saeki, Rie Ikeda, Yuhki Shiraishi, “Proposal of Awakening Behavior Detection System Using Neural Network”, The Second IASTED International Conference on Computational Intelligence, pp164-169, 2006, San Francisco, USA

参考文献

- [10] Hironobu Satoh, Fumiaki Takeda, “Examination of Awakening Behavior Detection System Using Online Tuning System”, The 7th International Conference on Optimization, Techniques and Applications, 2007, Kobe, Japan
- [11] Rie Ikeda, Hironobu Satoh, Fumiaki Takeda, “Development of Awakening Behavior Detection System Nursing Inside the house”, InTech 2006 International Conference on Intelligent Technology, pp.65-70, 2007
- [12] 久保和也, 佐藤公信, 白石優旗, 竹田史章, 井上啓史, “ニューラルネットワークを用いた医療画像診断システムの提案と検証”, 日本機械学会九州支部 九州支部・中国四国支部合同企画 沖縄講演会 講演論文集, No.78-2, pp.155-156, 2007
- [13] 濱田正広, 久保和也, 佐藤公信, 竹田史章, 井上啓史, “臨床情報を用いたニューラルネットワークによる医療画像診断システムの提案”, 第 50 回システム制御情報学会研究発表講演会講演論文集, pp.633-634, 2007
- [14] Simon Haykin, “Neural Networks a comprehensive foundation”, pp.83-84, 1998
- [15] Russell Beale, Tom Jackson, “ニューラルコンピューティング入門”, pp.76, 1993
- [16] 合原一幸, 銅谷賢治, 松葉育雄, 市橋秀友, 林勲, 徳永隆治, “ニューロ・ファジィ・カオス”, オーム社出版局, pp.1-37, 1993
- [17] 荒井正之, 奥田健三, 渡辺博芳, 宮道壽一, “追加学習が可能な大規模ニューラルネット “ Honeycomb ネット ” ”, 電気学会論文誌 D- , Vol.J80-D- , No.7, pp.1955-1963
- [18] 荒井正之, 奥田健三, 宮道壽一, “Honeycomb ネットにおけるカテゴリ追加学習能力”, 電気学会論文誌 D- , Vol.J80-D- , No.1, pp.348-349
- [19] 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動作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誌, 第 5 巻, 第 3 号, pp.17-24, 2002
- [20] 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

参考文献

- [21] M. Nakahara, F. Takeda, K. Nakaura and Y. Yamamoto, “Propose of an Arm Behavior Recognition System with EMG and Neural Network”, The 1st International Conference on Mechatronics and Information Technology, pp.400-405, 2001
- [22] 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
- [23] 大津展之, 栗田喜多夫, 神田巖, “パターン認識-理論と応用-”, 朝倉書店, pp.1-6, 2000
- [24] Philip D. Wasserman, “ニューラルコンピューティング-上級編-”, 森北出版株式会社, pp.234-270, 1998
- [25] Marvin L.Minsky, Seymour A. Papert, “パーセプトロン”, パーソナルメディア株式会社, pp.285-326, 1993
- [26] 川原祥子, 笠原幸恵, 橋本真智子, 君島とし子, “ベットからの転落予防法 高さを考慮して”, 日本農村医学会雑誌, 51 巻, 3 号, pp.421, 2002
- [27] 戸羽勝味, 甲斐健児, 豊田章宏, 平松和嗣久, 箱田歳正, 古屋敷智恵美, 辻下守弘, “当院における転倒・転落症例の特徴とアセスメントシートの分析”, 広島理学療法学, 11 号, pp.60-65, 2002
- [28] 二見典子, “生地情報モニタ機能を備えた介護支援システム”, ホスピスケア, 14 巻, 1 号, pp.82-103, 2003
- [29] 生田悦子, 竹下秀之, 並河孝, 松尾洋史, 田久保興徳, 中村文紀, 劉和輝, 西久保芳樹, 仲川春彦, 池田識道, 平田順一, “当院における入院患者の転倒・転落予防のための実態調査”, 大津市民病院雑誌, 7 号, pp.26-30, 2006
- [30] 平田順一, 生田悦子, 池田識道, 河井美代子, 磯部阿湖美, 篠原久子, 栗林久子, 濱崎陽子, 加藤佐織, 竹下秀之, 田久保興徳, 劉和輝, 中村文紀, 西久保芳樹, 仲川春彦, “当院回復期リハビリテーション病棟における転倒転落の検討と予防啓発活動の実際”, 大津市民病院雑誌, 7 号, pp.22-25, 2006
- [31] 樋口有樹, 澤木由華, 佐々木栄理子, 高橋智香子, “転倒・転落防止対策 マニュアル導入前後の転倒・転落件数の変化について”, 函館中央病院医誌 8~9, pp.45-47, 2005

参考文献

- [32] 渡辺栄治, “パターン認識問題に対する階層型ニューラルネットワークの汎化能力改善学習法”, 電子情報通信学会論文誌 D, Vol.J79-D2, No.5, pp.917-923, 1996
- [33] 柴田克成, 岡部洋一, 伊藤宏司, “ニューラルネットワークを用いた Direct-Vision-Based 強化学習—センサからモータまで—”, 計測自動制御学会論文集 Vol.37, No.2, 2001
- [34] 岡田奈美, 浜本義彦, 岡村健史郎, “画像認識による患者の行動理解の試み”, 電子情報通信学会技術研究報告, Vol.103, No.738, pp.31-36, 2004
- [35] 佐藤公信, 竹田史章, “DSP ユニットを用いた手首動作識別システムの開発とそのマシンコントロールへの応用”, 日本知能情報ファジィ学会 インテリジェントシステム・シンポジウム, pp.71-76, 2004
- [36] 佐藤公信, 竹田史章, “ニューラルネットワークオンラインチューニング DSP の開発と, そのマシンコントロールへの適応”, 高速信号処理応用技術学会 2004 年研究会, pp.43-48, 2004
- [37] 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
- [38] 佐藤公信, 竹田史章, “プログラム可変型 DSP ボードの開発とそのニューラルネットワークへの応用”, 計測自動制御学会 SI 部門学術講演会, pp489-pp490, 2001
- [39] 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
- [40] 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
- [41] 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
- [42] 竹田史章, 大松繁, 井上卓, 尾波幸三, 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, pp.249-258, 1992

参考文献

- [43] 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
- [44] 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”, 電気学会論文誌, Vol.114-C, No.1, pp269-270, 1994
- [45] 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”, 電気学会論文誌, Vol.115-C, No.3, pp101-107, 1995
- [46] 辻敏夫, 福田修, 大塚彰, 金子真, “ニューラルネットワークを利用した EMG 制御型ポインティングデバイス”, 電気情報通信学会論文誌, Vol.J83-D- , No.10, pp2030-2039, 2000
- [47] “TMS320C3x/C4x デジタル・シグナル・プロセッサ ユーザーズ・マニュアル”, 日本テキサスインスツルメンツ株式会社, pp.12-24, 1997
- [48] “TMS320C3x/C4x オプティマイジング (最適化) C コンパイラ ユーザーズ・マニュアル”, 日本テキサスインスツルメンツ株式会社, pp.2-6, 1998
- [49] “TMS320C3x/C4x デジタルシグナルプロセッサ ユーザーズ・マニュアル”, 日本テキサスインスツルメンツ株式会社, pp.1-3-1-4, 1997
- [50] 瀬谷啓介, “DSP C プログラミング入門”, 技術評論社, pp.5-40, 1998
- [51] 三上直樹, “デジタル信号処理プログラミング入門”, CQ 出版社, pp.10-26, 1993
- [52] 大塚明, “サウンドクリエータのための電気実用講座”, pp.109-114, 1995
- [53] 麻生秀樹, “ニューラルネットワーク情報処理”, 産業図書, pp.13-46, 1994
- [54] 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
- [55] S.Nagata, M.Sekiguchi, K.Akagawa, “ Mobil Robot Control by Structured Hierarchical Neural Network”, IEEE Control System Magazine, pp.69-76, 1990
- [56] 末松良一, 山田宏尚, “画像処理工学”, pp.22-23, 2000

付録 A

本件に関する業績

雑誌論文

1. 佐藤公信, 竹田史章, 香川真也, “知的高速選別システムの独立駆動系による搬送系の実現”, 高速信号処理応用技術学会誌, 第9巻第1号, pp.42-47, 2005
2. 佐藤公信, 竹田史章, 東幸靖, 西蔭紀洋, “2次元高速フーリエ変換を特徴抽出に用いた知的高速選別システムの開発”, 高速信号処理応用技術学会誌, 第9巻第1号, pp.48-54, 2005
3. 佐藤公信, 竹田史章, 白石優旗, 池田理恵, “ニューラルネットワークを用いた起床検知システムの開発”, 電気学会論文誌 C, 11月号掲載決定

国際会議講演論文

1. Hironobu Satoh, Fumiaki Takeda, “Development of a Intelligent input Interface using EMG for MobileTerminal”, International Simulation and Gaming Association, pp.1078-1088, 2003, Chiba, Japan
2. Hironobu Satoh, Fumiaki Takeda, “Development of DSP unit for Online Tuning and Application to Neural Pattern Recognition System”, 8th International Conference on Knowledge-Based Intelligence Information & Engineering Systems, pp.866-873, 2004, Wellington, New Zealand
3. Hironobu Satoh, Fumiaki Takeda, Yoshihiro Saeki, Rie Ikeda, Yuhki Shiraishi, “Proposal of Awakening Behavior Detection System Using Neural Network”, The

Second IASTED International Conference on Computational Intelligence, pp164-169, 2006, San Francisco, USA

4. Hironobu Satoh, Fumiaki Takeda, “Examination of Awakening Behavior Detection System Using Online Tuning System”, The 7th International Conference on Optimization, Techniques and Applications, 2007, Kobe, Japan