

階層型ニューラルネットワークを用いた指紋認証システムの高性能化

2014年7月

田中 章浩

目次

| | | |
|--------------|---------------------------------------|-----------|
| 第 1 章 | 序論 | 1 |
| 1.1 | 研究の背景 | 1 |
| 1.2 | 研究の目的及び構成 | 4 |
| 第 2 章 | 指紋認証システムの構築と性能評価 | 5 |
| 2.1 | 序言 | 5 |
| 2.2 | 認証システム的设计 | 6 |
| 2.3 | 認証システムの構築 | 12 |
| 2.4 | 認証システムの汎化能力 | 15 |
| 2.5 | 結言 | 19 |
| 第 3 章 | マルチステップ型ニューラルネットワークによる認証部の性能評価 | 21 |
| 3.1 | 序言 | 21 |
| 3.2 | 認証部の設計 | 22 |
| 3.3 | 認証部の構築 | 25 |
| 3.4 | 認証部の汎化能力 | 28 |
| 3.5 | 認証システムの性能評価 | 33 |
| 3.6 | 結言 | 36 |
| 第 4 章 | 認証システムの高性能化 | 38 |
| 4.1 | 序言 | 38 |
| 4.2 | 異なる分割数によるシステムの高性能化 | 39 |
| 4.3 | アンサンブル学習 | 48 |
| 4.3.1 | アンサンブル学習とは | 48 |
| 4.3.2 | 汎化能力への影響 | 49 |
| 4.4 | 結言 | 61 |

| | |
|----------|----|
| 第 5 章 結論 | 63 |
| 謝辭 | 67 |
| 参考文献 | 68 |
| 研究業績 | 74 |

第 1 章

序論

1.1 研究の背景

ニューラルネットワーク（神経回路網）とは、広義には生体が行う情報処理や情報伝達を指し、狭義には人間の脳に見られるいくつかの機能を模倣して数学的に表し、コンピュータで再現した情報処理システムを指す。広義のニューラルネットワークは、ニューロン（神経細胞）とニューロン間を接合するシナプスで構成される。ニューロンの基本的な機能は、ニューロンに入力された刺激（情報）に応じて活動電位を発生（発火）させて他のニューロンに情報を伝達することである。1個のニューロンに対して複数のニューロンから情報を入力されたり、1個のニューロンが複数のニューロンに出力したり、活動電位がおきる閾値を変化させる事によって、情報を修飾したり、処理を行う。ニューロンは大きくわけて3つの部分から構成される [1]。それらは、他のニューロンから刺激（情報）を受ける樹状突起、細胞核がある細胞体、他のニューロンに出力する軸索である。シナプスはニューロンとニューロンの接合部に存在し、ニューロン間の刺激（情報）の伝達を行う。シナプスは、化学シナプスと電気シナプスと両方が混在する混合シナプスに分類される。化学シナプスは、軸索側にシナプス前細胞があり、樹状突起側にシナプス後細胞があり、その間の 20nm 程度の隙間にシナプス接着分子（カドヘリンやニューロリギン等の糖タンパク質）が満たされ、細胞が接着されている。このシナプス前細胞に刺激が達すると、神経伝達物質（アミノ酸、ペプチド、モノアミン等）がシナプス後細胞に放出され刺激が伝達する。電気シナプスは、シナプス前細胞とシナプス後細胞の間をイオン（カルシウムイオン等）が透過できる分子で接着され、細胞間に直接イオン電流が流れることで刺激が伝達される。狭義のニューラルネットワーク（以降は単にニューラルネットワークと呼ぶ）は、ニューロンとシナプスの基本的な動作を模倣した形式ニューロンで構成される。形式

ニューロンは、入力された情報に結合荷重（シナプスに相当する）を付加し、全ての入力を総和する。それを伝達関数と呼ばれる非線形関数に渡され、次の形式ニューロンに出力される。一般に、伝達関数にはシグモイド関数やステップ関数が用いられる。ニューラルネットワークには、2つの特徴がある。これらは超並列分散処理をすることと学習を行うことである。超並列処理は、ニューラルネットワークに何等かの入力があった場合に、複数の形式ニューロンが同時に動作し処理を行う。現状のノイマン型コンピュータではコンピュータの原理上直列に処理されるが、同時に動作する形式ニューロンを時間的に区切って直列処理することで擬似的に並列処理を行っている。学習は3種類に分類され、それらは、(1) 遺伝子による進化段階の学習、(2) ニューロンの結合網による発達段階の学習と(3) シナプスの変化による日常の学習である。これらの特徴により、ニューラルネットワークでは、パターン分類や連想記憶、関数近似等の従来のコンピュータでは苦手とした処理が高速で処理できる。そして、様々な分野で応用・研究 [2]～[23] されている。

一方、コンピュータや通信技術の発展に伴って様々なサービスが”個人”に提供されている。近年では、クラウドコンピューティングと呼ばれるインターネットベースのコンピュータ資源の利用が盛んである。”個人”にサービスを提供するにあたり、サービスを受ける”個人”を特定することは非常に重要なことである。また、情報化社会において、個人情報取り扱いに対してより高いセキュリティが求められている。これを実現するためには情報を取り扱う人を特定し、限定しなければならない。現在、個人を特定する方法にカード、ユーザー ID、パスワード等やそれらを組み合わせた方法が幅広く使われている。これらの方法は認証のためにカードの管理、ID やパスワードの記憶が必要である。よって、これらの認証方法には盗難や紛失、忘却等の様々な脆弱性がある。そのため、より高いセキュリティで誰でも扱い易い操作性を有する認証システムが必要である。そこで、バイオメトリクス認証 [24][25] が注目を集めている。

バイオメトリクスとは、”個人”の身体的または行動的な特徴のことで、具体的には指紋 [26]、掌紋 [27]、静脈 [28]、虹彩 [29]、網膜 [30]、顔 [31]、音声 [32]～[35]、筆跡 [36] 等がある。これらの特徴はいずれも長期間にわたって変化しにくく、類似する特徴を持つ第三者が極めて少ないという大きな利点を持っている。また、体に付随する認証なので、カード等のように管理する必要はなく、紛失、盗難の危険性も少ない。このバイオメトリクスに含まれる情報を用いて個人を認証することをバイオメトリクス認証と言う。バイオメトリクス認証の中でも特に指紋を用いた個人認証システムは、認証時の指紋画像の取得が容易であり、経年変化に強い等の特徴を持っている。

一般に、指紋認証システムは、① 指紋画像の取得部、② 指紋画像の前処理部、③ 本人を判定する認証部から構成される。① 取得部は、センサーにより指紋を読み取る部分で

ある。センサーには、光学式，感圧式，静電容量式等 [37] がある。② 前処理部は，① 取得部で取得した指紋画像に拡大，縮小，回転やエッジ強調等の処理 [26] を行って，認証部への入力パターンとする。③ 認証部は，認証される指紋のデータと事前にデータベースに登録されているデータを比較して，個人を特定する。指紋認証システムの研究では，これらの 3 つの部分毎に研究がなされている。その中でも，③ 認証部では，データベースに登録されているデータの中から，該当するデータを効率よく検索する手法がよく報告 [38] されているが，それ以外の報告はほとんどない。

認証部にニューラルネットワークを用いた指紋認証システムは今までに報告されてきた [39]。そこでは，ニューラルネットワークが”本人”と”他人”を明確に区別し，個人認証システムに有効であることを確認した。しかし，学習に使用する指紋の数が増加するとニューラルネットワークの収束が困難になる等の問題が生じた。また，心理的拒否感等が存在するため指紋を大量に収集することは容易ではなく，現実的でもない。さらに，指紋の数は，1 人あたり，手だけでも 10 個ある。世界の人口は約 70 億人であり，指紋は膨大な数となる。従って，指紋認証システムでは対象とする指紋の数に制限があり，大量の指紋を想定した認証システムに関する報告はない。

1.2 研究の目的及び構成

本研究では、大量に存在し、収集することが困難な指紋を、高速に分類するためにマルチステップ型のニューラルネットワークを認証部にもつ、指紋認証システムを設計・構築し、その性能を評価して、さらなる高性能化を行う。この認証システムは、前処理部で、指紋画像を分割し、マニューシャ法による特徴点の有無によって2値化した2次元画像から1次元数列を作成することによって、入力パターンを作成する。マルチステップ型になっているため、1ステップで扱う入力パターン数は少なくとも、システム全体では、大量の指紋を扱うことができる。

本章以降の構成は、第2章で指紋による本人認証システムを設計・構築する。第3章では、マルチステップ型のニューラルネットワークを認証部に持つ本人認証システムを設計・構築し、その性能を評価する。第4章では、実際の指紋を想定した問題に対してマルチステップ型のニューラルネットワークを持つ認証部を改良し、高性能化する。また、本人認証システムを拡張して個人認証システムの構築を行う。さらに、アンサンブル学習がニューラルネットワークの汎化能力に与える影響を明らかにする。第5章では、本研究で得られた研究成果を総括し、今後の課題に言及する。

第2章

指紋認証システムの構築と性能評価

2.1 序言

本章では、指紋のマニューシャによる特徴点を3階層ニューラルネットワークが分類する認証システムを設計して、指紋認証システムを構築した。また、その認証システムの性能を評価した。一般的に、指紋認証システムでは、事前にデータベースに登録した指紋の情報と認証するために入力された指紋の情報をマッチングし、その類似度で認証を行う。指紋認証の手法として、マニューシャ法 [40][41]、周波数解析法 [42]、テンプレートマッチング法 [43] がある。マニューシャ法は、指紋の中に含まれる特徴点（端点や分岐点等）を抽出し、特徴点の位置関係で個人（本人）を判定する。周波数解析法は、指紋の凹凸を関数と仮定し、指紋画像をフーリエ変換して得られるデータをマッチングする。テンプレートマッチング法は、指紋画像にたいして、一定の処理をした後、指紋画像を重ねあわせてマッチングを行う。テンプレートマッチング法では、データベースに指紋画像そのものを登録するため、データベースから情報が流出すれば、指紋画像が流出する危険がある。この指紋画像を用いれば、指紋認証システムに対して本人だと誤認させることができる。また、周波数解析法では、データベースには、指紋画像は保存されていないが、保存されている情報から元の指紋画像に近い画像が作成される可能性がある。マニューシャ法では、特徴点の相対的な位置情報のみが保存されているため、情報流出した際の危険は少ない。さらに、同じ指紋から得られた指紋画像であれば、同じ情報が得やすい。そのため、市販されている指紋認証システムによく採用されている。また、警察で行われている指紋鑑定もマニューシャ法であるため信頼性が高い。

2.2 認証システムの設計

指紋認証システムとは、指紋で個人を特定するシステムのことである。特に、1つの認証システムで1人を特定することを本人認証、複数人を特定することを個人認証と言う。

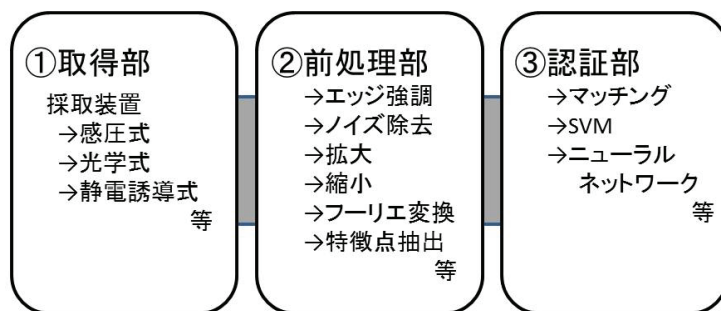


図 2.1 一般的な指紋認証システムの構成

図 2.1 は、一般的な指紋認証システムを示している。指紋認証システムは、① 取得部、② 前処理部、③ 認証部の 3 つの部分に分けられる。① 取得部は、指紋取得装置により、指から指紋画像を取得する部分である。指紋取得の手法は、感圧式、光学式、静電誘導式等がある。これらの方式は様々な長所や短所があるが、どの方式でも確実に指紋を取得することはできない。取得毎に、指紋の回転、位置移動等で指紋画像は異なり、指の同じ位置を取得できるとは限らない。指紋画像は 2 次元であるが、指は 2 次元ではなく膨らみがあり、指を取得装置に押し付ける圧力によって指紋画像は形し歪む。さらに、取得状況によっては指と取得装置の間に埃などが入りそれがノイズとなる。これらの影響がなく、指紋の取得の際に同じ人の同じ指の指紋が確実に取得することができれば、どの様な手法を用いても個人認証は容易にできるが取得部でそれを実現するのは現実的ではない。

② 前処理部は、指紋画像に対して処理を行い認証部への入力パターンを作成する部分である。具体的には、指紋画像に対して、拡大、縮小、回転、エッジ強調、2 値化等を行い、基準に沿った指紋画像にする。周波数解析法では、さらに指紋画像にフーリエ変換を行い入力パターンを作成する。マニューシャ法では、指紋画像に含まれる特徴点を抽出し、その位置関係を入力パターンとして用いる。

③ 認証部は、前処理部で得られた入力パターンを元にして、個人を判定する部分である。判定には、データマッチングが用いられることが多いが機械学習を用いる場合があ

る。機械学習には、サポートベクターマシン (SVM) [55][56] やニューラルネットワーク [46]~[52] がある。これらは、学習機会と呼ばれる。SVM とニューラルネットワークは、事前に提示された複数の入力パターン (学習パターン) により機械学習を行う。その結果を用いて、認証時の入力パターン (テストパターン) を認証する。例えば、本人認証は学習で得られた境界でテストパターンを本人と他人に分類する。境界は学習パターンに従って決められる。SVM の場合は、全ての学習パターンに対して最大の距離を持つ分類の境界 (マージンの最大化) が決定される。学習パターンが不変なパターンで分類する集団から偏ることなくパターンを得られる場合は、SVM が有効である。しかし、学習パターンが分類する集団から偏ることなく選ばれている保証はない。従って、マージンの最大化が認証率の向上に寄与するとは限らない。ニューラルネットワークの学習で得ることできる分類の境界は、学習時のニューラルネットワークの初期値によって学習毎に変わる。そのため、学習毎にテストパターンに対しての認証率は異なる。しかし、高い認証率をもつニューラルネットワークができる可能性がある。ニューラルネットワークと SVM 共に、学習に用いるパターンの数が多くなるほど認証率が高くなる。しかし、学習パターンを集めることは容易ではない。また、学習パターンが多くなると、学習に必要となる時間が増える。そのため、なるべく少ないパターンで学習することができればよい。従って、少ない学習パターンでも高い認証率となる可能性があるニューラルネットワークは認証システムに向いている。

図 2.2 は、本研究で使用したバックプロパゲーション法 [44] による 3 階層型のニューラルネットワークを示している。図に示されるように、このニューラルネットワークは入力層、中間層、出力層の 3 層から構成されており、各層は形式ニューロンとよばれるユニットで構成されている。また、出力層ユニットに教師信号を与えることにより出力値を教師信号の値に近づけるように結合荷重を変更することができる。

入力層と中間層は複数の形式ニューロンから、出力層は 1 つの形式ニューロンで構成される。形式ニューロンは、入力された全ての値を合計し、それに応じて値を出力する。入力層の全て形式ニューロンは中間層の全ての形式ニューロンと形式シナプスで結合される。同様に、中間層の全ての形式ニューロンは出力層の全ての形式ニューロンと形式シナプスで結合される。形式シナプスは、前層の形式ニューロンから出力された値に対して、結合荷重を乗算し、その値を次層の形式ニューロンに出力する。これ以降は、入力層ユニット数-中間層ユニット数-出力層ユニット数をニューラルネットワークのサイズと呼ぶ。学習パターンには、本人の入力パターンであれば「1」、他人の入力パターンであれば「0」を教師信号として与えた。教師信号とニューラルネットワークからの出力値との誤差

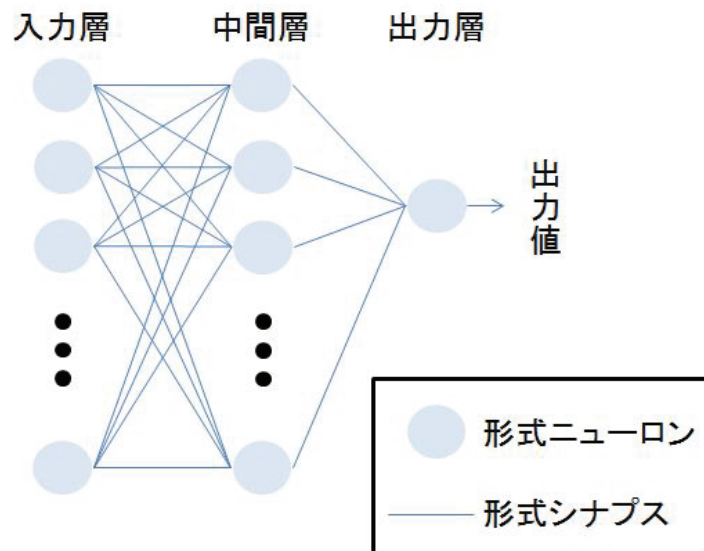


図 2.2 本研究で使したバックプロパゲーション法による 3 階層型ニューラルネットワーク

二乗和を減少させるため、次式を用いて各ユニット間の結合荷重の更新を繰り返した。

$$\Delta w_{kj}(n) = -\eta \frac{\partial E}{\partial w_{kj}(n)} + \alpha \Delta w_{kj}(n-1) \quad (2.1)$$

ここで、 $\Delta w_{kj}(n)$ は学習 n 回後における形式ニューロン k と形式ニューロン j の間の結合荷重の更新量、 η は学習係数、 E は教師信号と出力層ユニットの誤差二乗和、 α は慣性係数、 $\Delta w_{kj}(n-1)$ は学習 $(n-1)$ 回後における結合荷重の更新量を表している。ニューラルネットワークは、1つの数字に対して1つの入力層ユニットが対応するようにニューラルネットワークを構成した。よって、ニューラルネットワークの入力層ユニット数は分割数と同じになる。また、出力層ユニット数が1つなので、このユニットの出力値がニューラルネットワークの出力値となる。従って、出力層ユニットの出力値を、ニューラルネットワークの出力値と呼ぶ。

図 2.3 は、本研究で使した指紋取得装置を示している。この指紋取得装置から得られる画像の大きさは 256×384 画素であり、指紋の実寸は $16 \times 24\text{mm}^2$ である。指紋画像は取得時の状況により並行移動や回転等の位置ズレを起し、必ず同じ位置に存在するとは限らない。そこで、指紋画像を一定の大きさの領域に分割した。領域内での特徴点の有



図 2.3 指紋取得装置 (EZF-650)

無によって 2 値化し、ニューラルネットワークの入力パターンとした。

図 2.4 は、ニューラルネットワークに入力するパターンの作成手順を示している。入力パターンは、指紋画像から特徴点を抽出して作成した。ここでの、特徴点は、端点と呼ばれる指紋の隆線が途切れている点と分岐点と呼ばれる隆線が分岐する点である。図 2.4(a) に、指紋画像を $4 \times 4 = 16$ の領域に分割した例を示す。実際の実験では、指紋画像を $8 \times 12 = 96$ や $16 \times 24 = 384$, $32 \times 48 = 1536$ に分割した。次に、図 2.4(b) に示されるように、1 つの分割領域に特徴点が存在すれば「1」を、存在しなければ「0」を与えて指紋画像を 2 値化した。最後に、図 2.4(c) に示されるように、図 2.4(b) の数字を行単位で上から下に順番に並べてニューラルネットワークの入力パターンとした。この処理で指紋画像は、「0」と「1」で構成される 1 次元数列となる。このように処理した入力パターンを用いて、ニューラルネットワークの学習を行った。学習パターンとして、本人は 1 人で 1 パターン、他人は 5 人で計 5 パターンを用いた。テストパターンとして、本人に類似したパターンを用いた。このパターンは本人の指紋画像に存在する特徴点の位置を隣接する領域に移動したパターンである。移動した特徴点の数で本人のパターンとの類似度が変わ

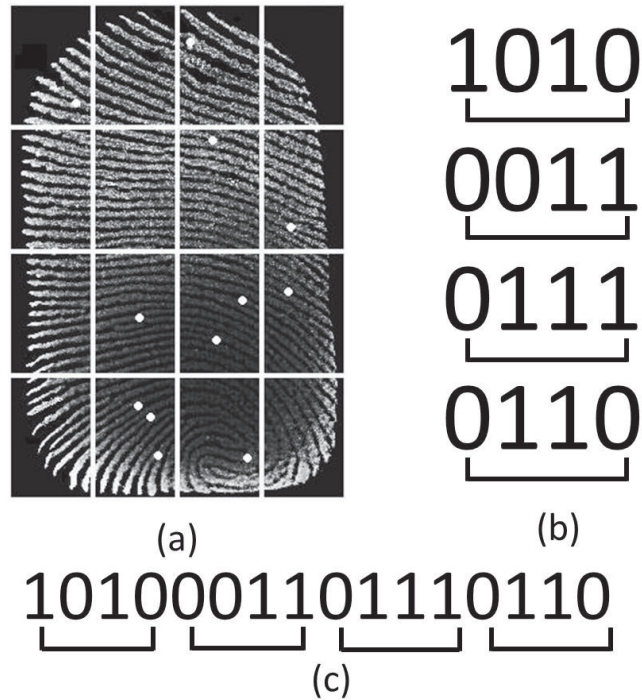


図 2.4 ニューラルネットワークに入力するパターンの作成手順

(a) 分割した指紋 (白点は特徴点を示す。)

(b) 2 値化した指紋

(c) ニューラルネットワークに入力するパターン

る。本研究では、指紋画像から 10 点の特徴点を抽出した。テストパターンの移動方法は以下のとおりである。

- 1 点の特徴点を 4 方向 (上下左右) に移動
- 10 点の特徴点の組み合わせで 1023 通り

従って、テストパターンは 4092 セットとなる。

表 2.1 にニューラルネットワークの各種パラメータを示す。本研究では、中間層数は 1、出力層ユニット数は 1、学習終了条件の誤差 2 乗和を 0.0001 とし、中間層ユニット数は、入力層ユニット数と同じとした。一般的に適用する問題に応じて、最適なニューラルネッ

表 2.1 ニューラルネットワークの各種パラメータ

| | |
|------------------|-------------|
| 入力層ユニット数 | 96,384,1536 |
| 中間層数 | 1 |
| 中間層ユニット数 | 96,384,1536 |
| 出力層ユニット数 | 1 |
| 学習係数 | 0.05~0.6 |
| 慣性係数 | 0.05~0.6 |
| 学習終了条件 (誤差 2 乗和) | 0.0001 |

トワークのパラメータは異なる。ここで、最適とは、ニューラルネットワークの収束速度や汎化能力等が良好であることを意味する。図には示さないが、学習係数及び慣性係数は、誤差 2 乗和が終了条件以下で収束する確率 (収束率) を基準に最適化した。その結果から、学習係数及び慣性係数が共に 0.2 の場合に、良好な収束率となった。以下の実験では、学習係数及び慣性係数は共に 0.2 を使用している。

2.3 認証システムの構築

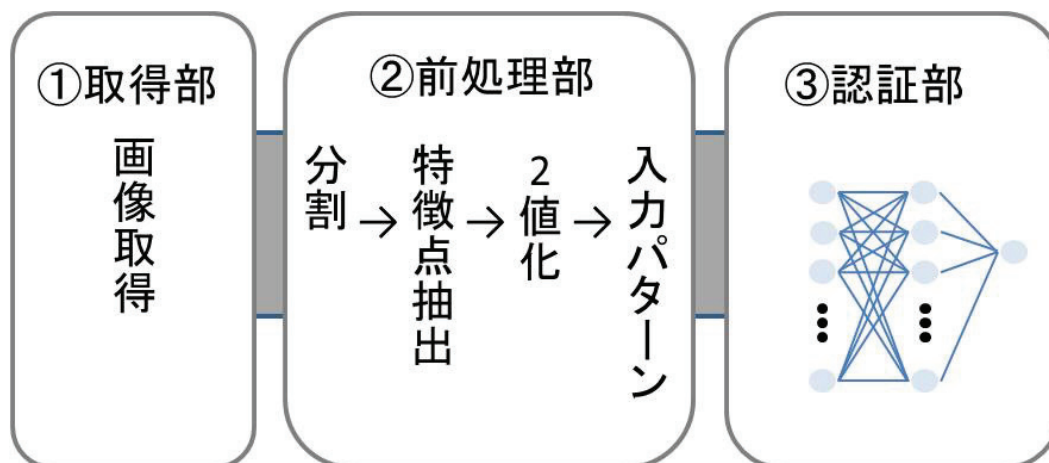


図 2.5 構築した認証システム

図 2.5 は、構築した認証システムを示す。認証システムは、3つの部分から構成されている。取得部で指紋画像を得る。前処理部で指紋画像から入力パターンを得て、認証部のニューラルネットワークの出力値で認証を行う。

図 2.6 は、学習回数に対するニューラルネットワークの誤差 2 乗和を示している。X 軸は学習回数を示しており、Y 軸はニューラルネットワークの誤差 2 乗和を表している。ここで、ニューラルネットワークのサイズは 384-384-1 である。図に示されるように、学習回数が増加するに従って誤差 2 乗和は減少した。しかし、学習の終了条件である誤差 2 乗和に達することがなく、学習が終了しない場合もある。この場合、作成されたニューラルネットワークは正しく分類が行えない場合がある。この結果より、終了条件である誤差 2 乗和に達したニューラルネットワークは収束している。以降の実験は、誤差 2 乗和が終了条件に達したニューラルネットワークのみを使用する。

図 2.7 は、学習パターンで認証を行った場合の等価エラー率 (Equal Error Rate : EER) を示している。ここでの、X 軸はニューラルネットワークの閾値を、Y 軸は誤認率を表している。凡例は、他人受入率 (False Acceptance Rate : FAR) と本人拒否率 (False Rejection Rate : FRR) を表している。図に示されるように、FAR は閾値 0 以外は誤認率 0% を示し、FRR は閾値 1 以外は誤認率 0% を示した。これらのことより、閾値が 0.1




図 2.6 学習回数に対するニューラルネットワークの誤差 2 乗和

～0.9 の範囲で FAR と FRR が共に誤認率 0% となった。従って、学習パターンに対してニューラルネットワークは正しく認証ができています。

図 2.6 と図 2.7 の結果より、ニューラルネットワークは、学習で誤差 2 乗和が終了条件以下に収束し、学習パターンに対して正しく認証したので、ニューラルネットワークは正常に動作している。従って、ニューラルネットワークを認証に持つ認証システムを構築できた。




図 2.7 学習パターンの EER

2.4 認証システムの汎化能力




図 2.8 移動した特徴点の数に対するニューラルネットワークの出力値（入力層ユニット数が異なる場合）

図 2.8 は、移動した特徴点の数に対するニューラルネットワークの出力層ユニットの出力値を示している。ここでは、入力層ユニット数は 96～1536 まで変化させて実験を行った。入力層ユニット数の違いによる出力値の影響を明らかにするために、指紋画像を分割する際に、1つの領域の大きさを 32×32 画素、 16×16 画素、 8×8 画素として実験を行なったので、入力層ユニット数はそれぞれ 96, 384, 1536 となる。図の X 軸は移動した特徴点の個数（本人パターンとの類似度）、Y 軸はニューラルネットワークの出力値を表している。図に示されるように、移動した特徴点の個数が増加するに従って出力値も減少した。また、入力層ユニット数の違いに注目してみると入力層ユニット数が 96 の場合が他の場合と比べて出力値が高くなった。これは他の場合と比べて入力層ユニット数が 96 の場合はニューラルネットワークの分類性能が低いためであると考えられる。入

力層ユニット数が 384 と 1536 の結果を比較してみると、移動した特徴点の数に対するニューラルネットワークの出力値には際立った変化は見られなかった。故に、学習時間が短い入力層ユニット数 384 が最も良いことがわかった。また、この時の画像ユニットの大きさは 16 × 16 ピクセルであり、これは指紋の凹凸の 1~2 個に相当し、取得時のズレの許容値としても妥当であると考えられる。




図 2.9 移動した特徴点の数に対するニューラルネットワークの出力値（特徴点の移動距離が異なる場合）

図 2.9 は、移動した特徴点の数に対するニューラルネットワークの出力値を示している。ここでは、テストパターンの作成時に特徴点の移動距離を 16 ピクセル~48 ピクセルに変化させて実験を行った。図の X 軸は移動した特徴点の個数、Y 軸はニューラルネットワークの出力値を表している。図に示されるように、移動した特徴点の個数が増加するに従って出力値も減少した。しかし、移動距離が増加しても出力値の減少の大きさは変化していなかった。これらの結果より、本認証システムは特徴点の位置が学習時の位置にあるかないかで出力値が決まり、移動距離に依存してしないことがわかる。

図 2.10 は、移動した特徴点の数に対するニューラルネットワークの出力値を示してい




図 2.10 移動した特徴点の数に対するニューラルネットワークの出力値（学習時の他人の数が異なる場合）

る。ここでは、学習時に他人とした人数を 5 人～15 人に変化させて実験を行った。図の X 軸は移動した特徴点の個数、Y 軸はニューラルネットワークの出力値を表す。図に示されるように、他人とする人数が多いほど出力値は大きく減少した。この結果は、学習時に他人パターンが多いほど、テストパターンに対してのニューラルネットワークの出力値が低いことを示している。すなわち、学習時の他人パターンが多いほど、本人とテストパターン（本人に類似するパターン）の差が大きくなることを示している。よって、他人とする指紋の数が多いほど本人認証には良いと考えられる。

図 2.11 は、移動した特徴点数に対するニューラルネットワークの出力値を示している。ここでは、テストパターンとして本人に類似したパターンだけでなく、他人に類似したパターンも追加して実験を行った。図の X 軸は移動した特徴点の個数、Y 軸はニューラルネットワークの出力値を表している。この実験でのテストパターンは、本人パターンと同様に他人パターンの特徴点を移動したパターンも含む。図に示されるように、他人指紋は移動した特徴点の数が増加してもニューラルネットワークの出力値は増加しなかった。こ




図 2.11 特徴点の数に対するニューラルネットワークの出力値（テストパターンとして本人と他人に類似したパターンを用いた場合）

これらのことより，他人に類似したパターンは，本人パターンを超えるニューラルネットワークの出力値を持たないことがわかった。従って，本認証システムは指紋認証に用いることができる。

2.5 結言

指紋による本人認証システムを設計・構築し、その性能を評価した。この認証システムは、取得部、前処理部、認証部からなっている。取得部では、機器を用いて指紋画像を取得した。前処理部では指紋画像を分割し、マニューシャ法による特徴点の有無によって2値化した2次元画像から1次元数列を作成することによって、入力パターンを作成した。認証部に、バックプロパゲーション学習則の3階層ニューラルネットワークを用いた。

この認証システムの性能は、前処理部の前処理法と認証部のニューラルネットワークの性能に依存する。特に、ニューラルネットワークの性能は、学習パターンや未学習パターンやニューラルネットワークパラメータ、例えば、学習係数、慣性係数、終了条件、ニューラルネットワークのサイズに大きく依存する。

出力層ユニットの出力値を「0」か「1」にする学習パターンを用いて、認証部のニューラルネットワークを学習した。つまり、ニューラルネットワークの結合荷重（入力層→中間層）（中間層→出力層）を決定した。言い換えれば、ニューラルネットワークの出力値は、「1」の値を示す学習パターンを入れると「1」となり、「0」の値を示す学習パターンを入れると「0」となるようにニューラルネットワークの結合荷重を変更した。学習の過程は、学習パターンに対して、ニューラルネットワークの出力値と教師信号との誤差2乗和が減少し、収束すること及び認証率が学習パターンで期待される出力値と一致する、つまり、本人拒否率と他人受入率が共に0となる領域があることでニューラルネットワークの構築が証明される。本認証システムのニューラルネットワークは、学習の進行に従って誤差2乗和が減少し、終了条件以下の値で収束した。また、学習パターンを認証した結果から、本人拒否率と他人受入率が共に0となる領域があった。これらのことより、ニューラルネットワークが構築できた。

本人パターンから「1」の位置を移動したパターンをテストパターンとして、ニューラルネットワークの汎化能力を調査した。テストパターンは、本人の指紋に似た他人の指紋である。テストパターンの移動した点数が本人パターンとの類似度を表している。テストパターンは、他人パターンなのでニューラルネットワークの出力値は0付近となることが望ましい。このテストパターンを用いて、認証実験を行った結果から、ニューラルネットワークの出力値は、移動した特徴点の数の増加に対して減少することがわかった。しかし、移動した特徴点の数が少ない場合、そのニューラルネットワークの出力値は本人パターンのニューラルネットワークの出力値とあまり差がない。この原因は、入力パターンのほとんどが「0」で構成されているためと考えられる。つまり、指紋の分割数が384の

場合、374個の「0」と10個の「1」で構成されているため、「1」が1, 2個移動しても、全体的に大差がないためである。この問題に対して、分割数を少なくしたり、用いる特徴点を増加させるなどの方法により解決できると考えられる。これらのことより、移動した特徴点の数の増加に対してニューラルネットワークの出力値は減少しているため、認証システムとしては用いることができる。しかし、1つの特徴点が移動しても、ニューラルネットワークの出力値があまり変化していないため、このニューラルネットワークでは特徴点の位置精度が悪い。また、ここまで、テストパターンには、本人パターンに似たパターンを用いたが、テストパターンに用いていないパターンは大量に存在する。そのため、テストパターンを用いて、本認証システムの認証率を求めてもあまり意味がない。さらに多くのパターンを用いて、高精度な認証率を求める必要がある。

第3章

マルチステップ型ニューラルネットワークによる認証部の性能評価

3.1 序言

本章では、認証部にマルチステップ型のニューラルネットワークを持つ認証システムを構築し、その性能を評価した。この認証システムの取得部と前処理部は、第2章で用いた認証システムと同様である。認証部は大分類と小分類を行うマルチステップ型のニューラルネットワークを用いている。マルチステップ型のニューラルネットワークを用いているため、1ステップに用いられているニューラルネットワークのサイズは小さく、学習や認証時の計算リソースが小さい。本人認証システムでは、入力された指紋を本人か他人に分類する。そのため、他人の指紋が入力された場合には、それを排除しなければならない。指紋はバイオメトリクスなので、その数は世界人口より多い。大量の指紋を、高速に分類するにはマルチステップ型のニューラルネットワークは、計算リソースが小さいので適している。マルチステップ型のニューラルネットワークは第2章で構築した指紋認証システムの位置精度や認証率の問題を解決できる。また、入力パターンは2値の1次元パターンなので0と1を組み合わせることで全ての入力パターンを生成できる。全てのパターンを用いての認証実験を行うことにより、全ての入力パターンのニューラルネットワークの出力値を得ることができ、正確な認証率を求めることが可能である。

3.2 認証部の設計

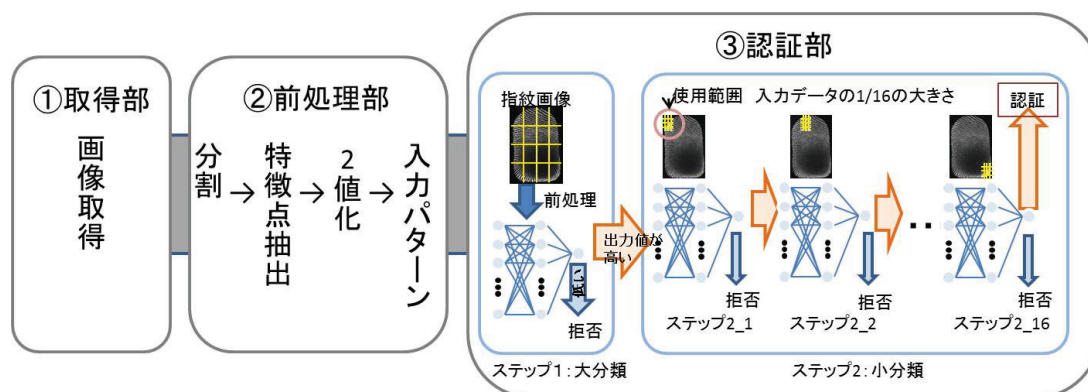


図 3.1 認証システムの構成

図 3.1 は、認証システムの構成を示している。この認証システムは、取得部で指紋画像を得た後、前処理部で指紋画像を 16 の領域に分割し、領域ごとに特徴点抽出を行って特徴点の有無で 2 値化する。そして、1 次元数列に変換して認証部への入力パターンと作成し、認証部で本人か他人に分類する。前処理部で指紋は 16 分割される。認証部はマルチステップとなっているので、最終的には、指紋画像を 256 分割した場合と同じになる。この場合の、1 つの分割領域の大きさは、指紋の隆線（凹凸）は 1~2 本程度の大きさとなる。指紋を扱う際の最小単位は隆線の太さなので、この分割数は妥当である。

図 3.2 は、本研究で提案される認証システムの認証部を示している。認証部では、複数のニューラルネットワークを用いて”本人”と”他人”を区別する。1 つのステップは、複数のニューラルネットワークからなり、各ニューラルネットワークは入力パターンを処理し、値を出力する。そして、すべてのニューラルネットワークの出力値を平均して、1 ステップの出力値となる。その出力値は事前に設定した閾値と比較され、”本人候補”と”他人”に分類される。”本人候補”に分類された指紋画像は、次のステップに進む。ステップ 1 では、指紋画像を 16 分割して入力パターンとしている。ステップ 2 では、ステップ 1 で 16 分割された指紋画像の 1 つを更に 16 分割した入力パターンを用いる。従って、ステップ 2 は 16 個のニューラルネットワークから構成される。それぞれのニューラルネットワークをステップ 2.1, ステップ 2.2, … ステップ 2.16 と呼ぶ。ステップ 2 のニュー

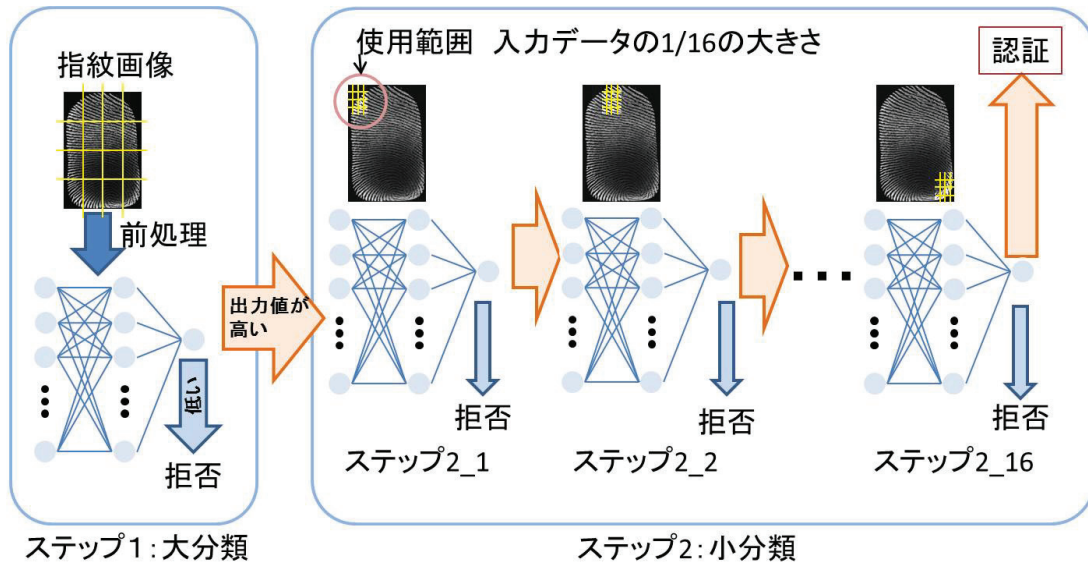


図 3.2 指紋認証システムの認証部

ラルネットワークでは、入力パターンはステップ1のニューラルネットワークと同様に処理され、小分類される。ここで「本人候補」に分類されたパターンは、次のステップへと進む。この様にして次々と分類する。指紋画像を16分割している、すなわち入力層ユニット数が16であるため、前章の図2.8より、本人に類似したパターンのニューラルネットワークの出力値は高い値となることが予想できる。そのため、1ステップには20個のニューラルネットワークを用い、それらの出力値にアンサンブル学習 [57]～[63] を行ってステップの出力値としている。ここ以降、「アンサンブル学習（単純平均）を行う」ことを、単に「アンサンブルする」と表記する。入力パターンは前章での作成方法と同様に処理して作成される。本章では、前章のように特徴点の数は指定していない。前章では、テストパターンに本人のパターンに類似したパターンを用いた。前章でも、入力パターンは「0」と「1」の数列であるので、その全パターンは組み合わせることが可能である。しかし、96分割でも 2^{96} となり、約 1.6×10^{29} 通りとなる。この数に比べて前章のテストパターンは、あまりにも少ないまた、本人パターンのニューラルネットワークの出力値が、全パターン中最大となる保証はない。 $4 \times 4 = 16$ に分割した場合では、全てのパターンをテストに用いることができる。この場合、全てのパターンは65536パターンとなる。このことによって、高い精度で認証率を求めることができる。この実験においても、ニューラル

ネットワークの学習パターンとして教師信号「1」を与える”本人”を1パターン、「0」を与える”他人”を5パターンの計6パターンを用いた。学習パターンはランダムに決定した。残りの65530パターンは、テストパターンとしてニューラルネットワークの認証実験で用いる。従って、テストパターンはすべて未学習パターンである。ニューラルネットワークの性能評価には、認識率を用い、以下の式で定義した。

$$\text{認識率} [\%] = \frac{\text{正しく認証したパターン数}}{\text{テストパターンの総数}} \times 100 \quad (3.1)$$

また、認証部のステップは直列に接続されているため、認証率は接続数に対して累乗となると考えられる。一般的にニューラルネットワークのパラメータの最適化は、ニューラルネットワークが収束するまでの学習回数や誤差2乗和の値によって行われる。しかしながら、本研究ではテストパターンが極めて多いので、認証率に対するニューラルネットワークのパラメータの影響を明らかにする必要がある。

3.3 認証部の構築

ニューラルネットワークを用いた分類では、本人に類似したパターンが本人パターンの出力値に近い値となるが、他のパターンのニューラルネットワークの出力値がどのような値になるのかわからない。よって、すべてのパターンをテストパターンに用いなければ、正しい認証率はわからない。本認証システムでは、指紋画像を「0」と「1」の組み合わせでパターン化しているので、 N 分割した場合の全パターン数は 2^N となる。しかし、 N が大きくなればテストに用いるパターンが膨大になり、現実的ではない。そこで、 $N=4$ とした。




図 3.3 学習回数に対するニューラルネットワークの誤差 2 乗和

図 3.3 は、学習パターンを用いた場合の学習回数に対するニューラルネットワークの誤差 2 乗和を示している。ここでは、中間層ユニット数、慣性係数、学習係数及び終了条件はそれぞれ 16, 0.2, 0.2, 10^{-4} である。図に示されるように、学習回数が増加すると、ニューラルネットワークの誤差 2 乗和は単調に減少した。これらの結果より、ニューラル

ネットワークは学習パターンに対して正常に学習が終了していることがわかった。




図 3.4 学習パターンの EER

図 3.4 は、学習パターンで認証を行った場合の EER を示している。ここでの、X 軸はニューラルネットワークの閾値を、Y 軸は誤認率を表している。図に示されるように、FAR は閾値 0 以外は誤認率 0% を示し、FRR は閾値 1 以外は誤認率 0% を示した。これらのことより、閾値が 0.1~0.9 の範囲で FAR と FRR が共に誤認率 0% となったので、学習パターンに対してニューラルネットワークは正しく認証ができています。

図 3.3 と図 3.4 の結果より、ニューラルネットワークは、学習で誤差 2 乗和が終了条件以下に収束し、学習パターンに対して正しく認証したので、ニューラルネットワークは正常に動作している。従って、ニューラルネットワークを認証に持つ認証システムを構築できた。

表 3.1 は、学習パターンに対して本研究で用いたニューラルネットワークの各種パラメータを示している。表に示されるように、ニューラルネットワークの入力層ユニット数は 16、中間層ユニット数は 16~80、出力層ユニット数は 1 とした。また、学習係数と慣性係数は 0.1~0.5、学習の終了条件のニューラルネットワークの誤差 2 乗和は 10^{-2} ~

表 3.1 ニューラルネットワークの学習パラメータ

| | |
|-------------------|------------------------|
| 入力層ユニット数 | 16 |
| 中間層ユニット数 | 16~80 |
| 出力層ユニット数 | 1 |
| 慣性係数 (α) | 0.1~0.5 |
| 学習係数 (η) | 0.1~0.5 |
| 終了条件 (誤差 2 乗和) | $10^{-2} \sim 10^{-6}$ |

10^{-6} を用いた。これらのパラメータを用いたニューラルネットワークの結果は図には示されないが、図 3.3 の結果と同様に、ニューラルネットワークの誤差 2 乗和は学習回数の増加と共に減少した。さらに、図 3.4 に示されたように学習パターンに対する認証結果においても本人と他人を明確に区別することができた。

3.4 認証部の汎化能力

テストパターンを用いてステップ1のニューラルネットワークのパラメータが認証の性能に与える影響を調べた。ステップ2のニューラルネットワークはステップ1のニューラルネットワークと同じニューラルネットワークサイズである。これ以降の実験結果は全てテストパターンに対するもので、ニューラルネットワークの汎化能力を調べたことになる。




図 3.5 閾値に対する認証率（中間層ユニット数が異なる場合）

図 3.5 は、閾値に対するステップ1の認証率を示している。ここでは、中間層ユニット数は16～80を用いた。図に示されるように、ステップ1の認証率は閾値と共に増加した。閾値が0～0.1の範囲では急激に増加し、0.1～1の範囲では緩やかに増加した。また、閾値が0.1～0.9の範囲ではステップ1の認証率は中間層ユニット数と共に増加する傾向が観測された。

表 3.2 は、中間層ユニット数に対するステップ1の認証率を示している。表に示される

表 3.2 中間層ユニット数に対するステップ 1 の認証率（異なる閾値の場合）

| 中間層ユニット数 | 閾値 | | |
|----------|--------|--------|--------|
| | 0.2 | 0.5 | 0.98 |
| 16 | 75.450 | 89.175 | 99.991 |
| 32 | 76.721 | 90.689 | 99.989 |
| 48 | 76.602 | 90.913 | 99.992 |
| 64 | 77.404 | 91.496 | 99.994 |
| 80 | 78.457 | 92.203 | 99.994 |

ように、ステップ 1 の認証率は閾値が 0.2 と 0.5 の場合、中間層ユニット数と共に増加する傾向にある。閾値が 0.98 の場合、中間層ユニット数に関わらずほぼ一定であった。中間層ユニット数が 16 から 80 に増加するとき、ステップ 1 の認証率は閾値によって中間層ユニット数の依存性が異なることがわかった。しかしながら、本ニューラルネットワークでは閾値を 0.98 に設定するので中間層ユニット数の最適値は計算量が最少となることを考慮して最少の中間層ユニット数 16 とした。

図 3.6 は、閾値に対するステップ 1 の認証率を示している。ここでは、慣性係数に 0.1～0.5 を用いた。図に示されるように、ステップ 1 の認証率は閾値と共に増加した。ニューラルネットワークのパラメータである慣性係数が 0.1～0.5 まで変化した時、ステップ 1 の認証率は慣性係数に依存しなかった。ステップ 1 の認証率の観点から最適な慣性係数の範囲は 0.1～0.5 となることがわかる。

図 3.7 は、閾値に対するステップ 1 の認証率を示している。ここでは、学習係数に 0.1～0.5 を用いた。図に示されるように、ステップ 1 の認証率は閾値と共に増加した。ニューラルネットワークのパラメータである学習係数が 0.1～0.5 まで変化した時、ステップ 1 の認証率は慣性係数に依存しなかった。ステップ 1 の認証率の観点から最適な学習係数の範囲は 0.1～0.5 となることがわかる。

図 3.8 は、閾値に対するステップ 1 の認証率を示している。ここでは、終了条件に 10^{-2} 、 10^{-4} 及び 10^{-6} を用いた。図に示されるように、ステップ 1 における閾値に対する認証率の振る舞いは終了条件に依存した。閾値が 0～0.25 の範囲では、ステップ 1 の認証率は終了条件が増加すると認証率は減少した。一方、閾値が 0.25～1 の範囲では、ステップ 1




図 3.6 閾値に対するステップ 1 の認証率 (慣性係数が異なる場合)

の認証率は終了条件と共に増加した。しかしながら、終了条件が 10^{-2} の時、閾値に対するステップ 1 の認識率の振る舞いは 10^{-4} や 10^{-6} の振る舞いと大きく異なった。

図 3.9 は、終了条件に対するステップ 1 の認証率を示している。ここでは、閾値に 0.2 ~ 0.98 を用いた。図に示されるように、閾値が 0.20 の場合、ステップ 1 の認証率は終了条件の増加と共に減少した。閾値が 0.5 と 0.98 の場合では、終了条件が増加すると共にステップ 1 の認証率は増加した。図 3.8 と 3.9 より、終了条件の最適値は計算量が最少となる 10^{-4} とした。




図 3.7 閾値に対するステップ 1 の認証率 (学習係数が異なる場合)




図 3.8 閾値に対するステップ 1 の認証率 (終了条件が異なる場合)




図 3.9 終了条件に対するステップ 1 の認証率 (閾値が異なる場合)

3.5 認証システムの性能評価




図 3.10 閾値に対するステップ 1 の認証率（最適パラメータを用いて学習したニューラルネットワークを用いた場合）

これまでの最適なニューラルネットワークのパラメータを用いてステップ 1 を構築し、認証実験を行った。図 3.10 は、最適パラメータを用いて学習したニューラルネットワークを用いた場合の閾値に対するステップ 1 の認証率を示している。ここでは、学習パラメータは中間層ユニット数、慣性係数、学習係数、終了条件はそれぞれ 16, 0.2, 0.2, 10^{-4} である。図に示されるように、ステップ 1 の認証率は閾値と共に急激に増加し、その後緩やかに増加した。

図 3.11 は、最適パラメータを用いて学習したニューラルネットワークの当誤り率 (Equal Error Rate : EER) を示している。ここでは、他人受入率 (False Acceptance Rate : FAR) と本人拒否率 (False Rejection Rate : FRR) を示している。図に示されるように、FRR においては閾値が 0.982 以下で 0% を示し、FAR においては閾値が 0.990 以




図 3.11 最適パラメータを用いて学習したニューラルネットワークの EER

上で 0% を示した。本認証システムの場合，ステップが直列に接続されているため本人を排除してはならないので，FRR が 0% である必要がある。このためには，FAR が 0% であっても容認しなければならない。故に，閾値を 0.980 とした。この場合のステップ 1 の認証率は 99.985% であり，0.015% の他人がステップ 2 へと進む。

ステップ 2 では，ステップ 1 の指紋を分割して，小さい領域で認証を行う。このため，ステップ 2 では 1 つの領域内に存在する特徴点の数はステップ 1 よりステップ 2 の方が少ない。そこで，学習時の本人パターンの特徴点数を減らして学習し，認証試験を行った。

図 3.12 は，学習時に使用される本人に含まれる特徴点数に対する認証率を示している。この学習では最適パラメータを使用し，閾値 0.980 を用いた。図に示されるように，特徴点数が減少すれば，認証率は増加した。この結果より，ステップ 2 の認証率は，ステップ 1 より同等であるか高いことがわかる。よって，ステップ 2 の各ニューラルネットワークの認証率はステップ 1 での認証率 99.985% とみなすことができる。本認証システムでは，ステップ 1 とステップ 2 で合計 17 のニューラルネットワークを直列に接続した。従って，システム全体の認証率は $\{100 - (0.015)^{17}\}$ で表される。




図 3.12 1つの領域に含む特徴点数に対する認証率

3.6 結言

大容量データを高速に処理し、高精度で本人認証が可能なシステムを設計・構築した。ここでのシステムの設計とは、認証部のマルチステップ型のニューラルネットワークであり、大分類と 16 の小分類が直列に接続されている。

認証システムの性能（認証率）は、前処理部の指紋画像の分割数や認証部での基本となる 1 ステップに使用されているニューラルネットワークの性能やステップ数に依存する。指紋画像の分割の大きさは、指紋の隆線（凹凸）幅の 1.5 倍に相当する、1 辺を持ち、指圧によって生じうる誤差の最大幅とした。認証部の 1 ステップのニューラルネットワークのパラメータを最適化し、以下のパラメータが得られた。

| | |
|----------|-----------|
| 入力層ユニット数 | 16 |
| 中間層ユニット数 | 16 |
| 出力層ユニット数 | 1 |
| 慣性係数 | 0.2 |
| 学習係数 | 0.2 |
| 終了条件 | 10^{-4} |

このニューラルネットワークのパラメータを用いて、学習を行った結果から、学習の進行に従って誤差 2 乗和が減少し、終了条件以下の値で収束した。また、学習パターンを認証した結果から、本人拒否率と他人受入率が共に 0 となる領域が存在した。これらのことより、ニューラルネットワークが構築できた。

この認証部の 1 ステップに対して、テストパターンを用いてニューラルネットワークの最適化を行った。ニューラルネットワークの入力パターンは 16 桁の「0」と「1」で構成されている。そのため、「0」と「1」の組み合わせで、ニューラルネットワークに入力される全てのパターンを作成することができる。従って、テストパターンは全ての入力パターンから、学習パターンを除いたパターンである。学習パターンでの最適化と異なり、テストパターンを用いての最適化はニューラルネットワークの汎化能力、すなわち、認証システムの認証率に影響を与える。最適化の結果から、認証率が 16~80 の範囲の中間層ユニット数に依存しないことがわかった。また、認証率が学習係数及び慣性係数にほとんど依存しないことがわかった。さらに、終了条件が小さい程、低閾値領域での認証率が高い、つまり、テストパターンの多くが低いニューラルネットワークの出力値を持つことが分かった。

最適なニューラルネットワークのパラメータを用いて、ニューラルネットワークを学習

し、テストパターンを用いて認証率を求めた。本実験では、本人パターンは1パターンとしている。そのため、本人パターンのニューラルネットワークの出力値以下に本人と他人を分類する閾値を設定しなければならない。本人パターンの出力値は0.982であった。従って、閾値を0.980に設定した。この時の1ステップあたりの認証率は、99.985%となった。これは、1ステップで、0.015%の他人が本人候補として次のステップに進むこと示している。この認証部では、17のステップが直列に接続されている。従って、認証部での認証率は $\{1 - (0.00015)^{17}\} \times 100\%$ となる。

第4章

認証システムの高性能化

4.1 序言

前章までで、指紋画像用いた本人認証システムを構築した。実際の指紋をあつかう上で、ステップ1の指紋画像分割時の境界線がステップ2においても同様に境界線となり、境界線上に特徴点が存在した場合には、取得時の僅かな差で入力パターンが異なり正しく認証が行えない問題がある。この問題を解決するため、分割数が異なるステップを並列に接続した認証部を用いて認証システムを構築する。また、第3章において、1ステップ内で複数のニューラルネットワークを用いて、アンサンブルを行ったが、アンサンブルがニューラルネットワークの出力値に与える影響が明らかでない。この問題に対して、既知の関数を用い、その関数にノイズを付加したテストパターンを用いて、アンサンブルがニューラルネットワークの汎化能力に与える影響を調査する。

4.2 異なる分割数によるによるシステムの高性能化




図 4.1 3 × 3, 4 × 4 分割の境界線

図 4.1 は、指紋画像を $3 \times 3 = 9$ と $4 \times 4 = 16$ 分割した場合の境界線を示している。赤点は、境界線上にある特徴点を表している。図に示されるように、9 分割と 16 分割の境界線は重なっていない。従って、この 2 つの境界線を用いれば、境界線上に存在する特徴点の問題は解決できる。

図 4.2 は、設計認証システムの構成を示している。この認証システムは、取得部で指紋画像を得た後、前処理部で指紋画像を 9 及び 16 の領域に分割し、領域ごとに特徴点抽出を行って特徴点の有無で 2 値化する。そして、1 次元数列に変換して認証部への入力パターンを作成し、認証部で本人か他人に分類する。

図 4.3 は、9 分割した場合のニューラルネットワークへの入力パターンを示している。図に示されるように、ここでの入力パターンの作成方法は、前章までの作成方法と同一である。しかし、9 分割を行っているのでニューラルネットワークの入力層ユニット数は 9 である。

図 4.4 は、本章で提案される認証システムの認証部を示している。本認証部は、第 3 章までの認証システムと異なり、大分類に 9 分割、16 分割した指紋画像を前処理して得られた入力パターンを扱うステップが並列に配置されており、どちらかのステップで「本人

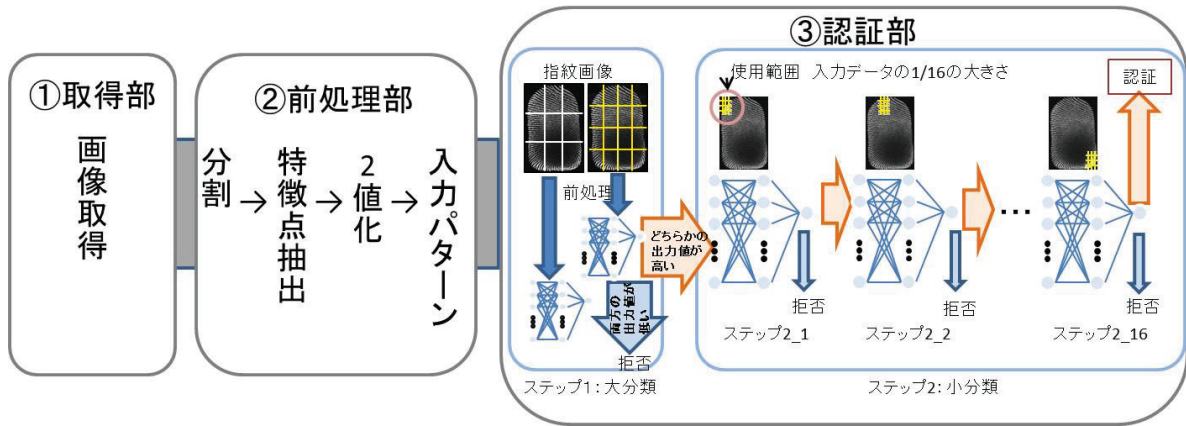


図 4.2 設計した認証システムの構成

候補」と認証すれば、次の小分類に進む。小分類では、大分類で「本人候補」と認証したステップの指紋分割数を用いて認証を行う。すなわち、大分類で 16 分割した指紋画像を扱うステップなら、小分類でも 16 分割した指紋を扱う。同様に、大分類で 9 分割した指紋画像を扱うステップなら、小分類でも分割した指紋を扱う。ここで、9 分割した指紋画像を扱うステップは、ニューラルネットワークのサイズが 16 分割した指紋画像を扱うステップと異なるので、9 分割した指紋画像を扱うステップを構築し、パラメータの最適化を行って、その汎化能力を調査した。

図 4.5 は、学習パターンを用いた場合の学習回数に対するニューラルネットワークの誤差 2 乗和を示している。ここでは、中間層ユニット数、慣性係数、学習係数及び終了条件はそれぞれ 9, 0.2, 0.2, 10^{-4} である。図に示されるように、学習回数が増加すると、ニューラルネットワークの誤差 2 乗和は単調に減少した。この結果より、ニューラルネットワークは学習パターンに対して収束することがわかった。

図 4.6 は、学習パターンで認証を行った場合の EER を示している。ここでの、X 軸はニューラルネットワークの閾値を、Y 軸は誤認率を表している。図に示されるように、FAR は閾値 0 以外は誤認率 0% を示し、FRR は閾値 1 以外は誤認率 0% を示した。これらのことより、閾値が 0.1~0.9 の範囲で FAR と FRR が共に誤認率 0% となったので、学習パターンに対してニューラルネットワークは正しく認証ができている。

図 4.5 と図 4.6 の結果より、ニューラルネットワークは、学習で誤差 2 乗和が終了条件以下に収束し、学習パターンに対して正しく認証したので、ニューラルネットワークは正




図 4.3 ニューラルネットワークに入力するパターン

(a) 分割した指紋 (白点は特徴点を示す。)

(b) 2 値化した指紋

(c) ニューラルネットワークに入力するパターン

常に動作している。従って、ニューラルネットワークを認証に持つ認証システムを構築できた。

次に、テストパターンを用いてパラメータの最適化を行った。

表 4.1 は、ニューラルネットワークの各種パラメータを示している。指紋画像を 9 分割しているため、全パターン数は $2^9=512$ パターンとなる。テストパターンを用いて最適化を行うにあたって、中間層ユニット数、慣性係数、学習係数は、第 3 章の最適化の結果より、認証率に依存しないことが分かっている。従って、中間層ユニット数、慣性係数、学習係数は、それぞれ 9, 0.02, 0.02 とした。学習の終了条件である誤差 2 乗和は、認証率に依存するので、最適化を行った。

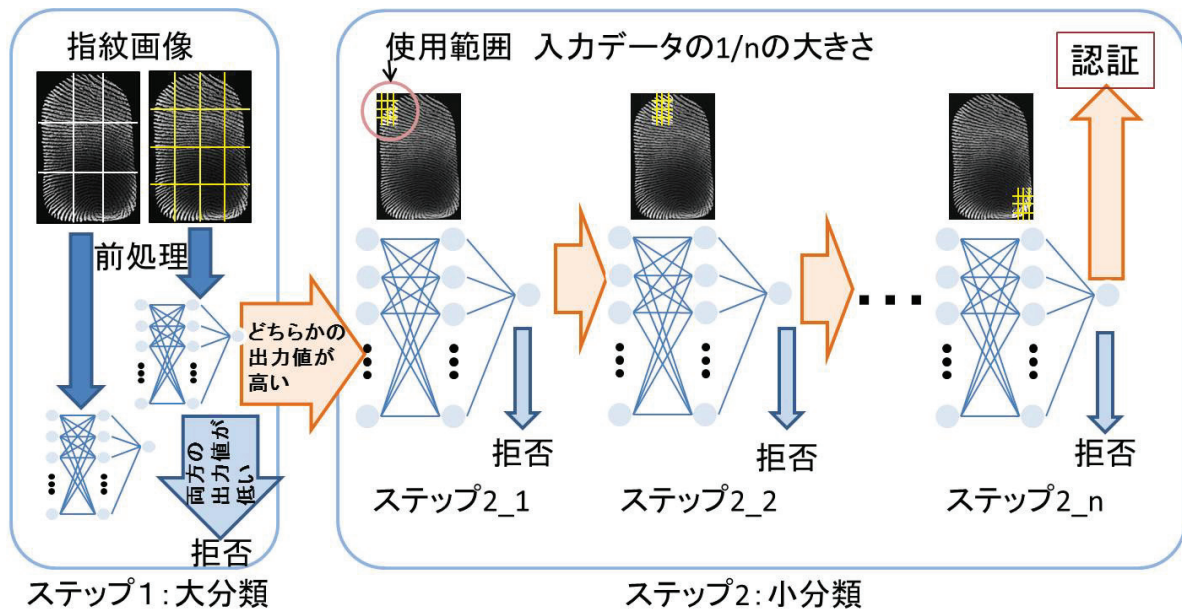


図 4.4 指紋認証システムの認証部

図 4.7 は、閾値に対するステップ 1 の認証率を示している。ここでは、終了条件に 10^{-2} 、 10^{-4} 及び 10^{-6} を用いた。図に示されるように、ステップ 1 における閾値に対する認証率の振る舞いは終了条件に依存した。閾値が $0 \sim 0.25$ の範囲では、ステップ 1 の認証率は終了条件が増加すると認証率は減少した。一方、閾値が $0.25 \sim 1$ の範囲では、ステップ 1 の認証率は終了条件と共に増加した。終了条件が 10^{-2} の時、 10^{-4} や 10^{-6} と比べて、低い閾値でも 100% となった。故に、終了条件の最適値は 10^{-2} とした。

これまでの最適なネットワークパラメータを用いてステップ 1 を構築し、ステップ 1 の認証実験を行った。これらの結果を図 4.8 に示す。ここでは、学習パラメータは中間層ユニット数、慣性係数、学習係数、終了条件はそれぞれ 9, 0.2, 0.2, 10^{-2} である。図に示されるように、ステップ 1 の認証率は閾値と共に急激に増加し、その後、緩やかに増加した。

図 4.9 は、最適パラメータを用いて学習したニューラルネットワークの EER を示している。図に示されるように、FRR においては閾値が 0.811 以下で 0% を示し、FAR においては閾値が 0.847 以上で 0% を示した。本認証システムの場合、ステップが直列に接続されているため本人を排除してはならないので、FRR が 0% である必要がある。このためには、FAR が 0% でなくても容認しなければならない。故に、閾値を 0.810 とした。こ




図 4.5 学習回数に対するニューラルネットワークの誤差 2 乗和

の場合のステップ 1 の認証率は 99.85% であり、0.15% の他人がステップ 2 へと進む。この認証部では、このステップが 10 個直列に接続されている。従って、認証システムの認証率は $1 - (0.0015)^{10} \times 100\%$ となる。この認証率は、16 分割を扱う場合と比べて、良い結果ではない。しかし、世界人口は約 70 億人で、手足を含めた総指紋数は、 1.4×10^{11} なので、この認証システムの認証率は十分である。

図 4.10 は入力層ユニット数依存性を示している。図に示されるように、入力層ユニットの増加、すなわち、指紋の分割数が増加すれば誤認率が低下することがわかる。しかし、入力層ユニット数が増加すると、入力パターン数が増えるので、それらを用いて認証率を求めることは現実的でない。また、9 より分割数を小さくすると、誤認率が大きくなるのでよくない。これらのことより、分割数が 9 と 16 を組み合わせるのが最適となる。




図 4.6 学習パターンの EER

表 4.1 ニューラルネットワークの各種パラメータ

| | | |
|----------------|------------------------|-----------|
| 入力パターン | 9 分割 | 16 分割 |
| 全パターン数 | 512 | 65536 |
| 学習パターン数 | 6 | 6 |
| → 本人パターン | 1 | 1 |
| → 他人パターン | 5 | 5 |
| テストパターン数 | 506 | 65530 |
| 入力層ユニット数 | 9 | 16 |
| 中間層ユニット数 | 9 | 16 |
| 出力層ユニット数 | 1 | 1 |
| 慣性係数 | 0.02 | 0.02 |
| 学習係数 | 0.02 | 0.02 |
| 終了条件 (誤差 2 乗和) | $10^{-2} \sim 10^{-6}$ | 10^{-2} |




図 4.7 閾値に対するステップ 1 の認証率 (異なる終了条件の場合)




図 4.8 最適パラメータを用いて学習したニューラルネットワークでの認証率




図 4.9 最適パラメータを用いて学習したニューラルネットワークの EER




図 4.10 誤認率に対する入力層ユニット数依存性

この本人認証システムを拡張して，個人認証を構築した。




図 4.11 個人認証システム

図 4.11 は本人認証システムを拡張して構成した，個人認証システムを示している。この個人認証システムは，本人認証システムを並列に接続している。指紋は全ての本人認証システムに入力され，認証される。仮に人 A の指紋が個人認証システムに入力された場合，人 A を本人認証するシステムでは認証される。人 A 以外の本人認証システムでは，他人なので認証されない。従って，人 A と個人認証される。これらの本人認証システムは互いに独立したシステムである。従って，認証したい人を追加したい場合は，すでに完成している個人認証システムに，新しい人用の本人認証システムを構築して個人認証システムに追加するだけでよい。

4.3 アンサンブル学習

4.3.1 アンサンブル学習とは

アンサンブル学習とは、単一の学習機械を何らかの形で融合して、汎化能力の向上を図ることである [57]。学習機械のパターン認識において、高い汎化能力を得ることは重要である。ニューラルネットワークを用いる場合、少ない学習パターンで大きな汎化能力を得ることは、学習時間の減少や学習の収束率などに大きなメリットがある。汎化能力を向上させる手段として、単一の学習機械性能向上をするのではなく、複数の学習機械を用いる。複数の学習機械を持ちいた研究に [62], [63] 等がある。アンサンブル学習は、大きく分けて2つの種類に分類できる。それは、1つの学習パターンに対して複数のニューラルネットワークを用いたアンサンブル学習と複数の学習パターンに対して複数のニューラルネットワークを用いたアンサンブル学習である。

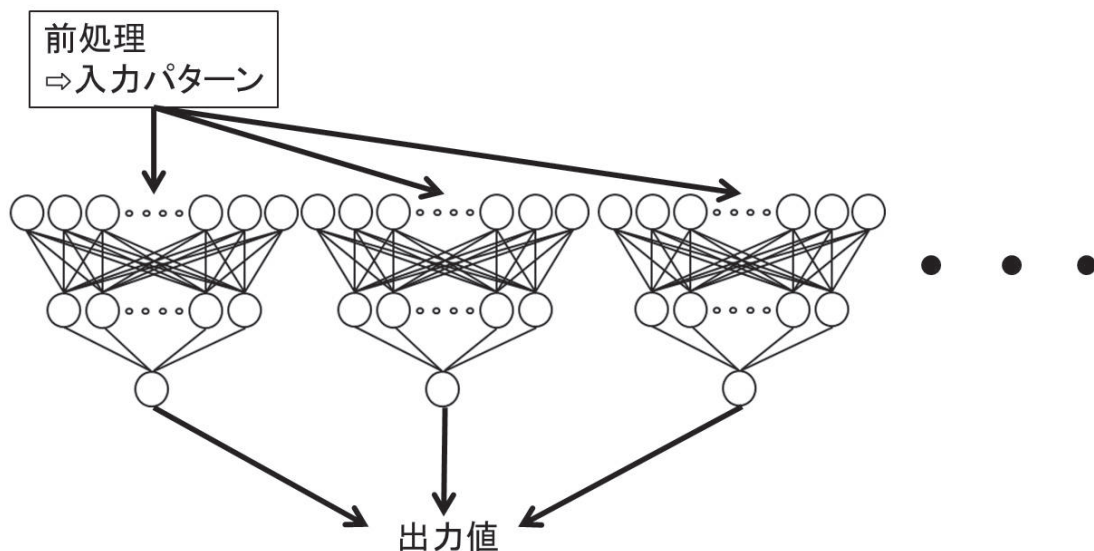


図 4.12 1つの学習パターンに対して複数のニューラルネットワークを用いたアンサンブル学習

これらの方法を図 4.12, 4.13 に示す。ここでは、学習機械にニューラルネットワークを用いた例を示した。前章までの認証システムを構築する場合、学習パターンの作成方法は

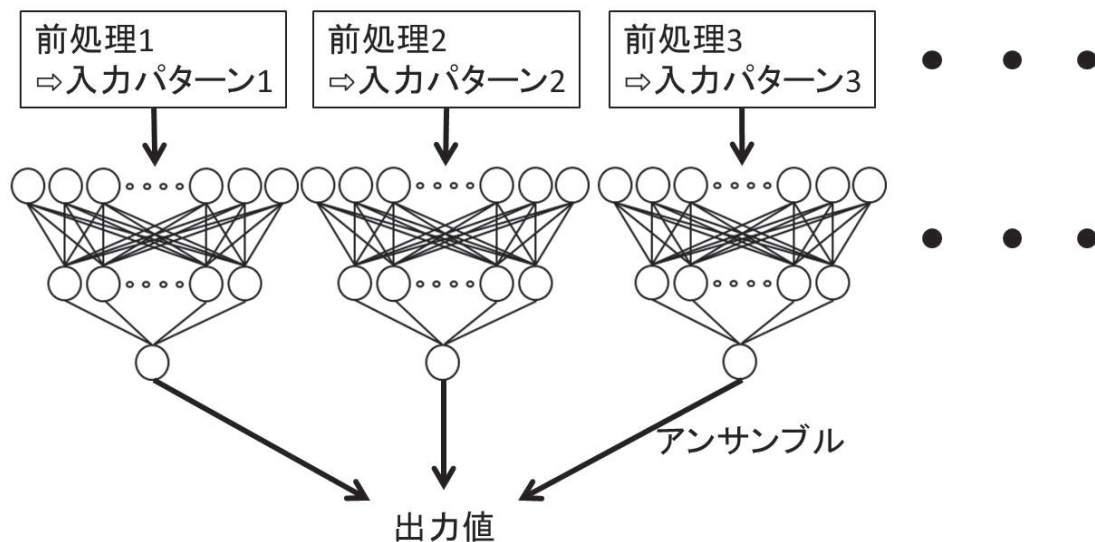


図 4.13 複数の学習パターンに対して複数のニューラルネットワークを用いたアンサンブル学習

決まっており、2 値のパターンなので、「0」と「1」の中間値等は存在せず、本人のパターンは 1 パターンである。この場合、複数のパターンを作成するのは困難であるため、同じパターンでも異なったニューラルネットワークを作成してアンサンブルする方法を用いている。これらのアンサンブル学習を用いた研究は良く報告されているが、ニューラルネットワークを学習機械に用いた場合でアンサンブルする場合の汎化能力に与える影響についての報告はあまりない。従って、既知の関数（パターン）を用いてニューラルネットワークを学習し、学習パターンに対してノイズを付加したテストパターンを用いて、ニューラルネットワークを用いたアンサンブル学習の汎化能力を調査した。

4.3.2 汎化能力への影響

図 4.14 は実験に用いた学習パターンである。これらは中心が 70 で半値幅が 30、振幅が 1 のガウシアン 1 と中心が 120、半値幅が 30、振幅が 0.2~1 のガウシアン 2 をそれぞれ合成した関数となっている。これらの中、ガウシアン 1 とガウシアン 2 の強度が 1 の関数に教師信号「1」を与え、他の関数には教師信号「0」を与えた。これらを教師信号 0.1~0.4 と呼ぶ。これらのパターンは、前半が共通部分であり後半はガウシアン強度が異




図 4.14 本実験に用いられた学習パターン

なる部分である。ニューラルネットワークの学習には教師信号「1」と教師信号「0」をそれぞれ 1 パターン用いて計 2 パターンで学習を行った。従って、学習パターンは 4 種類である。また、教師信号「1」のパターンと教師信号 0.1 のパターンとの成す面積を 1 として基準とし、これを学習パターンの面積差と呼ぶ。さらに、学習時のニューラルネットワークのパラメータは、入力層ユニット数、中間層数、中間層ユニット数、出力層ユニット数、学習係数、慣性係数及び終了条件（誤差 2 乗和）はそれぞれ、200, 1, 200, 1, 0.2, 0.2 及び 0.0001 を用いた。

図 4.15 は実験に用いたテストパターンの一例を示している。テストパターンは学習パターンにノイズを付加して用いた。ノイズにはホワイトノイズを用いた。また、ノイズの大きさは X 軸とノイズで囲まれている面積を学習パターンの面積差と同じ基準で表した。この時の面積をノイズの大きさと定義して以下で表される。

$$\text{ノイズの大きさ} = \frac{\sum_{n=0}^{200} |n(n)|}{\sum_{n=0}^{200} \{f(n) - g(n)\}} \quad (4.1)$$

ここでの $f(n)$ と $g(n)$ は、それぞれ、図の凡例の教師信号「1」と教師信号「0.1」の関数を




図 4.15 本実験に用いられたテストパターン

表している。また、 $n(n)$ は、ノイズの関数を表している。図には教師信号「1」のパターンにノイズの大きさが 1 と 40 の付加した場合を示している。実験にはノイズの大きさ毎に 100 種のノイズを用いた。また、アンサンブル学習を行う場合はニューラルネットワークを 100 個使い、同一テストパターンのニューラルネットワークの出力値を平均した。

図 4.17~4.20 はノイズの大きさに対するニューラルネットワークの出力値を示している。ここでは、それぞれ、学習パターンの差「1」~「4」の場合で教師信号「0」のテストパターンを用いた。図の横軸はテストパターンに付加したノイズの大きさを示し、縦軸は出力値を表している。また、凡例はアンサンブルする場合としない場合を示している。アンサンブルする場合を“アンサンブル有り”と表記し、しない場合をアンサンブル無し”と表記する。“アンサンブル有り”と“アンサンブル無し”は表記の都合上隣接して示しているが、ノイズの大きさの値はその中心の値である。図に示されるように、アンサンブル有り”と無し”共にノイズの大きさが増加すれば、ニューラルネットワークの出力値が存在する幅が増加する。また、アンサンブル有り”は無し”と比べて、ニューラルネットワークの出力値が存在する幅が小さい。これらのことより、アンサンブル学習を行うとニュー




図 4.16 学習回数に対する誤差 2 乗和

ラルネットワークの出力値の存在する幅が小さくなることがわかった。

図 4.21~4.24 はノイズの大きさに対するニューラルネットワークの出力値を示している。ここでは、それぞれ、学習パターンの差が「1」~「4」の場合で教師信号「1」のテストパターンを用いた。これらの図は図 4.17~4.20 と同様に隣接するアンサンブル有りと無しとの中心がノイズの大きさを示す。図に示されるように、アンサンブル無しの場合にはノイズの大きさが増加すると、ニューラルネットワークの出力値が存在する幅が大きくなり、ノイズの大きさが 16 でニューラルネットワークの出力値の幅がほぼ 1 となり、それ以降は飽和している。アンサンブル有りの場合は、ノイズの大きさが増加すれば、ニューラルネットワークの出力値の幅も増加する。しかし、ノイズの大きさが 16 付近でニューラルネットワークの出力値の幅が最大となり、その後、減少する。また、出力値の存在する範囲も減少している。これらのことより、アンサンブル学習を行えばニューラルネットワークの出力値の幅が収束することがわかる。図 4.20 を図 4.24 と比べて、それぞれのテストパターンのニューラルネットワークの出力値は、アンサンブル無しはノイズの大きさが 8 でアンサンブル有りはノイズの大きさが 16 で混在し、分類不可能になる。




図 4.17 ノイズの大きさに対するニューラルネットワークの出力値（学習パターンの差が「1」で教師信号「0」のテストパターンの場合）

図 4.25 は、ノイズの大きさに対するニューラルネットワークの出力値の差を示している。ここでは、種々の学習パターンの差における教師信号「0」のテストパターンを用いた。図の横軸はノイズの大きさを表し、縦軸はノイズの大きさ別にテストパターンを入力した場合のニューラルネットワークの出力値の最大値と最小値の差を表す。ここでのテストパターンは教師信号「0」の学習パターンにノイズを付加したパターンを使用している。また、100 個のニューラルネットワークを用いてアンサンブル学習を行った。図に示されるように、全ての学習パターンの面積差においてノイズの大きさが増加するとニューラルネットワークの出力値の差は増加し、一定値に収束する。また、同程度のノイズの大きさの場合、学習パターンの面積差が大きいほど、ニューラルネットワークの出力値の差が小さい。これらのことより、教師信号「0」のテストパターンでは、学習パターンの面積差が大きいとニューラルネットワークの出力値の存在する範囲は狭くなることがわかった。

図 4.26 は、ノイズの大きさに対するニューラルネットワークの出力値の差を示している。ここでは、種々の学習パターンの差における教師信号「1」のテストパターンを用いた。図の横軸はノイズの大きさを表し、縦軸はノイズの大きさ別にテストパターンを入力




図 4.18 ノイズの大きさに対するニューラルネットワークの出力値（学習パターン之差が「2」で教師信号「0」のテストパターンの場合）

した場合のニューラルネットワークの出力値の最大値と最小値の差を表している。ここでテストパターンは教師信号「1」の学習パターンにノイズを付加したパターンを使用している。また、100個のニューラルネットワークを用いてアンサンブル学習を行った。図に示されるように、全ての学習パターンの面積差においてノイズの大きさが増加すればニューラルネットワークの出力値の差は急激に増加し、その後、一定値に収束する。また、同程度のノイズの大きさの場合、学習パターンの面積差が大きいほど、ニューラルネットワークの出力値の差が小さい。これらのことより、教師信号「1」のテストパターンでも学習パターンの面積差が大きいとニューラルネットワークの出力値の存在する範囲は狭くなることがわかった。

図 4.27 は、テストパターンにおけるノイズの大きさに対するニューラルネットワークの出力値を示している。図の横軸はノイズの大きさを、縦軸はニューラルネットワークの出力値を示している。また、学習パターンの面積は4である。さらに、教師信号「1」のテストパターンを入力した場合の各ノイズの大きさにおけるニューラルネットワークの出力値の最小と教師信号「0」のテストパターンを入力した場合の各ノイズの大きさにおけ




図 4.19 ノイズの大きさに対するニューラルネットワークの出力値（学習パターンの差が「3」で教師信号「0」のテストパターンの場合）

るニューラルネットワークの出力値の最大を表している。図に示されるように、教師信号「1」の最小値はノイズの大きさの増加とともにニューラルネットワークの出力値は減少している。また、教師信号「0」の最大値はノイズの大きさの増加とともにニューラルネットワークの出力値も増加している。また、ノイズの大きさが 14 付近で交差している。この交差点でのノイズの大きさはテストパターンの分類が可能な最大のノイズの大きさであり、これ以上のノイズの大きさでは、テストパターンを正しく分類できない。この交差点のノイズの大きさを臨界ノイズと呼ぶ。

図 4.28 は、学習パターンの面積差に対する限界ノイズを示している。図の横軸は学習パターンの面積差、縦軸は臨界ノイズを表している。ここで、アンサンブル有りは、100 個のニューラルネットワークをアンサンブルした結果を使用している。また、アンサンブル無しは、ニューラルネットワーク 10 個の結果を表している。図に示されるように、学習パターンの面積差が増加すれば限界ノイズも増加した。これらのことより、学習パターンの面積差に対して臨界ノイズは比例していることがわかった。また、アンサンブル有りはアンサンブル無しに比べて大きいノイズを含むパターンでも分類することができる。




図 4.20 ノイズの大きさに対するニューラルネットワークの出力値（学習パターンの差が「4」で教師信号「0」のテストパターンの場合）




図 4.21 ノイズの大きさに対するニューラルネットワークの出力値（学習パターンの差が「1」で教師信号「1」のテストパターンの場合）




図 4.22 ノイズの大きさに対するニューラルネットワークの出力値 (学習パターンの差が「2」で教師信号「1」のテストパターンの場合)




図 4.23 ノイズの大きさに対するニューラルネットワークの出力値 (学習パターンの差が「3」で教師信号「1」のテストパターンの場合)




図 4.24 ノイズの大きさに対するニューラルネットワークの出力値 (学習パターンの差が「4」で教師信号「1」のテストパターンの場合)




図 4.25 ノイズの大きさに対するニューラルネットワークの出力値の差 (種々の学習パターンの差における教師信号「0」のテストパターンの場合)




図 4.26 ノイズの大きさに対するニューラルネットワークの出力値の差（種々の学習パターンの差における教師信号「1」のテストパターンの場合）




図 4.27 テストパターンにおけるノイズの大きさに対するニューラルネットワークの出力値




図 4.28 テストパターンにおけるノイズの大きさに対するニューラルネットワークの出力値

4.4 結言

実在の指紋画像を用いた場合に発生する境界線上の問題を解決するために指紋画像の分割数が異なるステップを作成し、それを組み合わせた認証システムを構築した。分割の境界線上に指紋の特徴点が存在した場合、取得時の僅かな差で、認証部への入力パターンが異なる。本認証システムでは、入力パターンが異なれば他人として排除するシステムのため、本人の指紋が認証システムに提示されても排除する。この問題を解決するために新しい認証部を設計・構築した。この認証部は、大分類と小分類を行う。大分類では、指紋の分割数に応じた2ステップが並列に接続されている。これらのステップのどちらかが「本人候補」と認証すれば、小分類を行う。小分類では、大分類で認証したステップの指紋の分割数と同じ分割数で認証を行う。9分割した指紋を扱うステップを構築して、認証部の1ステップのニューラルネットワークのパラメータを最適化し、以下のパラメータが得られた。

入力層ユニット数 9

中間層ユニット数 9

出力層ユニット数 1

慣性係数 0.2

学習係数 0.2

終了条件 10^{-2}

このパラメータを用いて、ニューラルネットワークを学習した結果から、1ステップあたり認証率は99.85%となった。この認証率は、16分割の場合と比べて低い。この認証部ではこのステップが10個直列に接続されているため、指紋認証システムとして認証率は十分である。

さらに、本認証システムを用いて個人認証システムを構築した。この個人認証システムは、本人認証システムを並列に接続している。指紋は全ての本人認証システムに入力され、認証される。仮に人Aの指紋が個人認証システムに入力された場合、人Aを本人認証するシステムでは認証される。人A以外の本人認証システムでは、他人なので認証されない。これらの本人認証システムは互いに独立したシステムであるので、認証したい人を追加したい場合は、すでに完成している個人認証システムに、新しい人用の本人認証システムを構築して個人認証システムに追加するだけでよい。

加えて、アンサンブル学習がニューラルネットワークの汎化能力に与える影響を調査した。アンサンブル学習は、学習機械のパターン分類の汎化能力を向上させる方法の1つで

ある。既知の関数（パターン）を用いて複数のニューラルネットワークを学習し、学習パターンにノイズを付加したテストパターンを用いて汎化能力調査した結果から、ニューラルネットワークが分類することが可能なノイズの大きさは、教師信号”1”と”0”の面積の差に比例することがわかった。さらに、アンサンブル学習の有無では、アンサンブル学習を行った方が行っていない方と比べて約2倍の大きさのノイズをまで分類することができる。

第5章

結論

本研究では、指紋画像を分割し、マニューシャ法による特徴点の有無によって2値化した2次元画像から1次元数列を作成することによって、入力パターンを作成し、マルチステップ型のニューラルネットワークで分類する指紋認証システムを構築し、その性能を評価して、さらなる高性能化を行った。

初めに、指紋による本人認証システムを設計・構築し、その性能を評価した。この認証システムは、取得部、前処理部、認証部からなっている。取得部では、機器を用いて指紋画像を取得した。前処理部では指紋画像を分割し、マニューシャ法による特徴点の有無によって2値化した2次元画像から1次元数列を作成することによって、入力パターンを作成した。認証部に、バックプロパゲーション学習則の3階層ニューラルネットワークを用いた。

この認証システムの性能は、前処理部の前処理法と認証部のニューラルネットワークの性能に依存する。特に、ニューラルネットワークの性能は、学習パターンや未学習パターンやニューラルネットワークのパラメータ、例えば、学習係数、慣性係数、終了条件、ニューラルネットワークのサイズに大きく依存する。

出力層ユニットの出力値を「0」か「1」にする学習パターンを用いて、認証部のニューラルネットワークを学習した。学習の過程は、学習パターンに対して、ニューラルネットワークの出力値と教師信号との誤差2乗和が減少し、収束すること及び認証率が学習パターンで期待される出力値と一致する、つまり、本人拒否率と他人受入率が共に0となる領域があることでニューラルネットワークの構築が証明される。本認証システムのニューラルネットワークは、学習の進行に従って誤差2乗和が減少し、終了条件以下の値で収束した。また、学習パターンを認証した結果から、本人拒否率と他人受入率が共に0となる領域があった。これらのことより、ニューラルネットワークが構築できた。

本人パターンから「1」の位置を移動したパターンをテストパターンとして、ニューラルネットワークの汎化能力を調査した。テストパターンは、本人の指紋に似た他人の指紋である。テストパターンの移動した点数が本人パターンとの類似度を表している。テストパターンは、他人パターンなのでニューラルネットワークの出力値は0付近となることが望ましい。このテストパターンを用いて、認証実験を行った結果から、ニューラルネットワークの出力値は、移動した特徴点の数の増加に対して減少することがわかった。しかし、移動した特徴点の数が少ない場合、そのニューラルネットワークの出力値は本人パターンのニューラルネットワークの出力値とあまり差がない。この原因は、入力パターンのほとんどが「0」で構成されているためと考えられる。つまり、指紋の分割数が384の場合、374個の「0」と10個の「1」で構成されているため、「1」が1、2個移動しても、全体的に大差がないためである。この問題に対して、分割数を少なくしたり、用いる特徴点を増加させるなどの方法により解決できると考えられる。これらのことより、移動した特徴点の数の増加に対してニューラルネットワークの出力値は減少しているので、認証システムとしては用いることができる。しかし、1つの特徴点が移動しても、ニューラルネットワークの出力値があまり変化していないので、このニューラルネットワークでは特徴点の位置精度が悪い。また、ここまで、テストパターンには、本人パターンに似たパターンを用いたが、テストパターンに用いていないパターンは大量に存在する。そのため、テストパターンを用いて、本認証システムの認証率を求めてもあまり意味がない。さらに多くのパターンを用いて、高精度な認証率を求める必要がある。

次に、大容量データを高速に処理し、高精度で本人認証が可能なシステムを設計・構築した。ここでのシステムの設計とは、認証部のマルチステップ型のニューラルネットワークであり、大分類と16の小分類が直列に接続されている。

認証システムの性能（認証率）は、前処理部の指紋画像の分割数や認証部での基本となる1ステップに使用されているニューラルネットワークの性能やステップ数に依存する。指紋画像の分割の大きさは、指紋の隆線（凹凸）幅の1.5倍に相当する、1辺を持ち、指圧によって生じる誤差の最大幅とした。認証部の1ステップのニューラルネットワークのパラメータを最適化した。このニューラルネットワークのパラメータを用いて、学習を行った結果から、学習の進行に従って誤差2乗和が減少し、終了条件以下の値で収束した。また、学習パターンを認証した結果から、本人拒否率と他人受入率が共に0となる領域が存在した。これらのことより、ニューラルネットワークが構築できた。

この認証部の1ステップに対して、テストパターンを用いてニューラルネットワークの最適化を行った。ニューラルネットワークの入力パターンは16桁の「0」と「1」で構成されている。そのため、「0」と「1」の組み合わせで、ニューラルネットワークに入力され

る全てのパターンを作成することができる。従って、テストパターンは全ての入力パターンから、学習パターンを除いたパターンである。学習パターンでの最適化と異なり、テストパターンを用いての最適化はニューラルネットワークの汎化能力、すなわち、認証システムの認証率に影響を与える。最適化の結果から、認証率が、16~80 の範囲の中間層ユニット数に依存しないことがわかった。また、認証率が、学習係数及び慣性係数にほとんど依存しないことがわかった。さらに、終了条件が小さい程、低閾値領域での認証率が高い、つまり、テストパターンの多くが低いニューラルネットワークの出力値を持つことが分かった。

最適なニューラルネットワークのパラメータを用いて、ニューラルネットワークを学習し、テストパターンを用いて認証率を求めた。本実験では、本人パターンは1パターンとしている。そのため、本人パターンのニューラルネットワークの出力値以下に本人と他人を分類する閾値を設定しなければならない。本人パターンの出力値は0.982であった。従って、閾値を0.980に設定した。この時の1ステップあたりの認証率は、99.985%となった。これは、1ステップで、0.015%の他人が本人候補として次のステップに進むこと示している。この認証部では、17のステップが直列に接続されている。従って、認証部での認証率は $\{[1 - (0.00015)^{17}] \times 100\}$ %となる。

最後に、実在の指紋画像を用いた場合に発生する境界線上の問題を解決するために指紋画像の分割数が異なるステップを作成し、それを組み合わせた認証システムを構築した。分割の境界線上に指紋の特徴点が存在した場合、取得時の僅かな差で、認証部への入力パターンが異なる。本認証システムでは、入力パターンが異なれば他人として排除するシステムのため、本人の指紋が認証システムに提示されても排除する。この問題を解決するために新しい認証部を設計・構築した。この認証部は、大分類と小分類を行う。大分類では、指紋の分割数に応じた2つステップが並列に接続されている。これらのステップのどちらかが「本人候補」と認証すれば、小分類を行う。小分類では、大分類で認証したステップの指紋の分割数と同じ分割数で認証を行う。9分割した指紋を扱うステップを構築して、認証部の1ステップのニューラルネットワークのパラメータを最適化した、最適化パラメータを用いて、ニューラルネットワークを学習した結果から、1ステップあたり認証率は99.85%となった。この認証率は、16分割の場合と比べて低いが、認証部ではこのステップが10個直列に接続されているため、指紋認証システムとして認証率は十分である。

さらに、本認証システムを用いて個人認証システムを構築した。この個人認証システムは、本人認証システムを並列に接続している。指紋は全ての本人認証システムに入力され、認証される。仮に人Aの指紋が個人認証システムに入力された場合、人Aを本人認

証するシステムでは認証される。人 A 以外の本人認証システムでは、他人なので認証されない。これらの本人認証システムは互いに独立したシステムであるので、認証したい人を追加したい場合は、すでに完成している個人認証システムに、新しい人用の本人認証システムを構築して個人認証システムに追加するだけでよい。

加えて、アンサンブル学習がニューラルネットワークの汎化能力に与える影響を調査した。アンサンブル学習は、学習機械のパターン分類の汎化能力を向上させる方法の 1 つである。既知の関数（パターン）を用いて複数のニューラルネットワークを学習し、学習パターンにノイズを付加したテストパターンを用いて汎化能力調査した結果から、ニューラルネットワークが分類することが可能なノイズの大きさは、教師信号「1」と「0」の面積の差に比例することがわかった。さらに、アンサンブル学習の有無では、アンサンブル学習を行った方が行っていない方と比べて約 2 倍の大きさのノイズをまで分類することができる。

以上のことより、本研究で提案した、指紋画像を前述の処理を行って得られた 2 値の 1 次元数列の入力パターンを分類するマルチステップ型のニューラルネットワークを認証部に持つ認証システムが構築できた。入力パターンは 2 値の 1 次元数列なので、「0」と「1」を組み合わせて、全てのパターンを表現することができる。これらのパターンを用いて、認証を行うことで不変的な認証精度、認証率を求めることができた。本認証システムの認証部は、2 値の入力パターンを分類する。従って、前処理で 2 値のパターンを作成できる全ての分類に対して、応用できると考えられる。

今後は、本認証システムを元にさら実践的な認証システムを目指す。現在の認証システムは、本人のパターンを 1 つであることを前提に構築されている。異なる分割数を組み合わせることによって、僅かな指紋の移動による境界線上の特徴点の移動は解決した。しかし、指紋を取得する際に生じる、さらに、大きな特徴点の位置移動等による入力パターンの変化には対応していない。この問題に対して、個人認証システムの応用で、変化したパターンを本人とする本人認証システムを構築して、並列に接続する等の解決策が考えられる。この方法では、本人パターンを増やすことよっての認証率、認証精度の低下が予想される。これに対しては、小分類の後に更に小さい領域を分類するステップを増設することで対応可能であると考えられる。つまり、大分類、中分類、小分類等の分類数を増やすことで対応する。この分類数と分割数の調整で、指紋画像の特徴点の位置の精度を調整することができる。また、認証部以外の部分の自動化を行い実用できる認証システムの構築を目指す。

謝辞

本研究は，鳥取大学大学院工学研究科博士後期課程において行われたものである。ご指導ご鞭撻賜りました主指導教官の工学研究科情報エレクトロニクス専攻，岸田悟教授に心から感謝いたします。また，研究はもとより公私にわたって大変お世話になりました。ありがとうございました。

副査として専門的なご助言を頂きました工学研究科情報エレクトロニクス専攻，伊藤良生教授，李仕剛教授に厚くお礼申し上げます。

共同研究者としてご協力いただきました工学研究科情報エレクトロニクス専攻，木下健太郎准教授に深く感謝いたします。

学内事務関連では，鳥取大学工学部附属電子ディスプレイ研究センター及び先端融合研究センターの職員の方々には大変お世話になりました。ありがとうございました。

現株式会社ノーリツの大西俊輔様，現オムロン株式会社小林光様を始めといたしました電子物理工学研究室，電磁エネルギー応用工学研究室の皆様には，本研究に関して多くの有益なアドバイスを頂きました。また，研究室行事等にも数多く参加させていただき，充実した学生生活を過ごすことができました。心からお礼申し上げます。

参考文献

- [1] 甘利俊一, 古市貞一: シリーズ脳科学 5—分子・細胞・シナプスからみる脳, 東京大学出版会, 2008
- [2] J.J.Hopfield, "Pattern Recognition Computation Using Action Potential Timing for Stimulus Representation", *Nature*, Vol. 376, No.6, pp.33-36, 1995.
- [3] G.-Q.Bi and M.-M.Poo, "Synaptic Modifications in Cultured Hippocampal Neurons Dependence on Spike Timing, Synaptic Strength, and Postsynaptic Cell Type", *The Journal of Neuroscience*, Vol.18, No.24, pp.10464-10472, 1998.
- [4] S.Song, K.D.Miller and L.F.Abbott, "Competitive Hebbian Learning through Spike-timing-dependent Synaptic Plasticity", *Nature Neuroscience*, Vol.3, No.9, pp.919-926, 2000.
- [5] 渡部徹, 岸田悟, 石原顕永, 山内康弘, 徳高平蔵, "ニューラルネットワークの定量分析への適用", *表面化学*, Vol. 19, No. 2, pp.98-105, 1998.
- [6] 渡部徹, 岸田悟, 石原顕永, 河相宰昭, 徳高平蔵, 福島整, "ニューラルネットワークの化学分析への適用", *表面化学*, Vol. 19, No. 6, pp.398-406, 1998.
- [7] 徳高平蔵, 岸田悟, 藤村喜久郎, "自己組織化マップの応用", 海文堂出版, 東京, 1999.
- [8] D.W.Piraino, S.C.Amartur, B.J.Richmond, J.P.Schils, J.M.Thome, G.H.Belhobek and M.D.Schlucter, "Application of an Artificial Neural Network in Radiographic Diagnosis", *Journal of Digital Imaging*, Vol.4, No.4, pp.226-232, 1991.
- [9] W.S.Gan, "Application of Fuzzy Neural Networks to Medical Image Processing", *Proceedings of International Joint Conference on Neural Networks*, Vol.VI, pp.386-391, 1992.
- [10] K.Quandt, T.Waschulzik, M.Lewis, A.Hörmann, R.Engelbrecht and W.Brauer, "Evaluation of Epidemiological Data with Neural Networks", *Proceedings of*

- World Congress on Neural Networks, Vol.I, pp.257-260, 1993.
- [11] P.J.G.Lisboa, "A Review of Evidence of Health Benefit from Artificial Neural Networks in Medical Intervention", *Neural Networks*, Vol.15, pp. 11-39, 2002.
 - [12] P.J.Lisboa and A.F.G.Taktak, "The Use of Artificial Neural Networks in Decision Support in Cancer: A Systematic Review", *Neural Networks*, Vol.19, pp. 408-415, 2006.
 - [13] X.Zhang, G.Yang, B.Xia, X.Wang, and B.Zhang, "Application of the Rough Set Theory and BP Neural Network Model in Disease Diagnosis", *Proceedings of 2010 Sixth International Conference on Natural Computation (ICNC 2010)*, pp.167-171, 2010.
 - [14] C.-P.Chuang, S.-S.Lee, J.-S.Tsai and T.-J.Kuo, "Detecting Mammography of Breast Microcalcification with SOL-based Self Organization Neural Network", *Proceedings of 2010 Sixth International Conference on Natural Computation (ICNC 2010)*, pp.1217-1222, 2010.
 - [15] Y.Xiang, J.Tian, Z.Zhang and Y.Dai, "Diagnosis of Endometrial Cancer Based on Near Infrared Spectroscopy and General Regression Neural Network", *Proceedings of 2010 Sixth International Conference on Natural Computation (ICNC 2010)*, pp.1228-1231, 2010.
 - [16] P.S.Maclin and J.Dempsey, "A Neural Network to Diagnose Liver Cancer", *Proceedings of International Conference on Neural Networks*, Vol.III, pp.1492-1497, 1993.
 - [17] M.Morrison and Y.Attikiouzel, "A Probabilistic Neural Network Based Image Segmentation Network for Magnetic Resonance Images", *Proceedings of International Joint Conference on Neural Networks*, Vol.III, pp.60-65, 1993.
 - [18] W.Liu, P.Shen, Y.Qu and D.Xia, "Fast Algorithm of Support Vector Machines in Lung Cancer Diagnosis", *Proceedings of International Workshop on Medical Imaging and Augmented Reality (MIAR'01)*, pp.188-192, 2001.
 - [19] Y.Wu, N.Wang, H.Zhang, L.Q.Yan and Y.Wu, "Application of Artificial Neural Networks in the Diagnosis of Lung Cancer by Computed Tomography", *Proceedings of 2010 Sixth International Conference on Natural Computation (ICNC 2010)*, pp.147-153, 2010.
 - [20] S.Katsuragawa, K.Do, H.MacMahon, L.M.-Cholley T.Ishida and T.Kobayashi, "Classification of Normal and Abnormal Lungs with Interstitial Diseases by

- Rule-Based Method and Artificial Neural Networks”, *Journal of Digital Imaging*, Vol.10, No.3, pp.108-114, 1997.
- [21] 銅谷賢治, ”計算神経科学への招待—脳の学習機構の理解を目指して (2) ニューロンのモデル”, *数理科学*, Vol.43, No.8, pp.63-72, 2005.
- [22] W.S.McCulloch and W.Pitts, ”A Logical Calculus of the Ideas Immanent in Nervous Activity”, *Bulletin of Mathematical Biophysics*, Vol.5, pp.115-133, 1943.
- [23] D.O. ヘップ, ”行動の機構—脳メカニズムから心理学へ (上, 下)”, 岩波書店, 東京, 2011.
- [24] バイオメトリクスセキュリティコンソーシアム編, ”バイオメトリックセキュリティ・ハンドブック”, オーム社, 東京, 2006.
- [25] 森雅博, 新崎卓, 佐々木繁, ”バイオメトリクス認証技術”, *Fujitsu*, Vol.54, No.4, pp.272-279, 2003.
- [26] 中村高宏, 藤原秀人, 広岡美和子, 鷲見和彦: 並行隆線フィルタ法による指紋画像の隆線強調処理, *電子情報通信学会論文誌 D-II*, 情報・システム, II-パターン処理, Vol.72, No.5, pp.707-714, 1989.
- [27] K.Ito, T.Aoki, H.Nakajima, K.Kobayashi and T.Higuchi: A palmprint recognition algorithm using phase-only correlation, *IEICE Trans. Fundamentals*, A Vol.E91, No.4, pp.1023-1030, 2008.
- [28] N.Miura, A.Nagasaka and T.Miyatake: Feature extraction of finger-vein patterns based on repeated line tracking and its application to personal identification, *Mach Vis Appl*, Vol.15, No.4, pp.194-203, 2004.
- [29] Y.Zhu, T.Tan and Y.Wang: Biometric personal identification based on iris patterns, *Proceedings 15th IEEE International Conference on Pattern Recognition*, Vol.2, pp.801-804, 2000.
- [30] C.Kanali, H.Murase and N.Honami: Shape identification using a charge simulation retina model, *Mathematics and Computers in Simulation*, Vol.48, pp.103-118, 1998.
- [31] A.Martinez and H.Jia: Support vector machines in face recognition with occlusions, *IEEE Conference on Computer Vision and Pattern Recognition, Neural Networks*, Vol.14, pp.795-803, 2001.
- [32] K.Amit and B.Biswas: Speaker identification from voice using neural networks, *Journal of Scientific & Industrial Research*, Vol.61, No.8, pp.599-606, 2002.
- [33] 小林光, 田中章浩, 木下健太郎, 岸田悟: 声紋による個人認証システムの構築, *信学*

- 技報, Vol.108, No.480, pp.13-17, 2009.
- [34] S.Onishi, A.Tanaka, H.Hasegawa, K.Kinoshita and S.Kishida, "Construction of Individual Identification System Using Voice in Three-layered Neural Networks", Proceedings of 2009 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS 2009), WP2-B-3, pp.635-637 2009.
- [35] H.Hasegawa, S.Onishi, K.Kinoshita and S.Kishida, "Effect of the Number of Input Layer Units on Performance of Voiceprint Identification Systems Using Layered Neural Network", Proceedings of 2010 International Workshop on Smart Info-Media Systems in Asia (SISA 2010), RS1-11, 2010.
- [36] I.Nakanishi, N.Nishiguchi, Y.Ito and Y.Fukui: On-line signature verification method using adaptive algorithm in wavelet transform domain, The 2002 International Technical Conference on Circuits/Systems, Computers and Communications(ITC-CSCC2002), Vol.1, pp.385-388, 2002.
- [37] 笹川 耕一: 指紋による個人認証, 生体医工学, 日本エム・イー学会誌, Vol.44, No.1, pp.15-19, 2006.
- [38] 前田 卓志, 松下 雅仁, 笹川 耕一: バイオメトリックス検索照合システムの性能モデル, 電子情報通信学会論文誌. D-I, 情報・システム, I-情報処理 Vol.87, No.6, pp.712-720, 2004.
- [39] H.Hasegawa, A.Tanaka, S.Kishida and K.Nishimura: Preprocessing method of fingerprint images in layered neural networks for individual identification, International Symposium on Intelligent Signal Processing and Consumer Electronics(ISPACS 2006), pp.267-270, 2006.
- [40] 若原 徹, 木村 義政, 鈴木 章, 塩 昭夫, 佐野 睦夫: 指紋隆線方向分布とマニューシャ対応付けを用いた指紋照合, 電子情報通信学会論文誌 D-II, 情報・システム, II-パターン処理, Vol.86, No.3, pp.63-71, 2003.
- [41] 田中章浩, 大西俊輔, 木下健太郎, 岸田悟: マニューシャ法により得られた指紋の特徴点とニューラルネットワークを用いた認証システムの構築, 信学技報, Vol.109, No.461, pp.237-242, 2010.
- [42] 田中 章浩, 西村 晃一, 岸田 悟, 渡部 徹, 長谷川 弘: ニューラルネットワークを用いた高速フーリエ変換前処理法における指紋照合システムの構築, 信学技報, Vol.105, No.659, pp.91-96, 2006.
- [43] 小林 哲二: 細線化画像パターンマッチングによる指紋照合, 電子情報通信学会論文

- 誌 D-II, 情報・システム, II-情報処理 Vol.79, No.3, pp.330-340, 1996.
- [44] D.E.Rumelhart, G.E.Hinton and R.J.Williams: Learning representations by back-propagating errors, *Nature*, Vol.323, No.9, pp.533-536, 1986.
- [45] システム制御学会編, "ニューラルネットと計測制御", 朝倉書店, 東京, 1995.
- [46] 伊東一良, "ニューロ・コンピューティング画像処理—汎化問題を中心として—", 日本放射線技術学会雑誌, Vol.50, No.1, pp.79-88, 1994.
- [47] 船橋正夫, "デジタル画像に求められる画像処理技術—前編—", 日本放射線技術学会雑誌, Vol.63, No.10, pp.1189-1199, 2007.
- [48] 船橋正夫, "デジタル画像に求められる画像処理技術—後篇—", 日本放射線技術学会雑誌, Vol.63, No.11, pp.1293-1302, 2007.
- [49] 中野馨, "ニューロコンピューターの基礎", コロナ社, 東京, 1990.
- [50] 船橋誠壽, "ニューロコンピューティング入門", オーム社, 東京, 1992.
- [51] 安居院猛, 長橋宏, 高橋裕樹, "ニューラルプログラム", 昭晃堂, 東京, 1993.
- [52] 熊沢逸夫, "学習とニューラルネットワーク", 森北出版, 東京, 1998.
- [53] T.Kohonen, "An Introduction to Neural Computing", *Neural Networks*, Vol.1, pp.3-16, 1998.
- [54] B.Biswas and A.Konar, "Speaker Identification from Voice Using Neural Networks", *Journal of Scientific and Industrial Research*, Vol.61, pp.599-606, 2002.
- [55] N.Cristianini and J.S-Taylor, "サポートベクターマシン入門", 共立出版, 東京, 2005.
- [56] 小野田崇, "サポートベクターマシン", オーム社, 東京, 2007.
- [57] 上田修功, "アンサンブル学習の新展開", *信学技報*, Vol.102, No.381, pp.31-36, 2002.
- [58] 小野田崇, 染谷博司, "ニューラルネットワーク研究の温故知新と最適化手法の研究動向", *電気学会論文誌*, Vol.130, No.1, pp.2-5, 2010.
- [59] L.K.Hansen and P.Salamon, "Neural Network Ensembles", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.12, No.10, pp.993-1001, 1990.
- [60] 上田修功, 中野良平, "アンサンブル学習における汎化誤差解析", *電子情報通信学会論文誌 D-II*, Vol.J80-D-II, No.9, pp.2512-2521, 1997.
- [61] D.Luo and C.Ke, "A comparative study of statistical ensemble methods on mismatch conditions", *Proc.IJCNN2002*, pp.59-64, 2002.
- ¥
- [62] V.G.Vovk, "Aggregating Strategies", *Proc. Computational Learning Theory*,

pp.371-386, 1990.

- [63] L.K.Hansen and P.Salamon, "Neural network ensembles", IEEE Trans. Pattern Anal. Machine Intell., vol.12, no.10, pp.993-1001, 1990.
- [64] 立石雅彦, 山崎晴明, "手書数字認識における階層型ニューラルネットワークの中間層に関する考察", 情報処理学会論文誌, Vol.30, No.40, pp.1281-1288, 1989.

研究業績

- 学術論文

- (1) 田中章浩, 木下健太郎, 岸田悟, ”ニューラルネットワークを用いた指紋認証システムの構築と性能評価”, Journal of Signal Processing, Vol.17, No.1, pp.1-10, Jan. 2013.

- 国際会議 (査読付 Proceedings)

- (1) Akihiro Tanaka, Kentaro Kinoshita, Satoru Kishida, ”Effect of the neural network size on performance of authentication systems for finger prints”, 2012 IEEE International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS 2012), pp.114-117, New Taipei City, Taiwan, Dec. 2012.
- (2) Akihiro Tanaka, Kentaro Kinoshita, Satoru Kishida, ”Construction of Neural Network Systems for Fingerprint Authentication”, 2012 RISP International Workshops on Nonlinear Circuits, Communications and Signal Processing (NCSP 2012), pp.784-787, Honolulu, USA, March 2012.

- 研究報告

- (1) 田中章浩, 岸田悟, ”ノイズを含む入力パターンがアンサンブル学習を持つニューラルネットワークシステムの汎化能力に与える影響”, 電子情報通信学会技術研究報告, Vol.113, No.343, pp.71-74, December 2013.
- (2) 田中章浩, 大西俊輔, 木下健太郎, 岸田悟, ”マニューシャ法により得られた指紋の特徴点とニューラルネットワークを用いた認証システムの構築”, 電子情報通信学会技術研究報告, Vol.109, No.461, pp.237-242, March 2010.
- (3) 小林光, 田中章浩, 木下健太郎, 岸田悟, ”声紋による個人認証システムの構築”, 電子情報通信学会技術研究報告, Vol.108, No.480, pp.13-17, March 2009.

- 学位論文の章と研究業績（学術論文，国際会議）の対応

| | 題目 | 雑誌名，会議名 |
|-----|---|------------|
| 第2章 | Construction of Neural Network Systems authentication systems for finger prints | NCSP2012 |
| 第3章 | ニューラルネットワークを用いた 指紋認証システムの構築と性能評価 | 信号処理学会誌 |
| 第4章 | Effect of the neural network size on performance of authentication systems for finger prints | ISPACS2012 |