

Title	量子化ニューロンモデルを用いたニューラルネットワークとそのハードウェア化に関する研究
Author(s)	丸野, 進
Citation	大阪大学, 2010, 博士論文
Version Type	VoR
URL	https://doi.org/10.18910/57477
rights	
Note	

Osaka University Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

Osaka University

量子化ニューロンモデルを用いたニューラルネットワークと
そのハードウェア化に関する研究

2010 年

丸 野 進

＜内容梗概＞

本論文は、高速学習認識処理が可能でハードウェア実装が容易な、量子化ニューロンモデルを用いたニューラルネットワークの研究成果についてまとめたものであり、基本構造とアルゴリズムに関する基礎検討、そのハードウェア化(LSI化)、並びに実用商品への展開までを総括して述べる。

第1章 序論

本章では、本研究の背景と目的について述べる。

ユーザーの好みや使用される環境に適応して行く知的機器の開発が望まれている中で、学習性を有し、柔軟な処理を行える可能性を秘めたニューラルネットワークによる実現が期待されている。筆者は、上記知的機器の実現に向けて、(1) 高速な学習認識と現場での追加学習が可能で、しかもハードウェア実装が容易なネットワークモデルを実現し、(2) そのハードウェア化を行い、実用機器への展開を図ることを目的に研究を行った。

第2章 量子化ニューロンの基本モデルと処理アルゴリズム

本章では、量子化ニューロンの基本構造と基本処理アルゴリズム、並びに量子化ニューロンを用いたネットワーク構造と学習認識アルゴリズムについて説明する。誤差逆伝播報による学習を用いた従来の階層型ニューラルネットワークと比較し、ハードウェア化が容易で、高速な学習と認識処理が可能であることを明らかにする。

典型的なアプリケーションである文字認識への適用事例では、従来の階層型ニューラルネットワークと比較して10倍以上の高速学習認識が可能で、実用性の観点で、飛躍的な性能向上が可能なことを検証する。

第3章 量子化ニューロンモデルを用いたニューラルネットワークのハードウェア化

本章では、量子化ニューロンモデルを用いたニューラルネットワークのハードウェア化の取り組みについて述べる。

量子化ニューロンによるネットワークは、ソフトウェアによる実行でも実用的には十分な高速学習認識性能を有するが、日本語文字認識等の大規模なネットワークを必要とするアプリケーションや、産業分野における超高速な画像認識においては、専用 LSI 化による高速化が望まれる。

作製した専用 LSI(QNC:Quantizer Neuron Chip)は、量子化ニューロンによるネットワークをハードワイヤードで構成したもので、第1層 64 ニューロン、第2層 64×8 ニューロン、第3層 64×8×8 ニューロン、第4層 64×8×8×8 出力端子、出力層 64 ニューロンを設けてあり、最大 4,736 個のニューロンからなるニューラルネットワークを実行可能にした。20.5G CPS (Connection Per Second)、20M CUPS (Connection Update Per Second) の実行速度を実証するとともに、この QNC を用いた高速手書き数字認識システムを開発実用化した。また、QNC を並列に結合することにより、日本語認識等に用いる大規模なネットワークをも構成可能にした。これらの取り組みの詳細について述べる。

第4章 適応増殖量子化ニューロン(ASQA)への拡張

本章では、ネットワークの自己生成が可能な適応増殖量子化ニューロン(ASQA:Adaptive Segmentation of Quantizer Neuron Architecture)への拡張について述べる。一般的にニューラルネットワークでは、ネットワーク構成そのものは最初の設計事項として固定であり、学習によるニューロン同士の結合荷重の変更のみによって学習課題に対する適応性を確保している。従って、ニューロンの数やネットワークの規模に関しては、試行錯誤的に決定するしか方法がなかった。

この課題に対応すべく、学習状況に応じてニューロンが分裂、増殖、結合し、

最適なネットワークを形成可能な、適応増殖量子化ニューロンへの拡張を行った。これにより、ネットワーク構成そのものも、学習により自動形成させることが可能になり、実用面での飛躍的な適応性を実現できた。

第 5 章 適応増殖量子化ニューロン(ASQA)のハードウェア化

本章では、適応増殖量子化ニューロン(ASQA)のハードウェア化の取り組みについて述べる。自己増殖によるネットワーク自動生成を実現すべく、ニューロン同士の結合荷重を外付けのメモリによって構成、ニューロ演算をシミュレートする演算部と、外付けメモリに保管したネットワーク中のニューロン同士の結合荷重をアドレッシングするネットワークアクセス部とによって構成することで LSI 化を試みた。作製した ASQA チップにより、手書き数字認識において 57,000 文字/秒の認識速度を実現した。この ASQA チップを用い、2,965 文字種からなる漢字認識システムを開発し、構造化ニューラルネットワークによる外部演算を含め、毎秒 570 文字の認識速度と、認識率 98.8%を実現した。

第 6 章 量子化ニューロンモデルの実用システムへの展開

本章では、第 5 章で述べた文字認識システムの開発実用化に加え、量子化ニューロンによるニューラルネットワークを用いた他の実用システムの開発の取り組みと、実現した実用システムの性能について述べる。産業分野での展開では形状検査装置を開発実用化、民生分野では、ビデオムービーのガンマ補正に適用、簡易ネットワークによるハードウェア化により、実用的商品を開発した。何れのシステムにおいても、世界最高レベルの性能を有していることを示す。

第7章 総括

本章では第2章から第6章までを総括し、結論とする。

量子化ニューロンモデルは、シンプルな構成と高速実行性を有し、ハードウェア実装が容易なモデルであり、実用性の高いニューラルネットワークを実現可能である。基本的なハードウェアとして、専用 LSI 並びに、民生機器にも実装可能な小規模回路を開発し、すでに数多くの実用製品で用いられつつある。

知的な認識処理を必要とする産業分野から、家電製品における知的制御まで、幅広い商品分野での今後の実用展開が期待される。

目次

第1章 序論	1
1.1 背景	1
1.2 研究の目的と概要	5
第2章 量子化ニューロンの基本モデルと処理アルゴリズム	7
2.1 量子化ニューロンの構造と動作	7
2.2 量子化ニューロンを用いた機能別階層ネットワーク (MFLN)	9
2.2.1 機能別階層ネットワークの基本構成	9
2.2.2 機能別階層ネットワークの基本認識過程	11
2.2.3 機能別階層ネットワークの基本学習過程	12
2.3 量子化ニューロンの文字認識への適用による性能検証	13
2.3.1 学習認識検討に用いた文字データ	13
2.3.2 特徴データ抽出方法	14
2.3.3 ネットワーク構成	14
2.3.4 学習認識実験方法	15
2.3.5 学習認識実験結果	16
2.4 量子化ニューロンの基本性能のまとめ	19
第3章 量子化ニューロンモデルを用いたニューラルネットワークのハードウェア化	20
3.1 量子化ニューロンチップ (QNC) の基本構造	20
3.1.1 量子化ニューロンチップの基本回路構成	21
3.1.2 量子化ニューロン演算のコンカレント実行	23
3.1.3 不要演算削減処理	24
3.2 量子化ニューロンボードの構成	25
3.3 開発した QNC 並びに量子化ニューロンボードの性能検証	26

3.3.1.	QNC の性能と諸元	26
3.3.2.	量子化ニューロンボードの性能検証	28
第 4 章	適応増殖量子化ニューロン (ASQA) への拡張	29
4.1.	適応増殖量子化ニューロンによるネットワークの自己生成	29
4.1.1.	適応増殖量子化ニューロンの構造	29
4.1.2.	量子化ニューロンの増殖	31
4.1.3.	量子化ユニットの分裂	32
4.2.	適応増殖ベクトル量子化ニューロン (ASQA-II) への拡張	34
4.2.1.	基本構造と動作	34
4.2.2.	ベクトル量子化ニューロンの分裂増殖	35
4.2.3.	ニューロンの複製による増殖	37
4.2.4.	適応増殖ベクトル量子化ニューロンによる機能別 階層ネットワーク	37
4.3.	適応増殖ベクトル量子化ニューロンの文字認識への適用検証	39
4.3.1.	学習認識実験に用いた文字データ	39
4.3.2.	入力特徴量	39
4.3.3.	ネットワーク構成	39
4.3.4.	認識処理	40
4.3.5.	学習処理	40
4.3.6.	学習認識実験結果	41
4.4.	適応増殖量子化ニューロン検討のまとめ	45
第 5 章	適応増殖量子化ニューロン (ASQA) のハードウェア化	46
5.1.	適応増殖量子化ニューロン (ASQA) チップの構成	46
5.1.1.	構造化ニューラルネットワーク NARA の概要	47
5.1.2.	ASQA チップの基本構造	48
5.1.3.	構造化ニューラルネットワーク NARA への対応方法	52

5.1.4.	メモリ削減モード	52
5.2.	ASQA チップの性能	53
5.3.	適応増殖量子化ニューロンハードウェア化のまとめ	56
第 6 章	量子化ニューロンモデルの実用システムへの展開	57
6.1.	形状検査装置への適用と実用化	57
6.1.1.	TASQA の構造と動作	58
6.1.2.	時系列統合ニューロン層の構造と動作	58
6.1.3.	TASQA の学習	59
6.1.4.	形状の ϕ - s 特徴変換	61
6.1.5.	TASQA による形状認識	62
6.1.6.	認識実験結果と考察	65
6.1.7.	形状検査装置への適用と実用化のまとめ	69
6.2.	逆光フリービデオムービーへの展開	70
6.2.1.	ニューロガンマ処理の入出力特性	71
6.2.2.	量子化ニューロンによるガンマ特性選択	79
6.2.3.	カメラの他のブロックとの協調動作	84
6.2.4.	ニューロガンマ処理による撮像画像	85
6.2.5.	逆光フリービデオムービーへの展開のまとめ	87
第 7 章	総括	88
7.1.	本研究の成果	88
7.1.1.	量子化ニューロンの基本モデルと処理アルゴリズム	88
7.1.2.	量子化ニューロンモデルを用いたニューラルネットワーク のハードウェア化	89
7.1.3.	適応増殖量子化ニューロン (ASQA) への拡張	89
7.1.4.	適応増殖量子化ニューロン (ASQA) のハードウェア化	90
7.1.5.	量子化ニューロンモデルの実用システムへの展開	90

7.2. 今後の展開	91
謝辞	93
参考文献	95
主要業績	105

第1章 序論

1.1 背景

人間のように柔軟で知的な機械を実現したいという欲求や取り組みは古くからあり、その初期には「計算機械」の実現に向けた取り組みから始まっている。最も原始的な「そろばん」は紀元前から存在するが、機械と言う観点では、1623年にシッカート (Wilhelm Schickard, 1592-1635) が考案した機械式計算機 (Calculating Clock) が最も古いと考えられる。1645年には、パスカル (Blaise Pascal, 1623-1662) がさらに進化した機械式計算機 (Pascaline) を考案した⁽¹⁾。加減算のみの Pascaline に対し、1671年にライプニッツ (G.W. Leibniz, 1646-1716) は、四則演算が行える計算機 (Stepped Reckoner) を発明した⁽²⁾⁽³⁾⁽⁴⁾⁽⁵⁾。

時代が進み、1843年には、バベッジ (Charles Babbage, 1791-1871) が、蒸気機関で動く解析エンジン (Analytical Engine) を構想し、開発に取り組んだ。解析エンジンは完成こそしなかったが、パンチカードによるプログラミング入力、記憶装置、演算装置、カード穿孔機、印刷装置等を備えたものであった。記憶装置にアドレスが無いので個別に指定できず、プログラム内蔵という概念もなく、現代のコンピュータとは異なる所があるが、少なくともその一部の原型を備えていたと言える⁽⁶⁾。

1946年には、エッカート (John Presper Eckert, 1919-1995) とモークリー (John William Mauchly, 1907-1980) らを中心とするグループが、電子式計算機であるエニアック (ENIAC) を開発、ノイマン型である現在のコンピュータへと発展し、社会における様々な分野で大きく貢献した。

しかしながら、以上述べた機械は計算を高度に、あるいは高速に行えるものであって、人間の高度な認識や判断、理解を代行できるものではなかった。エニアックの誕生以来、コンピュータの能力を計算以外でも活用しようとする取り組みが活発化した。シャノン (Claude Elwood Shannon, 1916-2001) は 1937年に

ブール代数の公理系を電子回路で表現できることを示し、1948年には情報伝達の本質を情報理論として体系化した⁽⁷⁾。ウィーナー(Norbert Wiener, 1894-1964)は生理学、機械工学、システム工学を統一的に扱おうとするサイバネティクスを創始した⁽⁸⁾。彼らの取り組みにより情報という概念が確立した。マッカーシー(John McCarthy)らは、「人工知能」(AI:Artificial Intelligence)に関する夏期研究会を1956年にダートマスで開催することを提案(ダートマス会議)⁽⁹⁾、以降AIに関する研究が盛んになり、日本でもAIを中心とした「第五世代コンピュータ」等の研究開発が行われた。これらの取り組みにより、プログラム言語や知識表現法、言語処理や推論機構等の技術が大きく発展したが、人間がいともたやすく行える文字認識や画像認識、音声認識等の問題で共通に存在する、「あいまいさ」や「ゆらぎ」への対応の点で課題を残した。

これらの課題に対し、記号処理的手法、あるいは知識表現的手法ではなく、人間や生物の知的な機能の根源である、神経細胞の機能までさかのぼって解明しようとする取り組みも始まった。1943年、マッカロックとピッツは生体の神経細胞の動作を数理モデル化した「形式ニューロン」(formal neuron)を考案⁽¹⁰⁾、1958年にはローゼンブラットが、この人工的な形式ニューロンを用いて層状にネットワークを形成した「パーセプトロン」を提唱⁽¹¹⁾、その学習機能を実証した。しかしこのパーセプトロンは線形分離しか行えないという欠点があり、ニューラルネットワークに対する研究は一時下火となったが、基礎的な取り組みは継続され着実に成果を上げるようになった。1969年中野馨は、自己想起、連想記憶が可能な、相互結合型のニューラルネットワークによる「アソシアトロン」⁽¹³⁾を提唱、1975年には福島邦彦が、文字認識が可能な自己組織的認識システム「コグニトロン」⁽¹⁴⁾を提唱した。1982年にはホップフィールド(John Joseph Hopfield)が、非同期型の相互結合型ネットワーク(Hopfield Network)によって連想記憶が可能であることを示し、1986年、ラメルハート(David E. Rumelhart)らは、誤差逆伝播学習法を用いることで階層型ニューラルネットワークの学習が可能

であることを示した⁽¹⁵⁾。

以上のような研究成果により、ニューラルネットワークが再び脚光を浴びるようになり、ニューラルネットワークに対する研究は、数理的研究段階から工学的研究開発、実用化段階に入った。

ユーザーの好みや使用される環境に適応可能な知的機器を実現するためのニューラルネットワークの要件を、実用化の視点から整理すると、

- (1) 学習に基づく識別境界の優れた非線形分離性能
- (2) 予め分かっているデータを学習するだけで、未学習のデータであっても柔軟、正確に認識可能な未学習認識性能
- (3) 学習済みデータを用いず、実用現場で得られる追加学習データのみによる学習で、学習済みデータの認識率を維持しながらも高速に学習可能となる追加学習性能

となる。さらには機器への実装を考慮すると、

- (4) 処理が軽く高速で、ハードウェア実装が容易な、ニューラルネットワークモデル
- (5) 上記モデルを用いたハードウェア化による高速処理
 - ・ 大規模カテゴリの学習認識へも対応可能なハードウェア構造
 - ・ 民生用機器向けのコンパクトなハードウェア

等を実現する必要がある。以上の要件の実現に向け、様々なニューラルネットワークの研究開発が行われてきた。

誤差逆伝播学習法を用いた階層型ニューラルネットワークは優れた学習性と非線形分離性能を有する事が実証されており、実用化に向けた多くの研究開発がなされた。アプリケーションへの適用研究だけでなく、中間層ニューロンの必要最小限化によるネットワーク規模の削減や効率化の取り組み⁽¹⁹⁾⁽²⁷⁾も行われてきた。これらの取り組みにより、前述の要件(1)と(2)に示した、学習に基づく非線形分離性能や未学習認識性能に関しては実現されつつある。しかし学習

に長い時間を要し、前述の要件(4)と(5)に示したハードウェア実装と高速処理の面で課題を残している。また誤差逆伝播学習法を用いた階層型ニューラルネットワークは、学習済みのネットワークに対し追加学習による微調整を行った場合、学習済みのパターン認識率が低下してしまう課題があり、この課題の解決に向け、メタ学習による追加学習法⁽²⁰⁾も提案されてきているが、これらの方法はメタ学習を行う新たなネットワークを付加する必要があるため、前述の要件(3)に示した追加学習性能に関しても一部課題を残している。

比較的良好な追加学習性を有するニューラルネットワークモデルとして、学習ベクトル量子化(LVQ:Learning Vector Quantization)⁽¹⁶⁾⁽¹⁷⁾、並びにRCEネットワーク(Restricted Coulomb Energy Network)⁽¹⁸⁾を挙げることができる。LVQは、入力パターンに対する最近傍ニューロン選択とそれに関する局所的な重み変更により学習を行うモデルであるため、追加学習による学習済みのパターン認識率低下が比較的少ない。また、RCEネットワークは、追加パターンと学習済みのパターンとの距離に応じて自動的に中間層ニューロンを生成するモデルで、高い追加学習性を有している。しかしながら、どちらのモデルもベクトル間の距離演算を必要とし、階層型ニューラルネットワークと同じく、前述の要件(4)と(5)に示したハードウェア実装と高速処理の面で課題を残している。

1.2 研究の目的と概要

以上 1.1 節で述べた背景の下、筆者はユーザーの好みや使用される環境に適応可能な知的機器の実現に向け、

- (1) 高速な学習認識と追加学習が可能で、しかもハードウェア実装が容易な、新ニューラルネットワークモデルの創出
- (2) 新ニューラルネットワークモデルのハードウェア化
- (3) 実用機器への展開
 - ・文字認識装置への展開
 - ・画像認識装置への展開
 - ・画像処理装置への展開

を目的に研究を行った。

高速な学習認識と追加学習、並びにハードウェア実装を実現するために、階層間の全ての結合係数を学習により最適化するのではなく、認識対象となる信号を予め大ぐりに分別した上で、学習による結合荷重変更を行うことで、ベクトル間の距離演算や指数関数演算等を必要としない新たなニューラルネットワークモデルである量子化ニューロンモデルを提案、高速学習性と優れた追加学習性を実証、そのハードウェア化を行い、文字認識装置への実用化展開を図った。

さらにはネットワークの自己生成が可能な適応増殖量子化ニューロン (ASQA: Adaptive Segmentation of Quantizer Neuron Architecture) への拡張を行った。一般的にニューラルネットワークでは、ネットワーク構成そのものは最初の設計事項として固定であり、学習によるニューロン同士の結合荷重の変更のみによって学習課題に対する適応性を確保している。従ってニューロンの数やネットワークの規模に関しては試行錯誤的に決定するしか方法がなかったが、適応

増殖量子化ニューロンを用いることで、学習状況に応じてニューロンが分裂、増殖、結合し、最適なネットワークを形成可能になり、実用面での飛躍的な適応性を実現できた。適応増殖量子化ニューロンのハードウェア化にも取り組み、ニューロン同士の結合荷重を外付けのメモリによって構成、ニューロ演算をシミュレートする演算部と、外付けメモリに保管したネットワーク中のニューロン同士の結合荷重をアドレッシングするネットワークアクセス部とによって構成することで、自己増殖によるネットワーク自動生成が可能な LSI を実現した。作製した ASQA チップにより、手書き数字認識において毎秒 57,000 文字の認識速度を実現した。この ASQA チップを用い、2,965 文字種からなる漢字認識システムを開発し、構造化ニューラルネットワークによる外部演算を含め、毎秒 570 文字の認識速度と、認識率 98.8%を実現した。

文字認識システムの開発実用化に加え、量子化ニューロンによるニューラルネットワークを用いた他の実用システムへの展開を図った。画像認識装置への展開においては、機構部品の形状検査装置を開発実用化した。この装置は毎秒 143 枚の速度で画像中の物体形状認識が可能である。

画像処理装置への展開においては、画像のガンマを最適に制御可能なニューロガンマ処理法を構築、民生機器にも適用可能な小規模回路構成を新たに創出することで、逆光フリービデオムービーの商品化を実現した。

第2章 量子化ニューロンの基本モデルと処理アルゴリズム

2.1 量子化ニューロンの構造と動作

誤差逆伝播法による学習を用いた階層型ニューラルネットワークは優れた学習性と非線形分離性能を有し、さらには、メタ情報による追加学習機能等も提案されてきている。しかしながら、各階層のニューロン間の結合荷重を全て学習によって形成するため、学習に時間を要し、実行速度、並びにハードウェアの点で、実用化に際しての課題が存在する。

そこで、各階層間のニューロン同士の結合荷重を全て学習によって形成するのではなく、認識対象となる特徴データを予め大ぐくりに分類し、分類したデータごとに、最終層のニューロンとの結合荷重を学習によって形成することで上記課題を解決すべく、新たなモデルの創出に取り組んだ。その結果、高速な学習認識と追加学習が可能で、しかもハードウェア実装に適した「量子化ニューロンモデル」を新規提案し、その導入を図ることができた。

図 2.1 に量子化ニューロンの基本構造を示す。量子化ニューロンは量子化信号入力端子 R から入力された特徴データ x を、出力端子数に応じたレベル数(図 2.1 の場合には 5 レベル)で量子化し、この量子化値 c に応じて、 r 番目の出力端子の結合荷重 τ_r を、式(2.1)に示すように、結合関数 g を用いて設定する。次に、式(2.2)に示すように選択信号入力端子 S から入力された伝達信号 t に、結合荷重 τ_r を掛け合わせて出力値 y_r を求め、上層に結合した量子化ニューロンの選択信号入力端子 S に入力する。

$$\tau_r = g(r, c) \quad (2.1)$$

この時 $c = [x]$ ($[\]$ は量子化関数)

$$y_r = t \tau_r \quad (2.2)$$




図 2.1 量子化ニューロンの基本構造

以上の量子化ニューロンの動作をまとめると、認識対象となる量子化入力信号を離散値に量子化して出力端子にマッピングし、出力端子ごとの結合荷重を、量子化入力信号に応じて設定し、多重に閾値処理を行うもので、これにより認識対象となる信号を予め大きくりに分別することができる。またこの処理は距離演算等を伴わず、高速に実行が可能である。図 2.2 は 3 つの出力端子を持つ量子化ニューロンを例に、この動作の概要をに示したものである。量子化器は、量子化信号入力端子から入力された特徴データを、レベル 0 からレベル 2 の、3 レベルに量子化する。また結合荷重 τ も、0 から 2 の 3 レベルに設定する。この時、量子化入力信号の大きさが中程度で、レベル 2 に量子化された場合、端子 2




図 2.2 量子化ニューロンの動作と結合関数

の結合荷重 τ_m が大きく設定 (例えば 2 に) され、出力端子 1 及び 2 の結合荷重 τ_b 及び τ_s は小さく (例えば 1 に) 設定される。量子化入力信号の大きさが大、小の場合にも同様にして、各端子の結合荷重 τ_b 、 τ_m 、 τ_s が量子化入力信号に応じて設定される。これらの動作は、式(2.3)として記述することもでき、ファジィ推論の前提部と同様の手続き記述型の処理となっており、またこれらの動作により、選択信号入力 of 伝達方向の振り分けを行うことができる。

$$\begin{aligned}
 & \text{if } \text{quantized data} = 0 \text{ then } \tau_s = 2; \quad \tau_m = 1; \quad \tau_b = 0 \\
 & \text{if } \text{quantized data} = 1 \text{ then } \tau_s = 1; \quad \tau_m = 2; \quad \tau_b = 1 \quad (2.3) \\
 & \text{if } \text{quantized data} = 2 \text{ then } \tau_s = 0; \quad \tau_m = 1; \quad \tau_b = 2
 \end{aligned}$$

2.2 量子化ニューロンを用いた機能別階層ネットワーク (MFLN)

2.2.1 機能別階層ネットワークの基本構成

図 2.3 に、量子化ニューロンを用いたニューラルネットワーク(機能別階層ネットワーク:MFLN)の構成例と、各層のニューロン間の結合荷重が設定される様子を模擬的に示す。この図は、3 種類の系列からなる 1 次元のデータを P 種類のカテゴリーにクラスタリングする場合の構成例を示したものであり、第 1 層

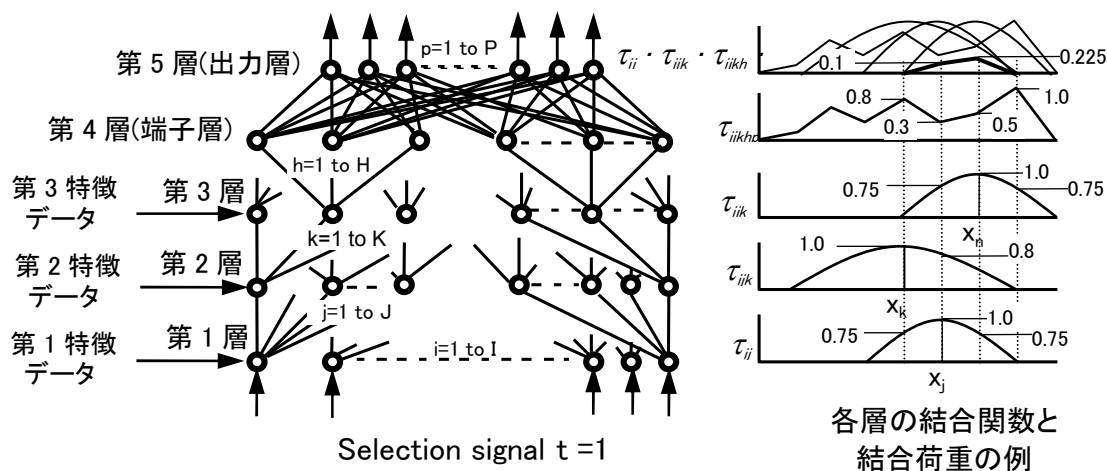


図 2.3 機能別階層ネットワークの構成例

から第 3 層までを量子化ニューロンを用いて構成し、第 4 層は端子層のみを設けた。これに通常のニューロンから成る第 5 層(出力層)を連結する。第 1 層はデータの次元数に対応する I 個の量子化ニューロンからなり、それぞれの量子化ニューロンに、第 1 層目の量子化レベル J に対応する J 個の第 2 層目のニューロンを連結する。第 2 層の各量子化ニューロンには、第 2 層目の量子化レベル K に対応する K 個の第 3 層目の量子化ニューロンを連結する。第 3 層の各量子化ニューロンには、第 3 層目の量子化レベル H に対応する H 個の出力端子を第 4 層として連結する。以上のように、第 1 層の各量子化ニューロンに、木分岐的に第 2 層目以降の量子化ニューロンを順次連結してネットワークを構成した。図 2.4 は、第 1 層中のニューロン Q_i 上に、 J, K, H をそれぞれ 3 として構成した木分岐構造の例を示す。この木分岐構造は、第 1 層のニューロン数と同数存在する。ここで第 1 層目のニューロン番号は i 、ニューロン Q_i の出力端子番号は j 、従って第 2 層目のニューロン番号は ij となる。ニューロン Q_{ij} の出力端子番号は k で、よって第 3 層目のニューロン番号は ijk となる。またニューロン Q_{ijk} の出力端子番号は h となり、第 4 層目の端子番号(第 4 層目は単なる端子層)は $ijkh$ となる。端子総数は $I \times J \times K \times H$ 個となり、第 4 層目の全端子 QT_{ijkh} と P 種類のカテゴリに対応する P 個の出力層のニューロンとを相互連結し、ネットワークを構成した。




図 2.4 木分岐構造によるネットワークの詳細例

2.2.2 機能別階層ネットワークの基本認識過程

まず初めに、第 1 層の量子化ニューロン全ての選択信号入力端子に、スカラー値として“1”を入力する。第 1 層から第 3 層までの量子化ニューロンは、量子化入力端子に入力した認識対象となる信号の、大ぐくりな分類結果に基づいて次層の量子化ニューロンとの結合荷重を設定する。第 1 層の量子化ニューロンの選択信号入力端子に入力した信号が各層の量子化ニューロンを伝達する中で、これらの結合荷重によって重み付けされて第 4 層まで到達、第 4 層と出力層である第 5 層との間で学習によって形成された結合荷重を掛け合わせ、第 5 層より最終識別結果を出力する。以上のプロセスについてさらに詳細に説明する。

第 1 層目から第 3 層目までの各ニューロンの量子化信号入力端子 R に、認識対象となる第 1 番目から第 3 番目までの特徴データをそれぞれ入力する。各層の量子化ニューロンは、入力された特徴データを各層に対応した量子化レベルにそれぞれ量子化し、次層のニューロンとの結合荷重 τ を、結合関数 g に基づいて設定する。第 1 層から第 3 層の任意の層中の量子化ニューロン番号を $\{nn\}$ 、出力端子番号を、これに連結した次層の量子化ニューロン番号（第 4 層の場合は端子番号）を $\{nn\}r$ 、次層のニューロンとの結合荷重を $\tau_{\{nn\}r}$ とした場合、結合関数 g は、例えば式(2.4)に示すように、入力データ x の量子化値 c と一致する出力端子番号 r で極大値を持つような 2 次関数によって記述でき、結合加重 $\tau_{\{nn\}r}$ を式(2.5)によって設定する。

$$g(r, c) = 1 - \beta (r - c)^2 \quad (2.4)$$

$$\tau_{\{nn\}r} = g(r, c) \quad (2.5)$$

但し、 $g(r, c) \leq 0$ の場合： $\tau_{\{nn\}r} = 0$

また、 $\{nn\}=i$: 第 1 層目のニューロンの場合
 $\{nn\}=ij$: 第 2 層目のニューロンの場合
 $\{nn\}=ijk$: 第 3 層目のニューロンの場合

第 3 層の出力端子と最終出力層との結合荷重は学習によって形成されたもので、最終出力層の P 個の通常のニューロンは式(2.6) に示すように、下層のセルから送られた信号と学習によって形成された結合係数 τ_{ijkhp} との積和をとり、閾値関数 f に基づいて発火出力 y_p を出す。最終出力層の最大出力を出しているニューロンの番号、すなわちカテゴリ番号を、ネットワークが出した認識結果とする。

$$y_p = f\left(\sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K \sum_{h=1}^H t \tau_{ij} \tau_{ijk} \tau_{ijkh} \tau_{ijkhp}\right) \quad (2.6)$$

i : 第 1 層ニューロン番号 (=1 to I)

j : 第 1 層ニューロン出力端子番号 (=1 to J)

k : 第 2 層ニューロン出力端子番号 (=1 to K)

h : 第 3 層ニューロン出力端子番号 (=1 to H)

p : 最終出力層ニューロン番号 (=1 to P)

t : 選択信号 (=1), τ : 結合荷重, g : 結合関数

f : 閾値関数, y_p : 発火出力

$$\tau'_{ijkhp} = \tau_{ijkhp} + \delta \quad (2.7)$$

2.2.3 機能別階層ネットワークの基本学習過程

基本認識過程において、最大出力を出している最終出力層のニューロンの番号が正しいカテゴリ番号を示す教師信号と一致しない場合、式(2.7)に示す荷重変更則に基づき、これらが一致する方向に向けて、第 4 層と最終出力層との結合荷重 τ_{ijkhp} を変更 (δ だけ増加) することで学習を行わせる。

第 3 層に選択入力信号が届いた時点で、量子化ニューロン同士の結合荷重による重み付けにより、認識対象となる特徴データの大ぐくりな分類ができており、比較的容易に、しかも高速に学習を行わせることが可能となる。

2.3 量子化ニューロンの文字認識への適用による性能検証

以上説明した量子化ニューロンによる機能別階層ネットワークを、典型的、かつ実用的な課題である 62 文字種 (0 から 9、a から z、A から Z) からなる英数字文字認識に適用することで学習認識性能の検証実験を行い、量子化ニューロンモデルの動作とその有効性の実証を行った。検証実験では異なる字体のフォントを複数使用し、フォントの差により文字形状が異なっても、同じ文字種であれば同じカテゴリとして認識結果を出すように教師付学習を行った。認識率の測定でも同様に、フォントの差によらず正しカテゴリ (文字種) として出力した場合に正解として認識率を測定した。なお全ての性能検証は、ワークステーション(Spark2)を用いたシミュレーションにより行った。

2.3.1 学習認識検討に用いた文字データ

英数 62 字種からなる 23 フォントの文字中、13 フォントを学習に用い、残り 10 フォントを未学習の文字の認識性能評価(未学習認識率)に用いた。図 2.5 に実験検討に使用した文字データの例を示す。

A B C D E F G H I J K L M N O P
Q R S T U V W X Y Z
a b c d e f g h i j k l m n o p
q r s t u v w x y z
1 2 3 4 5 6 7 8 9 0

A B C D E F G H I J K L M N O P
Q R S T U V W X Y Z
a b c d e f g h i j k l m n o p
q r s t u v w x y z
1 2 3 4 5 6 7 8 9 0

A B C D E F G H I J K L M N O P
Q R S T U V W X Y Z
a b c d e f g h i j k l m n o p
q r s t u v w x y z
1 2 3 4 5 6 7 8 9 0

図 2.5 学習認識実験に使用した文字データの例

2.3.2 特徴データ抽出方法

図 2.6 は文字認識に用いる特徴データの抽出方法を示したものである。2 値イメージとして取り込んだ文字を外接する方形の大きさに切り出し、 8×8 のメッシュをかけた上で各メッシュの濃度を演算し、(1) 8×8 のメッシュ濃度、(2)メッシュ濃度の横方向微分値、及び (3)メッシュ濃度の縦方向微分値を求め、8 ビットで正規化し、機能別階層ネットワークに入力するようにした。

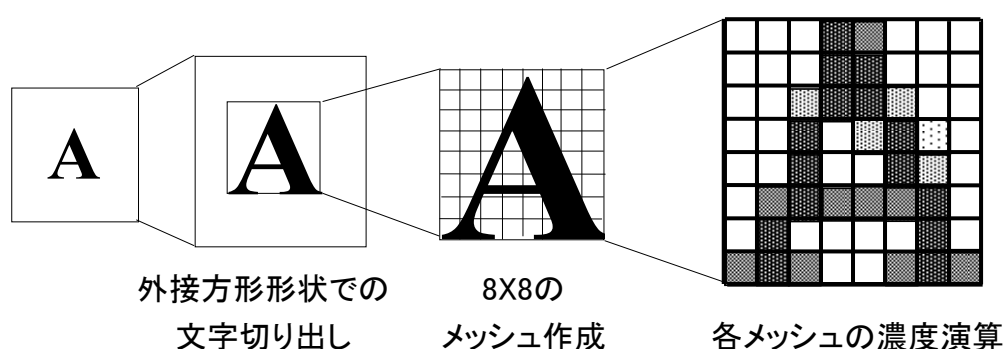


図 2.6 入力特徴量の抽出方法

2.3.3 ネットワーク構成

図 2.7 に、文字認識性能の評価実験に用いたネットワークの構成を示す。文字認識に用いる特徴データである $8 \times 8 = 64$ 個のメッシュ濃度に対応する、 $N=64$ 個の、図 2.4 に例示したような木分岐構造を構成した。具体的には、第 1 層を 8×8 のメッシュ数に対応する $N=64$ 個の量子化ニューロンによって構成、各ニューロンの量子化入力端子に入力したメッシュ濃度を 8 レベルで量子化し、64 個のニューロン各々に、量子化レベル 8 に対応する 8 個の第 2 層目のニューロンを連結した。第 2 層目のこれら 8 個全てのニューロンに、当該ニューロンが属する木分岐構造に対応したメッシュ濃度の横方向微分を入力(8 個のニューロンには全て同じ値を入力)、第 2 層目はこれを 8 レベルで量子化し、これに対応する 8

個の第3層目のニューロンを連結した。これら8個全てのニューロンに、当該ニューロンが属する木分岐構造に対応したメッシュ濃度の縦方向微分を入力、これを8レベルで量子化することにし、量子化レベル8に対応する8個の第4層目の端子を連結した。従って、第4層を $64 \times 8 \times 8 \times 8$ 個の端子によって構成した。最終出力層には英数字62字に対応する62個の通常の閾値処理ニューロンを配置し、第4層目の全出力端子と相互連結してネットワークを構成した。




図 2.7 文字認識性能評価に用いたネットワーク構成

2.3.4 学習認識実験方法

2.3.4.1 学習処理

学習処理では、各フォントの各文字種の特徴データ (8×8 の各メッシュ濃度、メッシュ濃度の横方向微分値、メッシュ濃度の縦方向微分値) を順次入力、各フォント、各文字種ごとに 2.2.1 項で示した基本認識過程を実行し、最終出力層の最大出力を出しているニューロンの番号を求めた。この時、式(2.4)における β を 0.5 に、式(2.7)の δ を 1 に設定した。この出力結果が英数字のカテゴリ番号 (文字種) を示す教師信号と一致しない場合に、すでに式(2.7)に示した荷重変更則

よって、これらが一致する方向に第 4 層の出力端子と出力層のニューロンとの結合荷重 τ_{ijkhp} を変更した。出力結果が教師信号と一致する場合には何もせず次の文字種の入力を行い学習を進めた。なお学習に用いた全てのフォントの全ての文字種の入力による一連の学習処理を 1 回の学習回数としてカウントした。

2.3.4.2 認識処理

毎回の学習処理が終了するごとに、全フォント(学習フォント 13、未学習フォント 10)全文字種の特徴データをネットワークに入力し、出力層の最大出力を出しているニューロンの番号を求め、教師信号との一致率を文字認識率として測定した。

2.3.4.3 初期学習性能評価

英数 62 字種からなる 23 フォントの文字中、13 フォントを学習に用い、残り 10 フォントを未学習文字の認識性能評価(未学習認識率)に用い、学習フォント並びに未学習フォントの認識率と学習回数との関係を調べた。

2.3.4.4 追加学習性能評価

13 フォントを初期学習済みのネットワークに対して、未学習フォント中の 7 フォントのみを用い、この 7 フォントの認識率が 100%になるまで追加的に学習を行わせ、学習に要する速度を測定するとともに、初期学習に用いた 13 フォントの認識率がどのような影響を受けるかを調べた。

2.3.5 学習認識実験結果

2.3.5.1 初期学習特性

図 2.8 に MFLN の初期学習の特性を示す。23 回の学習で、13 の学習フォント

の認識率が100%となり、またこの時の未学習フォントの認識率は72%に達した。

表 2.1 に他のニューラルネットワークモデル((1)Multi layered neural network with back propagation(いわゆるバックプロパゲーションモデル)、(2)Learning vector quantization、(3)RCE network)との初期学習速度の比較を示す。MFLN は、バックプロパゲーションモデルの約 10 分の 1 の学習回数、約 40 倍の学習速度を実現できることがわかる。

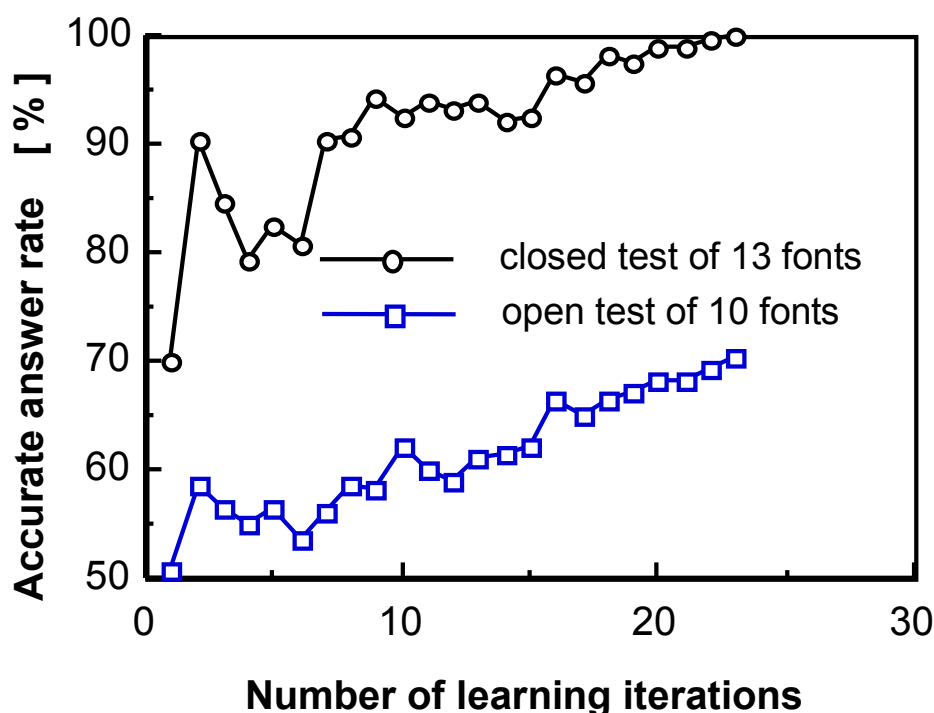


図2.8 文字認識課題に適用した場合のMFLNの初期学習特性

表 2.1 他のニューラルネットワークモデルとの初期学習速度の比較

model	Learning speed	
	Iteration	Time [min]
MFLN	23	4.5
Multi layered neural network with BP	200	192
	never went up to 100% in 250 minutes	
RCE network	5	17
LVQ3	20	170

2.3.5.2 追加学習特性

[追加学習速度]

図 2.9 に、他のニューラルネットワークモデルとの追加学習特性の比較を示す。図に示すように、MFLN は3回の学習で追加学習フォントの認識率が 100%となり、他のモデルと比べ、最も高速に追加学習を行うことができた。

表 2.2 に、追加学習速度、並びに 13 の初期学習フォント認識率の変化の比較を示す。MFLN の追加学習速度は 83 秒で、バックプロパゲーションモデルの約 600 倍の速度で学習できることがわかる。

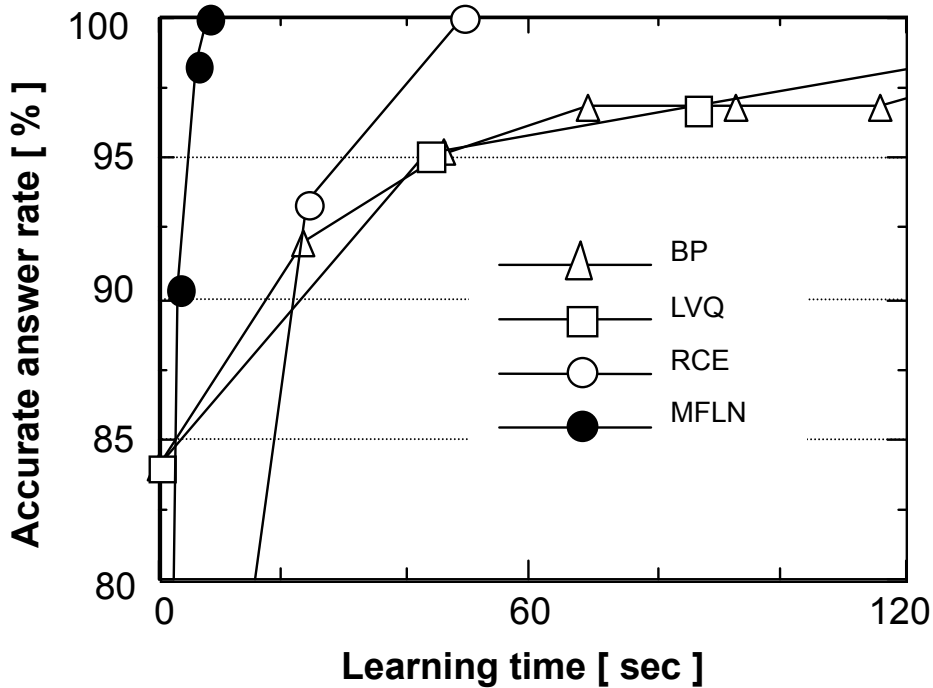


図 2.9 他のニューラルネットワークモデルとの追加学習特性の比較

BP: Multi layered neural network with back propagation

LVQ: Learning vector quantization

RCE: RCE network

MFLN: 機能別階層ネットワーク

[初期学習フォントの認識率変化]

表 2.2 に示すように、7 フォント追加学習後の 13 初期学習フォントの MFLN による認識率は 97.4%で、追加学習による初期学習結果の影響が他のネットワークモデルに比べ最も少なく、高い初期学習フォントの認識率を実現している。

表 2.2 他のニューラルネットワークモデルとの追加学習特性の比較

Model	Supplemental learning speed [sec]	Recognition accuracy of the 13 initial learning fonts [%]
MFLN	83	97.4
Multi layered neural network with BP	4,800	94.5
RCE network	652	96.4
LVQ3	3874	96.5

2.4 量子化ニューロンの基本性能のまとめ

量子化ニューロンモデルとこれを用いた機能別階層ネットワークを提案し、典型的なアプリケーションである文字認識に適用して、その基本性能の検証を行った。MFLN の学習速度は、他のニューラルネットワークモデルに比べ極めて高速で、代表的モデルであるバックプロパゲーション学習による階層型ニューラルネットワークに比べ、約 10 分の 1 の学習回数、約 40 倍の学習速度を実現できた。

追加学習も極めて高速に行え、代表的モデルであるバックプロパゲーションモデルに比べ 600 倍以上の高速学習を実現できた。また初期学習フォント(学習済みのデータ)を用いず、追加学習フォント(実用現場で得られる追加学習データ)のみによる追加的な学習を行っても、過去に学習した初期学習フォント(学習済みのデータ)の認識率を 97.4%と、非常に高く維持することができ、ユーザーの好みや使用される環境に適応して行く機器に向けた基礎能力を実証できた。

第3章 量子化ニューロンモデルを用いたニューラルネットワークの ハードウェア化

量子化ニューロンによるネットワークは、ソフトウェアによる実行でも実用的には十分な高速学習認識性能を有するが、日本語文字認識等の大規模なネットワークを必要とするアプリケーションや、産業分野における超高速な画像認識においては、専用 LSI 化による更なる高速化が望まれる。

文字認識や画像認識等の実用的なアプリケーションへの適用を可能にするため、4,736 ニューロンからなるネットワークを高速で実行可能な専用 LSI(QNC: 量子化ニューロンチップ)とこれを用いた量子化ニューロンボードを開発した。

量子化ニューロンチップは第1層(入力層)64 ニューロン、第2層 64×8 ニューロン、第3層 64×8×8 ニューロン、第4層 64×8×8×8 端子、出力層 64 ニューロンからなり、20.5G CPS、20M CUPS の性能を実現した。また、量子化ニューロンチップを並列に結合することにより、出力層のニューロン数を自在に拡張可能であり、日本語認識等に用いる大規模なネットワークの構成も可能にした。

3.1 量子化ニューロンチップ(QNC)の基本構造

量子化ニューロンによるネットワークをハードワイヤードで構成し、高速実行を可能にした。膨大な量のシナプス結合の処理を高速に行わせるために、新たな2つのスキームを導入した。一つ目は、「量子化ニューロン演算のコンカレント実行」であり、これにより、量子化ニューロンの処理を超並列に行うことができる。二つ目のスキームは「不要演算削除処理」であり、これにより、結果に意味を成さない0の乗算を削除し、高速な処理を行わせることができた。

3.1.1 量子化ニューロンチップの基本回路構成

MFLN の 3 つの入力レイヤーの演算を行う 3 つの演算回路と、出力ニューロン層の演算を行う演算回路を独立に設け、それぞれを同時並列演算すると同時に、各入力レイヤー中の各ニューロンの演算をもコンカレントに実行可能な回路構成を実現することで、超高速なネットワーク演算を可能にした。以下、その構成について詳細に述べる。

図 3.1 に量子化ニューロンチップのブロック図を示す。QNC を 3 つの量子化ニューロンブロック (QN block)、乗算 ROM (MPY-ROM)、出力ニューロンブ

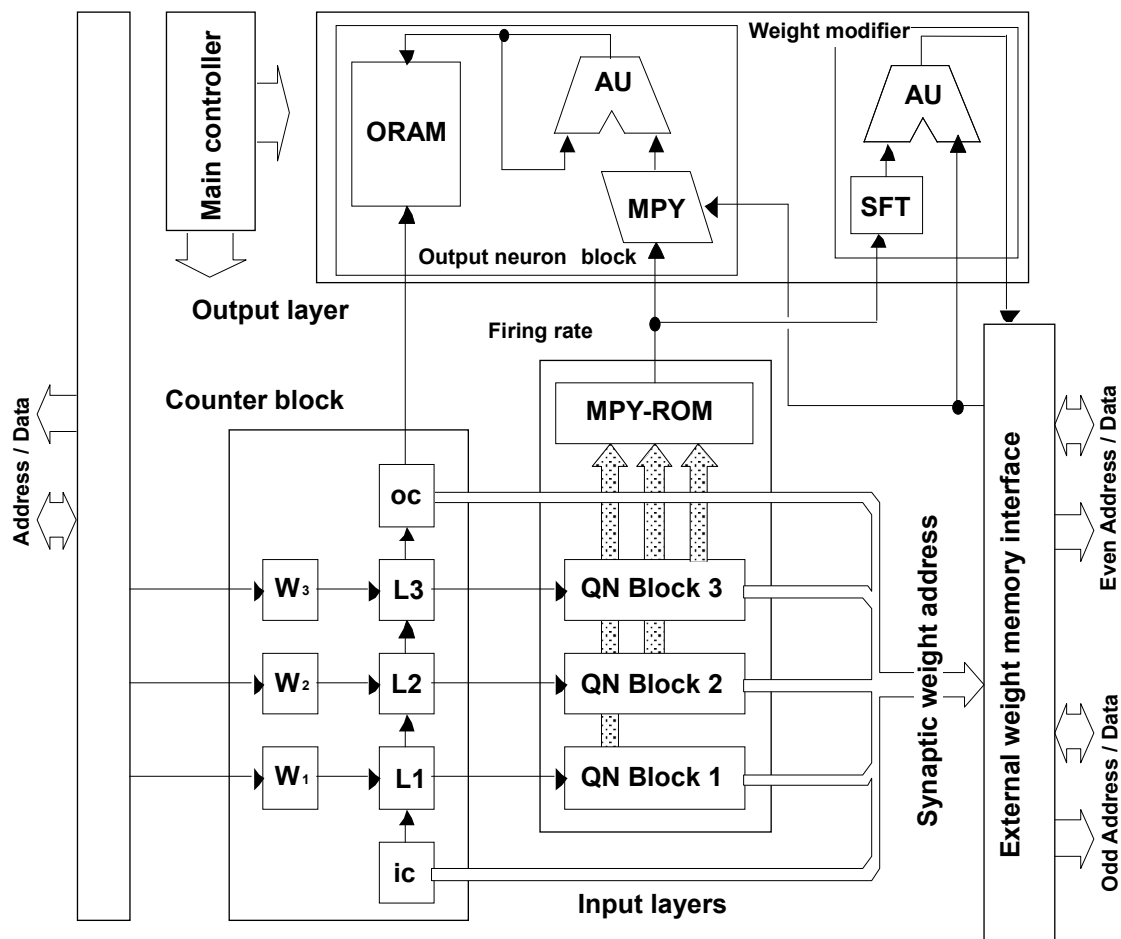


図3.1 量子化ニューロンチップのブロック図

ック (output neuron block)、荷重変更器 (weight modifier)、カウンタブロック (counter block)、及びメインコントローラ (main controller) とによって構成することで、3つの入力層と出力層のニューロンの同時並列演算を可能にした。

図 3.2 に、量子化ニューロンブロック (QN block) の詳細を示す。各量子化ニューロンブロックは、結合関数 RAM (CRAM)、量子化テーブル RAM (LRAM)、入力 RAM (IRAM)、アドレス変換器 (Address converter) によって構成することで、全ての入力層の全量子化ニューロンをシミュレート可能にした。

3bits × 8words のメモリからなる CRAM は、2.2.3 項の式 (2.4) で示した結合関数をテーブルとして保存する。256 words × 3bits のメモリからなる LRAM は、量子化テーブルを保存し、入力データを 8 レベルにマッピングして量子化する。64 words × 3bits のメモリからなる IRAM は、LRAM による量子化結果を保存する。MPY-ROM は 3つの QN Block の信号を乗算し、第 3 層の量子化ニューロンの発火値を演算する。

出力ニューロンブロック (output neuron block) は、64 個の出力ニューロンをシミュレートする。外部接続メモリ (external weight memories) に保存したシナプス荷重と MPY-ROM の発火値の積和をとり、結果を出力 RAM (ORAM) に保存する。

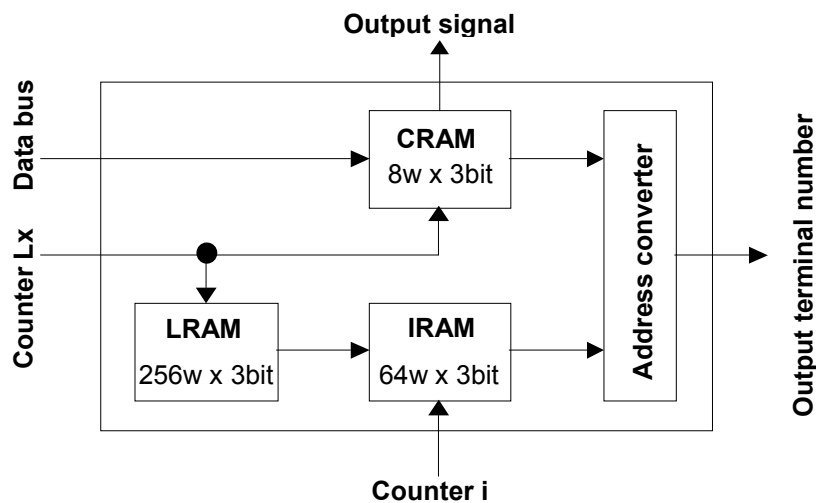


図3.2 量子化ニューロンブロック (QN Block) の詳細

荷重変更器 (weight modifier) は、学習モード時のみに働き、MPY-ROM の値と外部接続荷重のメモリに保存したシナプス荷重の値に応じ、荷重変更則を用いて、荷重変更後のシナプス荷重を求める。

以上の構成により 64 次元 $\times 3 = 192$ 次元のデータ入力と 64 次元の出力を行う機能別階層ネットワークをシミュレート可能な量子化ニューロンチップを実現した。

カウンタブロック (counter block) を 5 つのカウンタと 3 つのレジスタによって構成し、これにより入力層と出力層の演算中のニューロン番号を供給する。入力カウンタ ic は、各 QN Block の IRAM 中にある入力データのアドレスを示し、L1、L2、及び L3 カウンタは、それぞれ各 QN Block の CRAM 中に保存した結合関数の、所定の読み出しアドレスのカウントに用いる。W1、W2、及び W3 レジスタは、L1、L2、及び L3 カウンタによってカウントアップする結合関数の有効領域を設定するが、この W レジスタの動作と目的については後で詳細に説明する。出力カウンタ oc は、ORAM 中に保存した出力値のアドレスを指し示す。従って、これらのカウンタをインクリメントすることで、各 QN Block は、各入力層中の全ての量子化ニューロンをシミュレートできる。

メインコントローラ (main controller) はホスト CPU の I/O スペースへのレジスタのマッピングを行い、これによりホスト CPU は、ニューラルネットワーク構造に関する全てのパラメータのセッティング、実行モード (学習または認識) の設定、データの入力、演算の実行タイミングを制御できる。

3.1.2 量子化ニューロン演算のコンカレント実行

前述した 3 つの QN Block は並列に動作するだけでなく、各 QN Block において、出力値と出力端子番号の演算とをコンカレントに行う。具体的には、 3 つの QN Block の出力値は MPY-ROM により、第 3 層の量子化ニューロンの発火値として変換されると同時に、外部メモリに保存したシナプス結合荷重のアドレス

を、QN Block の出力端子番号と、入力カウンタ **ic** と出力カウンタ **oc** の値によって一義的に変換し、また、これらの変換を同時並列で実行する。

以上のプロセスにより、大規模なシナプス荷重を有するネットワーク構成であっても、非常に高速な学習と認識の処理を可能とした。

3.1.3 不要演算削除処理

演算の高速化を図るためには、0 の乗算等の不要演算の削減も重要な要素である。例えば図 3.3 に示す結合関数が CRAM に設定されている場合、量子化ニューロンの 8 つの端子中 5 つの端子の結合荷重が 0、従って出力値が 0 になり、これら 0 の値を持つ端子の乗算を省くことで高速化を図ることができる。

QNC の学習、認識実行時には、5 つのカウンタ (**ic**、**L1**、**L2**、**L3**、**oc**) をインクリメントしながら、CRAM、LRAM、IRAM のアドレスを設定して実行を行うが、結合関数の有効領域を設定する **W** レジスタを 3 にセットしておくことで、カウンタ **L** は最大 3 までしかカウントアップしなくなり、外部接続メモリへのアクセスを含め、0 値を有する 5 つの端子の演算をスキップさせることができる。

これにより、学習、認識何れのプロセスにおいても、19 (= $8/3 \times 8/3 \times 8/3$) 倍の高速化を図ることができた。

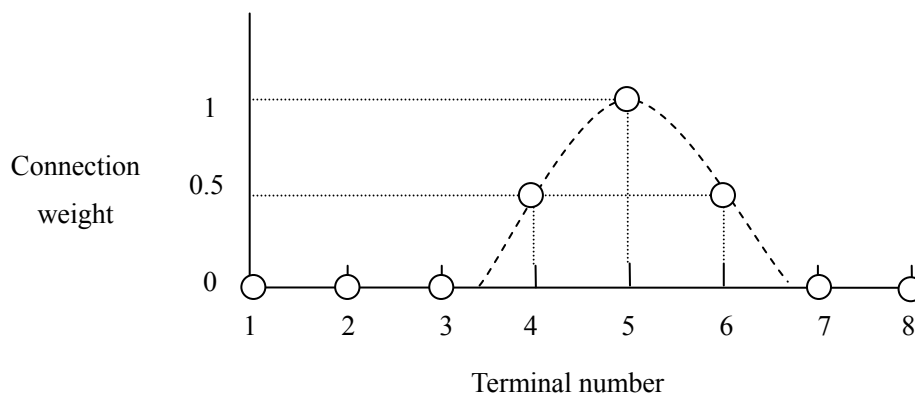


図 3.3 CRAM 中の結合関数の事例

3.2 量子化ニューロンボードの構成

図 3.4 に量子化ニューロンボードのブロック図を示す。量子化ニューロンボードをメインボードとメモリボードによって構成した。メインボードを QNC とアドレスデコーダーとによって構成し、メモリボードは、QNC のシナプス荷重を保存する外部メモリとして構成した。

量子化ニューロンボードを接続したホスト PC から、ネットワーク構造のパラメータの設定、学習または認識のモード切替、演算の実行開始を、PC Bus を介して制御可能にした。また、QNC のメインコントローラのコントロールレジスタにマッピングされた I/O スペースを介して、学習と認識に用いる入力データを QNC に入力できる。

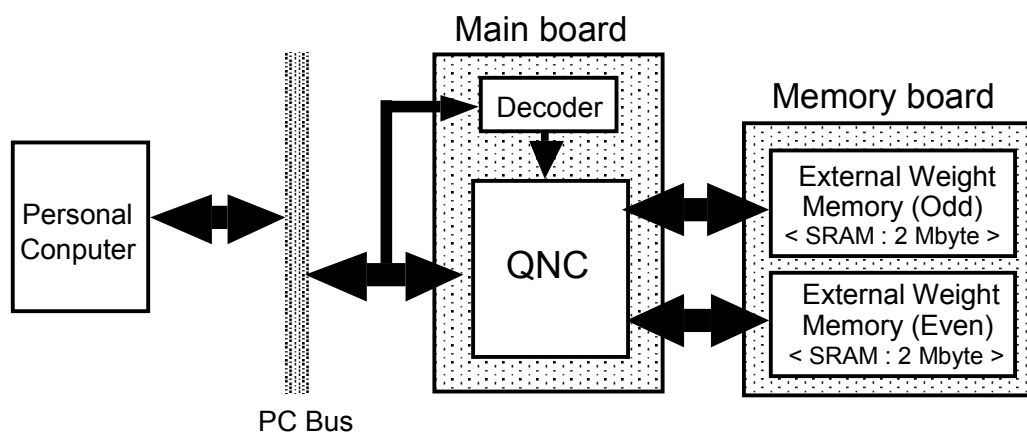


図 3.4 量子化ニューロンボードのブロック図

3.3 開発した QNC 並びに量子化ニューロンボードの性能検証

3.3.1 QNC の性能と諸元

開発した QNC は、1.2 μ m、ダブルメタル CMOS プロセスを用いたもので、27,000 ゲートを有し、ダイサイズは 10.99 mm \times 10.93 mm、25nsec (40MHz) のクロック サイクルで実行可能であり、4,736 ニューロンと 2,000,000 シナプス荷重を用いた MFLN のネットワーク演算 (W レジスタ (結合関数の有効領域) の値が 3 の場合) を 2.8ms で実行できる。

ニューラルネットワーク演算における結合荷重演算速度 (CPS: Connection Per Second) を求めると、20.5G CPS (at W=1)、0.76G CPS (at W=3) であった。また、学習を行わせた場合の結合荷重変更速度 (CUPS: Connection Update Per Second) を求めると、20M CUPS であった。

QNC は、任意の容量の外部メモリを増設することで、容易に大規模なニューラルネットワークを実現することができ、また、非常に高速な学習認識処理を実現可能である。開発した QNC のチップ写真を図 3.5 に、諸元を表 3.1 に示す。




図 3.5 量子化ニューロンチップのチップ写真

表 3.1 QNC の諸元

No. of simulation neurons	4,736
No. of synapses	2,101,760
Recognition speed at W= 1	0.76 GCPS
Recognition speed at W= 3	20.5 GCPS
Learning speed at W= 3	20.0 MCUPS
Precision of synapse weight	16 bits
Clock rate	40 MHz
Power supply	5.0 V
Power dissipation	1.0 W (at 40 MHz)
Process technology	1.2 μ m CMOS
No. of gates	27,000
Chip size	10.99 x 10.93 mm
package	160pin QFP

3.3.2 量子化ニューロンボードの性能検証

図 3.6 に開発した量子化ニューロンボードの写真を示す。

開発した量子化ニューロンボードを、20MHz 駆動のホスト PC (Cx486DLC-20MHz CPU) に接続し、動作検証を行った。クロック 20MHz の駆動において、毎秒 1,030 パターンの認識が可能であり ($64 \times 3 = 192$ 次元の入力データ、62 出力ニューロン、 $W=1$)、ワークステーション Solbourne series 5 (22 MIPS、3 MFLOPS) によるシミュレーションと比較し、約 25 倍の高速処理を可能にした。

開発した量子化ニューロンボードを用い、手書き数字認識システム (64×3 次元入力データ、10 出力ニューロン、 $W=3$) を開発した結果、各数字 500 サンプルの学習をわずか 32 秒で行わせることができた。

以上のように、量子化ニューロンモデルを専用ハード化することにより、汎用 CPU による演算処理に比べ桁違いの高速化を実現、使用現場での状況に即応したアダプティブな学習認識処理が可能となった。




図 3.6 開発した量子化ニューロンボード

第4章 適応増殖量子化ニューロン(ASQA)への拡張

一般的にニューラルネットワークでは、ネットワーク構成そのものは、最初の設計事項として固定であり、学習によるニューロン同士の結合荷重の変更のみによって学習課題に対する適応性を確保している。従って、ニューロンの数やネットワークの規模に関しては、試行錯誤的に決定するしか方法がなかった。

前章までに、その高速学習性能と追加学習性能を実証した、量子化ニューロンモデルによる機能別階層ネットワークにおいても、量子化ニューロン層の各ニューロン数や量子化レベル数を一義的に決める手法は無く、計算論的に、あるいはハードウェアとして実現できる最大数を割り当ててネットワークを構成するか、ないしは、膨大なチューニング実験に基づいて決定するしかなかった。

この課題に対応すべく、学習状況に応じて、ニューロンが分裂、増殖、結合し、最適なネットワークを形成可能な、適応増殖量子化ニューロン(ASQA: Adaptive Segmentation of Quantizer neuron Architecture)への拡張を行った。これにより、ネットワーク構成そのものも、学習により自動形成させることが可能になる。本章では、適応増殖量子化ニューロンモデルの詳細について述べるとともに、この拡張により、実用面で飛躍的な適応性を確保できることを検証する。

4.1 適応増殖量子化ニューロンによるネットワークの自己生成

4.1.1 適応増殖量子化ニューロンの構造

これまで説明してきた量子化ニューロンの基本構造を、ニューロンの分裂増殖が可能なモデルへ拡張するために、図4.1に示す量子化ユニットの概念を導入する。量子化器を上限値 XU_i と下限値 XL_i を量子化範囲として持つ量子化ユニットによって構成する。各量子化ユニットは入力された量子化入力データの平均 A 、

分散 σ 、結合荷重変更回数 n 並びに量子化ユニットの内部状態を表わす変数 E を有している。データ x が各量子化ユニットに入力され、式(4.1) に示すように、 x が c 番目の量子化ユニット U_c の量子化範囲に入っていれば量子化ユニット U_c が反応し、量子化ユニット U_c に連結した結合荷重 τ_c を 1 に設定し、その他の量子化ユニットに結合した結合荷重 τ_i を、結合係数 β を含めた式(4.2)および式(4.3)によって求める。ただし、 $g(i, c)$ が負であれば、 τ_i に 0 を代入する。

$$\tau_c = 1 \quad (XL_c \leq x < XU_c \text{ の場合}) \quad (4.1)$$

$$g(i, c) = 1 - \beta (i - c)^2 \quad (4.2)$$

$$\tau_i = g(i, c) \quad (4.3)$$

ただし、 $g(i, c) \leq 0$ の場合には、 $\tau_i = 0$

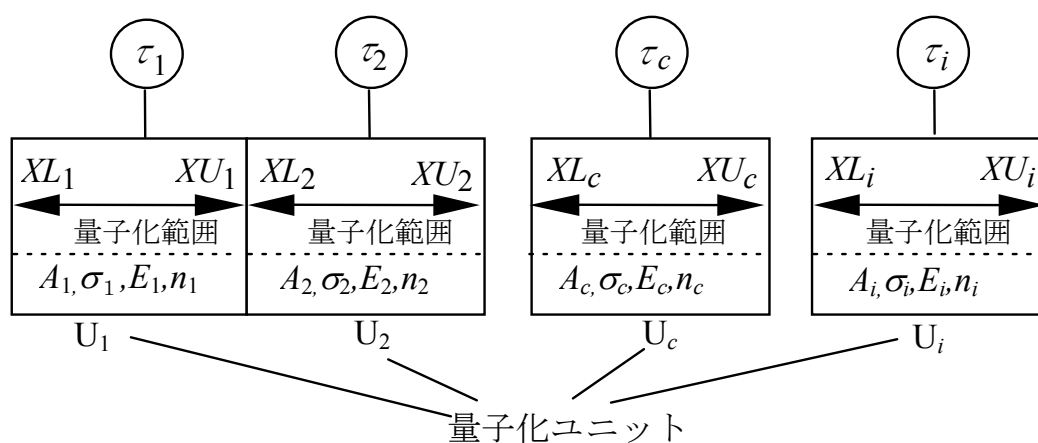


図 4.1 量子化器の構造

4.1.2 量子化ニューロンの増殖

量子化ニューロンの増殖は、量子化ユニットの分裂と、連結されている他の量子化ニューロンの複製によって行う。初期状態の量子化ニューロンの量子化ユニット数は 1 に設定してあり、また、入力の対象となる量子化入力データの分布の全域に反応するように量子化の範囲を設定した。量子化ニューロンに何らかの学習指示信号が与えられると、入力データ x に反応した量子化ユニットは、過去の平均 A_{io} 、分散 σ_{io} 、学習回数 n_{io} 及び入力データ x を用い、量子化入力端子から入力された全データの平均 A_i 、分散 σ_i 、学習回数 n_i 及び内部状態 E_i を近似式(4.4)～(4.7)に基づいて演算する。

量子化ユニットの量子化範囲が広すぎて結合荷重の変更だけではデータの学習が進まない場合に、量子化ユニットを自動的に分裂させる。そのためには学習の困難さを表す指標が必要となる。そこで、内部状態 E_i を式(4.7)に示すように、学習回数と分散との積で表現することで、学習の困難さを表す指標として用いた。

内部状態 E_i は、学習が難しく学習回数が増加するほど、また量子化ユニットが反応したデータ群の分散が大きいほど増大する。内部状態 E_i が式(4.8)で示す分裂条件を満たした場合に、量子化ユニットの分裂並びに量子化ニューロンの複製を行い、量子化ニューロンを増殖させる。

$$A_i \cong \frac{n_{io} A_{io} + x}{n_{io} + 1} \quad (4.4), \quad \sigma_i \cong \frac{n_{io} \sigma_{io} + |x - A_i|}{n_{io} + 1} \quad (4.5)$$

$$n_i = n_{io} + 1 \quad (4.6), \quad E_i = n_i \sigma_i \quad (4.7)$$

$$\text{分裂条件} : E_i > \alpha \quad (\alpha: \text{定数}) \quad (4.8)$$

4.1.3 量子化ユニットの分裂

量子化ユニット U_i の内部状態 E_i が閾値 α を越えた場合、図 4.2 に示すように量子化ユニット U_i を、 U_i と U_{i+1} の 2 つに分裂させる。この時、平均 A_i を分裂境界 Th_i として量子化範囲を 2 つに分割し、分裂後の量子化ユニット U_i 及び U_{i+1} の量子化範囲を式 (4.9) ~ (4.12) を用いて求める。さらに、それぞれの量子化ユニットの平均 A_i 及び A_{i+1} 、分散 σ_i 及び σ_{i+1} 、学習回数 n_i 及び n_{i+1} を式 (4.13) ~ (4.16) を用い、また、内部状態 E_i 及び E_{i+1} を式 (4.8) を用いて演算する。量子化ユニット U_{i+1} の結合荷重 τ_{i+1} は、式 (4.17) に示すように、量子化ユニット U_i の結合荷重 τ_i をそのまま複製して用いる。

量子化ユニットの分裂を行わせた後、図 4.3 に示すように、当該ニューロン QN_1 に連結したニューロン QN_2 の複製 QN_2' を作成し、量子化ユニット U_{i+1} の結合荷重 τ_{i+1} と QN_2' の入力端子とを連結する。以上の処理により、入力データに応じて適応的に量子化ニューロンを増殖させ、ネットワークの自己生成を行わせることができる。

$$XL_{i'} = XL_i \quad (4.9), \quad XU_{i'} = Th_i = A_i \quad (4.10)$$

$$XL_{i+1} = Th_i = A_i \quad (4.11), \quad XU_{i+1} = XU_i \quad (4.12)$$

$$A_i = \frac{XL_{i'} + XU_{i'}}{2} \quad (4.13)$$

$$A_{i+1} = \frac{XL_{i+1} + XU_{i+1}}{2} \quad (4.14)$$

$$\sigma_{i'} = \sigma_{i+1} = 1 \quad (4.15), \quad n_{i'} = n_{i+1} = 1 \quad (4.16)$$

$$\tau_{i+1} = \tau_i \quad (4.17)$$




図 4.2 量子化ユニットの分裂




図 4.3 量子化ニューロンの複製と増殖

4.2 適応増殖ベクトル量子化ニューロン(ASQA-II)への拡張

4.2.1 基本構造と動作

以上説明した適応増殖量子化ニューロンを、ベクトルの量子化入力可能な適応増殖ベクトル量子化ニューロン(ASQA-II)へ拡張する。基本的構造はこれまで説明してきたスカラーの量子化ニューロンと全く同じで、量子化器の各量子化ユニットの量子化範囲 XU と XL 、入力データの平均 A 、分散 σ 、学習回数 n 並びに内部状態を表わす変数 E をベクトル化し、それぞれ、 \overline{XU}_i 、 \overline{XL}_i 、 \vec{A}_i 、 $\vec{\sigma}_i$ 、 \vec{n}_i 、 \vec{E}_i とする。

ベクトルデータ \vec{x} が各量子化ユニットに入力され、式(4.18)に示すように、 \vec{x} が量子化ユニット U_c の量子化範囲に入っていれば量子化ユニット U_c が反応し、量子化ユニット U_c に連結した結合荷重 τ_c を 1 に設定する。量子化範囲が量子化ユニット U_c に隣りあう全てのユニット U_i に連結した結合荷重 τ_i を、 U_c と隣りあっている次元 s における入力データ \vec{x} とユニット U_i との距離 $|x_s - A_{is}|$ に応じて、式(4.19)に示すように結合係数 β を用いて設定する。式(4.19)は式(4.2)をベクトル拡張したものであるが、ベクトル拡張に当り、二乗演算簡略化のため、入力データ \vec{x} とユニット U_i との距離 $|x_s - A_{is}|$ と、隣り合う量子化ユニット同士との距離 $|A_s - A_{is}|$ との比に基づき、入力データ \vec{x} とユニット U_i との距離が近い程、結合荷重 τ_i が大きく設定できるようにした。図 4.4 に 2 次元ベクトル量子化ニューロンの結合荷重設定の様子を示す。ユニット U_8 がデータ \vec{x} に反応すると、結合荷重 τ_8 が 1 に設定され、また隣あうユニット U_2 、 U_7 、 U_9 、 U_{12} の結合荷重 τ_2 、 τ_7 、 τ_9 、 τ_{12} が式(4.19)に基づいて設定される。

$$\tau_c = 1 \quad (\overline{XL}_c \leq \vec{x} < \overline{XU}_c \quad \text{の場合}) \quad (4.18)$$

$$\tau_i = \beta \left(1 - \frac{|x_s - x_{is}|}{|A_s - A_{is}|} \right) \tau_c \quad (4.19)$$

($\overrightarrow{XL}_i \cap \overrightarrow{XU}_c = 1$ または $\overrightarrow{XU}_i \cap \overrightarrow{XL}_c = 1$ の場合)

$$\vec{x} = \{ x_1, x_2, x_3 \dots, x_s, \dots, x_m \}$$

$$\vec{A}_i = \{ A_{i1}, A_{i2}, A_{i3}, \dots, A_{is}, \dots, A_{im} \}$$

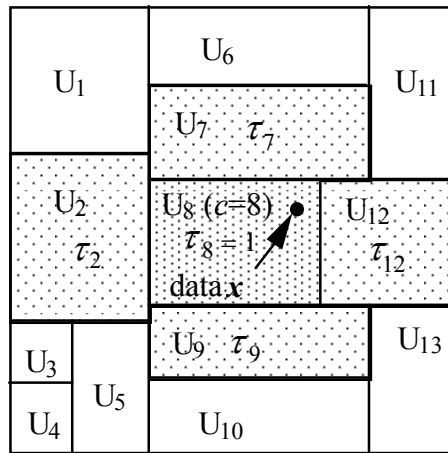


図 4.4 ベクトル量子化ニューロンの結合荷重の設定

4.2.2 ベクトル量子化ニューロンの分裂増殖

ベクトル量子化ニューロンの増殖は、すでに説明したスカラータイプの量子化ニューロンの分裂増殖プロセスをベクトルに拡張することで、全く同じように行わせることができる。初期状態の量子化ニューロンの量子化ユニット数は 1 に設定してあり、また入力の対象となる特徴データの分布の全域に反応するように量子化の範囲を設定する。学習データ \vec{x} を入力すると、 \vec{x} に反応した量子化ユニット U_i は、各次元 m ごとに、過去の平均 A_{imo} 、分散 σ_{imo} 、結合荷重変更回数 n_{imo} 及び入力データ x_m を用い、量子化入力端子から入力された全データの平均 A_{im} 、分散 σ_{im} 、結合荷重変更回数 n_{im} 及び内部状態 E_{im} を近似式 (4.20) ~ (4.23) に基づいて演算する。

$$A_{im} \cong \frac{n_{imo} A_{imo} + x_m}{n_{imo} + 1} \quad (4.20) \quad \sigma_{im} \cong \frac{n_{imo} \sigma_{imo} + |x - A_{im}|}{n_{imo} + 1} \quad (4.21)$$

$$n_{im} = n_{imo} + 1 \quad (4.22), \quad E_{im} = n_{im} \sigma_{im} \quad (4.23)$$

$$\text{分裂条件} : E_{im} > \alpha \quad (\alpha: \text{定数}) \quad (4.24)$$

近似式(4.20)～(4.23)に基づく各次元 m における内部状態 E_{im} の演算結果が最大となる次元 max を求める。さらには次元 max における内部状態 E_{imax} が式(4.24)で示す分裂条件を満たした場合に、すでに模式図 4.2 で示したように、次元 max において量子化ユニット U_i を、 U_i' と U_{i+1} の 2 つに分裂させてニューロンの複製、増殖を行う。この時、次元 max における平均 A_{imax} を分裂境界 Th_{imax} として量子化範囲を 2 つに分割し、分裂後の量子化ユニット U_i' 及び U_{i+1} の分裂した次元での量子化範囲を式(4.25)～(4.28)を用いて求める。さらに平均 A 、分散 σ 、結合荷重変更回数 n を式(4.29)～(4.33)を用いて求め、内部状態 E を式(4.23)を用いて演算する。量子化ユニット U_{i+1} の結合荷重 τ_{i+1} は、式(4.33)に示すように、量子化ユニット U_i の結合荷重 τ_i をそのまま複製して用い、また、ユニット U_{i+1} の分裂していない次元での量子化範囲も、式(4.34)、式(4.35)に示すように、量子化ユニット U_i の量子化範囲をそのまま複製して用いる。

$$XL_{i'max} = XL_{imax} \quad (4.25), \quad XU_{i'max} = Th_{imax} = A_{imax} \quad (4.26)$$

$$XL_{(i+1)max} = Th_{imax} = A_{imax} \quad (4.27), \quad XU_{(i+1)max} = XU_{imax} \quad (4.28)$$

$$A_{i'max} = \frac{XL_{i'max} + XU_{i'max}}{2} \quad (4.29), \quad A_{(i+1)max} = \frac{XL_{(i+1)max} + XU_{(i+1)max}}{2} \quad (4.30)$$

$$\sigma_{i'max} = \sigma_{(i+1)max} = 1 \quad (4.31), \quad n_{i'max} = n_{(i+1)max} = 1 \quad (4.32)$$

$$\tau_{i+1} = \tau_i = \tau_i \quad (4.33)$$

$$XL_{i'(m \neq max)} = XL_{i(m \neq max)} \quad (4.34), \quad XU_{i'(m \neq max)} = XU_{i(m \neq max)} \quad (4.35)$$

4.2.3 ニューロンの複製による増殖

量子化ユニットの分裂を行わせた後、図 4.3 で示したと同様に、当該ニューロン QN_1 に連結した中間層ニューロン QN_2 の複製 QN'_2 を作成し、量子化ユニット U_{i+1} の結合荷重 τ_{i+1} に連結することで、中間層ニューロンを増殖させる。

4.2.4 適応増殖ベクトル量子化ニューロンによる機能別階層ネットワーク

図 4.5 は、適応増殖ベクトル量子化ニューロンを用い、2次元の入力を2つの領域(A, B)に分離する機能別階層ネットワークの構成例とネットワークの自己生成の様子を示したものである。

入力層に $N=1$ 個の2次元ベクトル量子化ニューロンを配置し、出力層に $P=2$ 個の通常のニューロンを配置してネットワークを構成した。出力層の各ニューロン p は式(4.36)に示すように、下層のニューロンから送られた信号 $t\tau_j$ と学習によって形成された結合荷重 τ_{jp} との積和をとり、閾値関数 f に基づいて発火出力 y_p を出力する。

$$y_p = f\left(\sum_{i=1}^N \sum_{j=1}^M t \tau_{ij} \tau_{ijp}\right) \quad (4.36)$$

出力層の出力結果が誤っている場合に、教師信号に応じて中間層と出力層の結合荷重 τ_{ijp} を変更するとともに、すでに説明したように、過去の平均、分散、学習回数 n 及び入力データ \bar{x} を用い、認識誤りをしたデータの平均 \bar{A} 、分散 $\bar{\sigma}$ 、学習回数 \bar{n} 、及び内部状態 \bar{E} を近似式(4.20)～(4.23)に基づいて演算させる。内部状態 \bar{E} が式(4.24)に示す分裂条件を満たせば適応増殖ベクトル量子化ニューロンの量子化器の量子化ユニットを分裂させ、中間層のユニットを増殖させる。

図 4.5(a)に示すように初期状態では中間層のユニット数は1であるが、図 4.5(b)、(c)に示すように、データの入力に適応して中間層のユニットが増殖し、ネットワークの自己生成が行われる。図 4.6 は、2次元領域の二次曲線による分

離を実際にネットワークに学習させた場合の、量子化ユニットの分裂の様子を量子化範囲の分割として表したものである。図に示すように、非線形領域程細かく量子化範囲が分割されて、量子化ユニットが分裂して行く。




図 4.5 ベクトル量子化ニューロンによる機能別階層ネットワークの構成例とネットワークの自己生成




図 4.6 量子化ユニットの分裂

4.3 適応増殖ベクトル量子化ニューロンの文字認識への適用検証

これまで説明してきた適応増殖ベクトル量子化ニューロンを用いたネットワークを、実用的な課題であるマルチフォント英数字認識に適用し、学習認識実験検討を行った。なおシミュレーション実験は、SEQUENT S81(4MIPS、0.4MFLOPS)を用いて行った。

4.3.1 学習認識実験に用いた文字データ

英数 62 字種からなる 23 フォントの文字中、13 フォントを学習に用い、残り 10 フォントを未学習認識率の評価データとして用いた。

4.3.2 入力特徴量

文字認識に用いる特徴データとして、第 2 章 図 2.6 で示したと同様に、2 値イメージとして取り込んだ文字の (1)8×8 のメッシュ濃度値、(2)メッシュ濃度の横方向微分値、及び (3)メッシュ濃度の縦方向微分値を 8 ビットで正規化し、3 次元ベクトル量子化ニューロンに入力した。

4.3.3 ネットワーク構成

図 4.7 にネットワークの構成を示す。入力層を 8×8 のメッシュ数に対応する $N=64$ 個の 3 次元ベクトル量子化ニューロンによって構成し、出力層に英数字 62 文字に対応する 62 個の通常の閾値ニューロンを配置した。中間層のニューロン数は初期状態では 64 個であるが、学習によってベクトル量子化ニューロンの量子化ユニットが分裂し、中間層のニューロンが増殖することにより、設定した最大個数 J_{max} まで増加して行く。




図 4.7 英数字文字認識ネットワークの構成

4.3.4 認識処理

8×8 の各メッシュの濃度値、メッシュ濃度の横方向微分値、メッシュ濃度の縦方向微分値を、量子化信号入力として、入力層の $N=64$ 個のベクトル量子化ニューロンに入力する。すでに 4.2.1 項で説明したように、各量子化ニューロンは、中間層との結合荷重 τ_{ij} を量子化信号入力値に応じて設定し、信号を出力層に伝える。出力層の各ニューロン p は、式(4.36)に基づいて発火出力 y_p を出力する。出力が最大のニューロンの番号を検出し、認識結果とする。

4.3.5 学習処理

すでに 4.3.4 項で説明したと同様にしてネットワークの認識結果を求め、認識結果が誤っている場合、教師信号と認識結果が一致するように中間層と出力層の結合荷重 τ_{ijp} を変更すると同時に、認識誤りをしたデータの平均 \bar{A} 、分散 $\bar{\sigma}$ 、学習回数 \bar{n} 、及び内部状態 \bar{E} を近似式(4.20)～(4.23)に基づいて演算させる。また内部状態 \bar{E} は、認識誤りをしたデータの学習回数 \bar{n} で代表させ、内部状態 \bar{E} が式(4.24)に示す分裂条件を満たせば、適応増殖ベクトル量子化ニューロンの量子化器の量子化ユニットを分裂させ、中間層のユニットを増殖させる。また、

メッシュに対応する量子化ニューロンごとに増殖可能な中間層ニューロン数の最大値を、一定値 J_{max} で制限する。

4.3.6 学習認識実験結果

4.3.6.1 学習特性

図 4.8 に、結合係数 β を 0 に設定し、中間層ニューロン数の最大値 J_{max} を各メッシュごとに 100 に制限した場合の学習特性を示す。図に示すように、学習が進むにつれて中間層のニューロン総数が増加し、認識率が向上した。

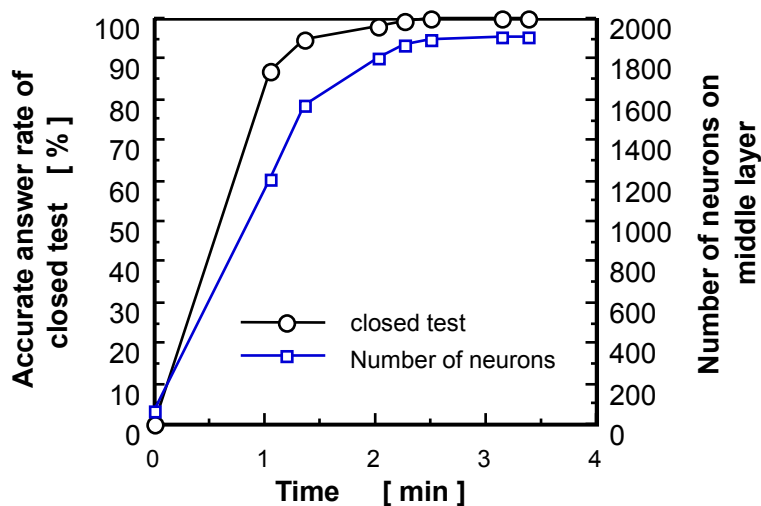


図 4.8 学習特性

4.3.6.2 分裂条件と中間層ニューロン数

図 4.9 は、学習フォントの認識率が 100% に達した時点での中間層総ニューロン数と、分裂条件 α との関係を示したもので、結合係数 β を 0 に設定し、各メッシュごとの中間層ニューロン数の最大値 J_{max} を変化させて上記関係を求めた。 α を大きくし、分裂条件を厳しくすると、中間層総ニューロン数が減少し、ネットワーク規模を縮小できる。いずれの J_{max} 値においても α を 100 程度に設定すれば、ネットワーク規模の十分な縮小が可能である。

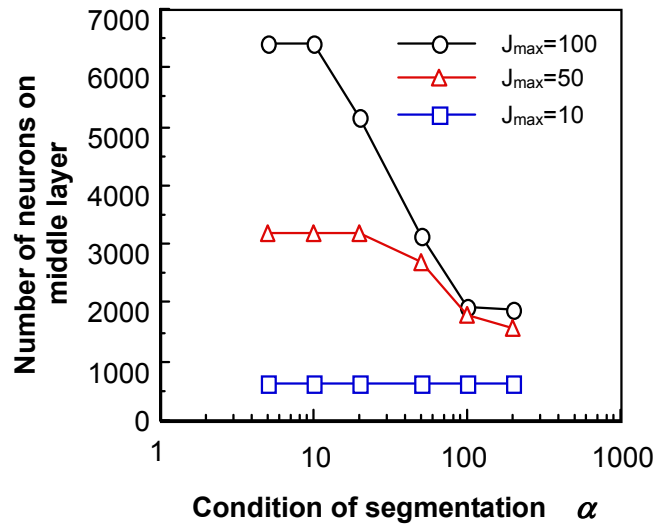


図 4.9 分裂条件と中間層ニューロン数

4.3.6.3 分裂条件と学習速度

図 4.10 に学習フォントの認識率が 100%に達するまでに要する時間と分裂条件 α との関係を示す。4.3.6.2 と同様に、結合係数 β を 0 に設定し、各メッシュごとの中間層ニューロン数の最大値 J_{\max} を変化させて上記関係を求めた。分裂条件 α が 100 を越えると、学習に要する時間が急激に増加する。

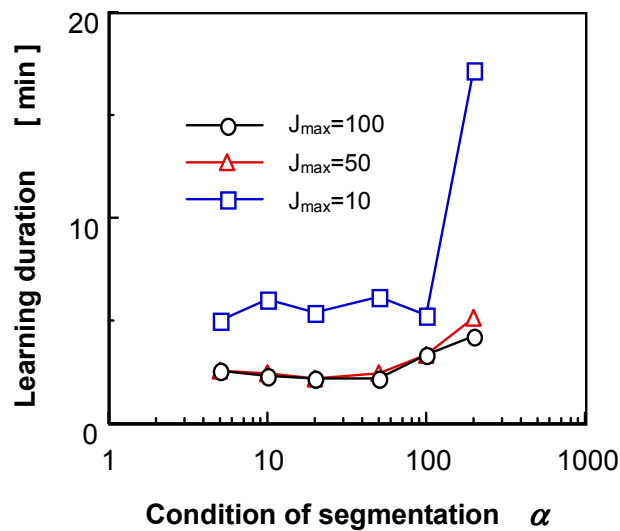


図 4.10 分裂条件と学習に要する時間

4.3.6.4 分裂条件と未学習フォント認識率

図 4.11 は、学習フォントの認識率が 100%に達した時点での未学習フォント認識率と分裂条件 α との関係を示したもので、これまでと同様に結合係数 β を 0 に設定し、各メッシュごとの中間層ニューロン数の最大値 J_{max} を変化させて上記関係を求めた。未学習フォント認識率は α に対してピークを持ち、概ね 10~100 程度に設定すると良好な未学習フォント認識率が得られた。

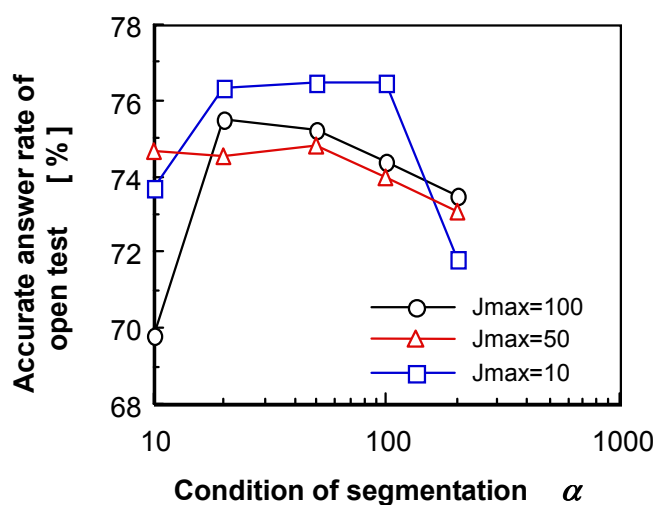


図 4.11 分裂条件 α と未学習フォント認識率

4.3.6.5 結合係数 β と未学習フォント認識率

以上 4.3.6.1~4.3.6.4 の結果に基づき、各メッシュごとの中間層ニューロン数の最大値 J_{max} を 100 に設定し、分裂条件 α が 20 と 100 の場合について、結合係数 β と未学習フォント認識率との関係を求めた結果を図 4.12 に示す。

図に示すように、結合係数 β を適切に設定することにより未学習フォント認識率を向上させることができ、概ね $\beta=1$ に設定すれば、比較的良好な未学習認識率を得ることができる。




図4.12 結合係数 β と未学習フォント認識率

4.3.6.6 他のネットワークモデルとの学習速度比較

中間層ニューロン数の最大値 J_{max} を 100、分裂条件 α を 20、結合係数 β を 0.16 に設定した場合の ASQA-II (MFLN-II) の文字学習速度を、他のネットワークモデル (誤差逆伝搬法による階層ニューラルネットワーク及び RCE ネットワーク) と比較した結果を、表 4.1 に示す。ASQA-II (MFLN-II) の学習速度は圧倒的に速く、階層型 NN の約 25 倍以上の高速学習が可能になった。

表 4.1 他のネットワークモデルとの学習速度比較

Model	Learning speed of accurate answer rate became below [min]	
	99%	100%
ASQA-II (MFLN-II)	8	11
Multi layered neural network with BP	200	Never became 100% in 250 minutes
LVQ3		20

4.4 適応増殖量子化ニューロン検討のまとめ

入力データに応じて適応的に増殖し、ネットワークの自己生成が可能な、適応増殖量子化ニューロン (ASQA: Adaptive Segmentation of Quantizer neuron Architecture) を提案した。さらには適応増殖量子化ニューロンをベクトル入力可能なモデルに拡張、マルチフォント文字認識に適用し、試行錯誤によることなく、入力データに応じて適応的にネットワークを構築でき、良好な学習と認識性能が得られることを実証した。

認識システム等の環境への適応を考えた場合、追加的に新たなデータを学習させ、ネットワークの結合荷重を微調整することは非常に有効な手段である。本方式を用いることにより、状況に応じてネットワーク構造自身も変化させ、より柔軟に環境の変化に適応させることも可能であり、将来の発展、応用展開を期待できる。

第5章 適応増殖量子化ニューロン(ASQA)のハードウェア化

適応増殖量子化ニューロンモデルは、通常の量子化ニューロンモデルに比べ、メモリの使用効率が非常に高く、ベクトル量子化に拡張することで、その学習認識性能を格段に向上させることができる。またそのハードウェア化は、実用化を進める上で重要な取り組みである。適応増殖量子化ニューロンのハードウェア化に際し、キーポイントとなる自己増殖によるネットワーク自動生成を実現すべく、ネットワーク構造やニューロン同士の結合荷重を外付けのメモリによって構成、ニューロ演算をシミュレートする演算部と、外付けメモリに保管したネットワーク中のニューロン同士の結合荷重をアドレッシングするネットワークアクセス部とによって構成し、LSI化を行った。作製したASQAチップにより、2,965文字種からなる漢字の認識において、わずか6MBのメモリを使用するだけで、認識率97.4%の漢字認識システムを実現した。

5.1 適応増殖量子化ニューロン(ASQA)チップの構成

実用的なアプリケーションへの適用を考えた場合、例えば漢字認識等、数千文字のカテゴリを認識させる必要があるものも多い。また、アプリケーションごとに必要となるカテゴリ数も異なり、これらの大規模カテゴリ認識でありながら、しかも、カテゴリ数を柔軟に変更可能な構造がハードウェアとして望まれる。そこで、単純に出力層のニューロン数を増加させるのではなく、構造化した複数のサブネットワークの出力をファジィ推論によって統合化することにより大規模カテゴリの学習認識を行わせる、NARA (Neural network Approximate Reasoning Architecture)⁽⁴⁶⁾に適用可能なチップ構造を実現した。

5.1.1 構造化ニューラルネットワークNARAの概要

図5.1に、構造化ニューラルネットワークNARAの基本構造を示す。NARAは、入力したデータを、予め決められた数の、複数グループに分類する大分類部と、分類したグループの中で、さらに詳細なカテゴリへの分別(認識)を行う複数のサブネットワークとからなる。大分類部は、ファジィベクトル量子化(FVQ)によって構成し、サブネットワーク群をASQAによって構成する。

認識すべきデータを大分類部及び全てのサブネットワークに入力すると、大分類部は、入力データのそれぞれのグループへの帰属度 m を出力し、また、各サブネットワークは、それぞれが担当するカテゴリへの帰属度(一致度)を出力する。統合認識部で、入力データの各グループへの帰属度 m と各サブネットワークの出力との積和を取り、各カテゴリへの帰属度(一致度)を最終結果として出力する。以上のような構造により、比較的容易に大規模カテゴリの学習認識に対応できる。

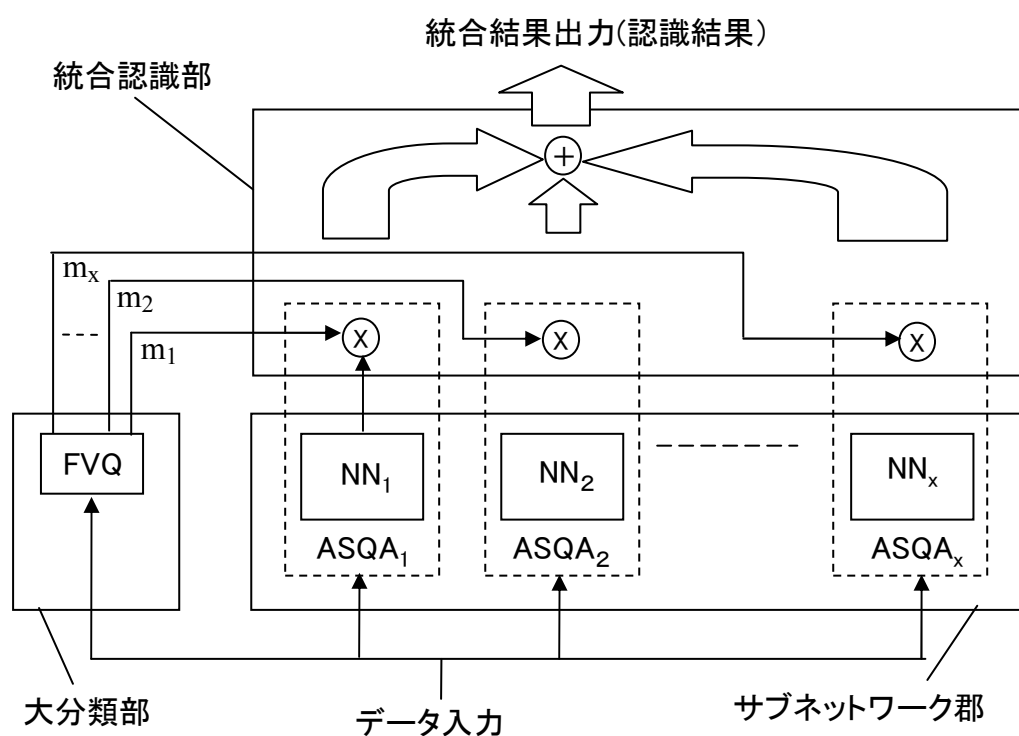


図 5.1 構造化ニューラルネットワーク NARA の基本構造

5.1.2 ASQAチップの基本構造

図5.2に、ASQAチップのブロック図を示す。ASQAチップは、ベクトル量子化器(VQU:Vector Quantization Unit)、汎用演算器(GPU:General Processing Unit)、システムインタフェースユニット(SIU:System Interface Unit)、入力RAM(IRAM)、出力RAM(ORAM)、パイプラインソートユニット(PSU:Pipeline Sorting Unit)、マルチネットワーク・アドレスジェネレータ(MAG)から成る。これらに加え、外付けの256K wordのテーブルRAM(TRAM)及び、外付けの8M wordの結合加重RAM(WRAM)を取り扱えるようにした。TRAMはネットワーク構造を格納するために用い、またWRAMは、ニューロン同士の結合荷重を格納するために用いるものである。

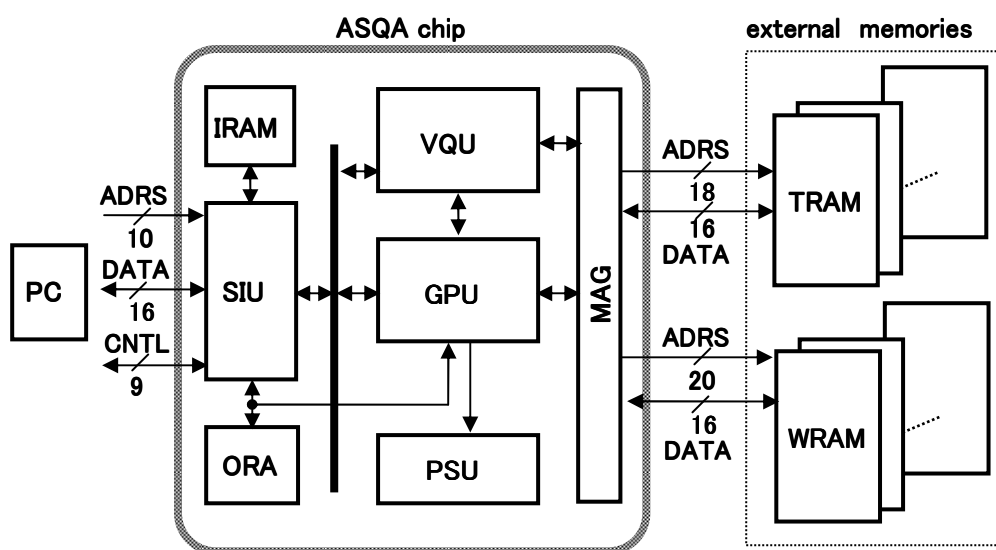


図 5.2 ASQA チップの基本構成図

5.1.2.1 ニューロン分裂増殖を実現するアーキテクチャ

前述したようにASQAチップには、VQUとGPUの2つの異なるタイプのDSPを実装した。VQUはネットワーク構造を制御し、GPUは、出力層ニューロンの出力の演算と、量子化入力端子から入力された全データの平均 A_{im} 、分散 σ_{im} 、結

合荷重変更回数 n_{im} 及び内部状態 E_{im} の演算を行う。

TRAM及びWRAMを外付けのメモリで構成した。TRAMは、分裂増殖の全ての履歴を含めたネットワーク構造を格納し、またWRAMは出力ニューロンの結合荷重と、平均 A_{im} 、分散 σ_{im} 、結合荷重変更回数 n_{im} 及び内部状態 E_{im} を格納する。

VQUは入力されるデータごとにTRAMを読むだけで、量子化ユニット番号を算出することができ、高速なデータの量子化を行える。量子化ユニット番号はWRAM中のアドレスを指し示し、WRAMから、量子化ニューロンの結合荷重 τ_i 、平均 A_{im} 、分散 σ_{im} 、結合荷重変更回数 n_{im} 及び内部状態 E_{im} を読み出すことができる。GPUは認識モードにおいては、VQUから量子化ユニット番号を受け取り、WRAMから結合荷重を読み取る。また学習モードでは、これらに加え平均 A_{im} 、分散 σ_{im} 、結合荷重変更回数 n_{im} 及び内部状態 E_{im} を演算する。

学習モードにおいて内部状態 E_{im} が閾値 α を超えた場合、VQUはニューロンの分裂増殖を行わせる。以下にその詳細について説明する。

5.1.2.2 ASQAチップにおけるニューロンの分裂増殖プロセス

図5.3に、ネットワーク構造とTRAMに保存されたデータとの関係を示す。TRAMに、量子化ユニットの量子化範囲を示す閾値(XU)及び、分裂の順序をバイナリツリーとして記録することで、全ての分裂増殖履歴を保持するようにした。TRAMのアドレスは、量子化ユニット分裂増殖のバイナリツリーのノードを指し示す。図5.3(a)分裂増殖前のTRAMを例に説明すると、TRAM中に量子化範囲の閾値XU、分裂増殖した量子化ユニットの番号Un、分裂後の子ノードの若い方の番号を示すNx、終端ノード(すなわち量子化ユニット)であることを示すフラグFlgの4種類のデータをテーブルとして保存する。このテーブル中で、例えばノード1及び2はノード0の子ノードであり、ノード0のNxは、ノード1を指し示しており、フラグFlgに“1”が立っているノード1、3、4は終端ノード、すなわ

ち量子化ユニットであることを示す。

図5.3(a)において、ネットワークにデータが入力されると、VQUは、入力データが量子化範囲に入る量子化ユニットを、ノード0から検索し始める。例えば、入力データが“5”である場合、ノード0のXU=4よりも大きく、ノード0のNxが示すノード番号+1、すなわちノード2を参照すると、ノード2のXU=7よりも小さいことがわかり、さらには、XU=7であるノード2のNxを参照すると“3”が示されている。従ってノード3を参照すると、フラグFlgに“1”が立っていることが確認でき、データが量子化範囲に入る量子化ユニット番号Unとして“1”を得ることができる。VQUはこの量子化ユニット番号をGPUに送る。

図5.3(b)に1回の分裂増殖後のTRAMの状態を示す。学習モードにおいて分裂増殖が起き、分裂境界 $Th=2$ で新たな閾値XUが追加された時、VQUはノード1のフラグFlg をクリアし、新たなXU=2、及び、Nx=5(最大ノード番号+1=5)を書き込む。これに加え、VQUはノード1の量子化ユニット番号Unをノード5に移動する。ノード5及び6は、ノード1の子ノードであり、バイナリツリー上では、ノード1に連結して記述できる。ノード6の量子化ユニット番号Unを、最大ユニット数+1=3に設定、さらには、ノード5及び6のフラグFlgに“1”を立てる。以上のプロセスで、1つのネットワークの全ての分裂増殖履歴をTRAMに保存することができる。また1つのネットワークごとに、最大8,192個まで量子化ニューロンを分裂増殖可能にした。

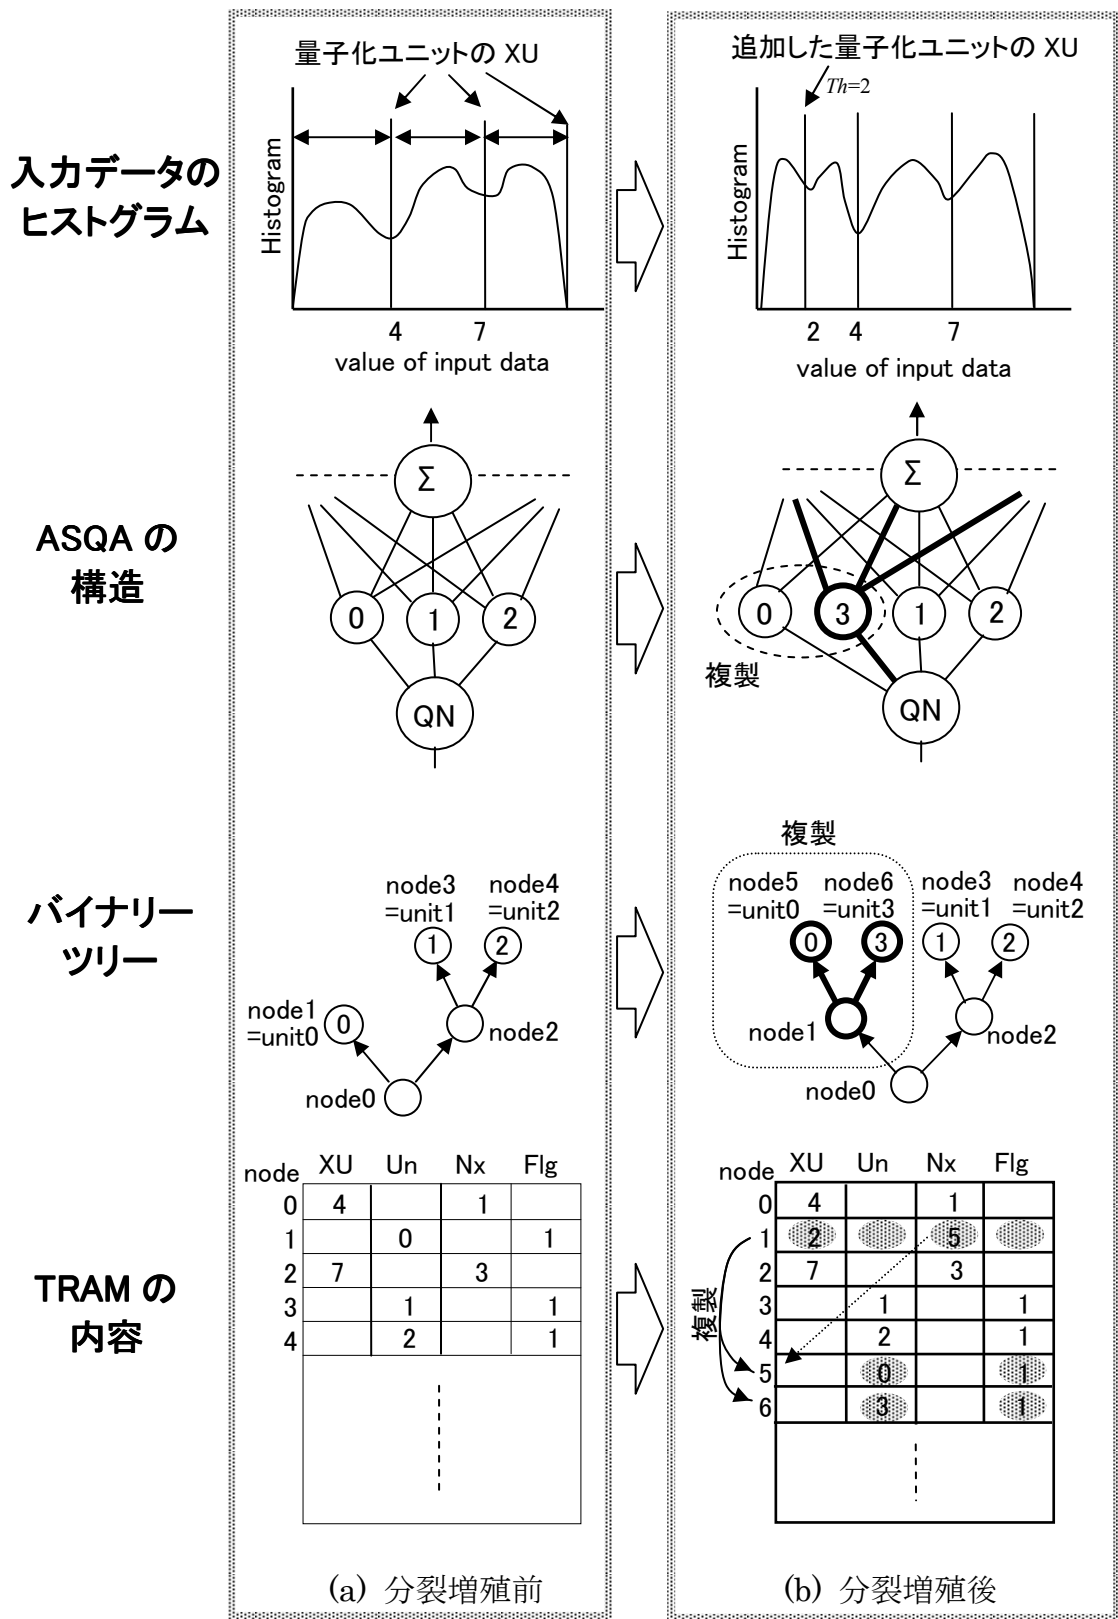


図 5.3 量子化ニューロンの分裂増殖履歴の TRAM への保存方法

5.1.3 構造化ニューラルネットワークNARAへの対応方法

各種サイズの複数サブネットワークをASQAによって構成することで、大規模カテゴリの学習認識が可能な構造化ニューラルネットワークNARAを実現した。

ASQAチップは、個々のサブネットワークの全ての情報を外付けメモリに保存する。サブネットワークごとに、1、2、4、8、または16個のTRAM及びWRAMを外付けメモリ上で取り扱うことができるため、サブネットワークごとのネットワークサイズに応じて最適にメモリをアサインすることにより、最小限のメモリ構成でNARAを実現可能にした。

ホストCPUによって、メモリ中のサブネットワークの領域をMAGにセットすると、TRAM及びWRAMへのアドレス信号はMAGによって、所定のサブネットワークのアドレスへ変換される。TRAM及びWRAMを、それぞれ最大8個のメモリチップによって構成し、最大128個のサブネットワークと、最大16,384個の出力ニューロンによるネットワークを実現可能にした。

5.1.4 メモリ削減モード

ASQAチップには、「デュアル・メモリ・モード」及び「シングル・メモリ・モード」という2つのメモリモードを持たせた。「デュアル・メモリ・モード」は、TRAM及びWRAMの両方を使用するモードで、「シングル・メモリ・モード」は、WRAMのみを使用するモードである。「シングル・メモリ・モード」では、ネットワークの情報をWRAM中のサブネットワークごとに保存し、サブネットワークの構造は、WRAMの空領域に保存される。MAGはどちらのメモリモードにおいても、アドレスを変換可能である。

「シングル・メモリ・モード」を用いると、認識システムを構築した場合に、メモリ容量を大幅に削減でき、ワンチップ、ワンメモリで、PC接続可能な漢字認識システムを実現できる。

5.2 ASQAチップの性能

ASQAチップの性能評価と実用システムの構築に向けて、ASQAチップを用いたニューロボードを開発した。

手書きの数字認識に適用した場合、実行速度は、 $17.5\mu\text{sec}$ /文字、(毎秒57,000文字)であった。この速度は、ワークステーション(SPECint92 = 104、SPECfp92 = 172)と比べ、約11倍の速度であった。

図5.4に、ASQAチップとすでに開発している量子化ニューロンチップ(QNC: 第3章で説明)を手書き数字認識に適用した場合の、認識精度とメモリサイズの観点からの性能比較を示す。図に示すように、ASQAチップはQNCに比べ、約1/11のメモリサイズで同等の認識性能を得ことができ、メモリサイズを約9%まで大幅に削減できた。また、13個のサブネットワークと、351KBのメモリを用いた構造化ニューラルネットワークにより、最高認識率97.1%を得ることができた。

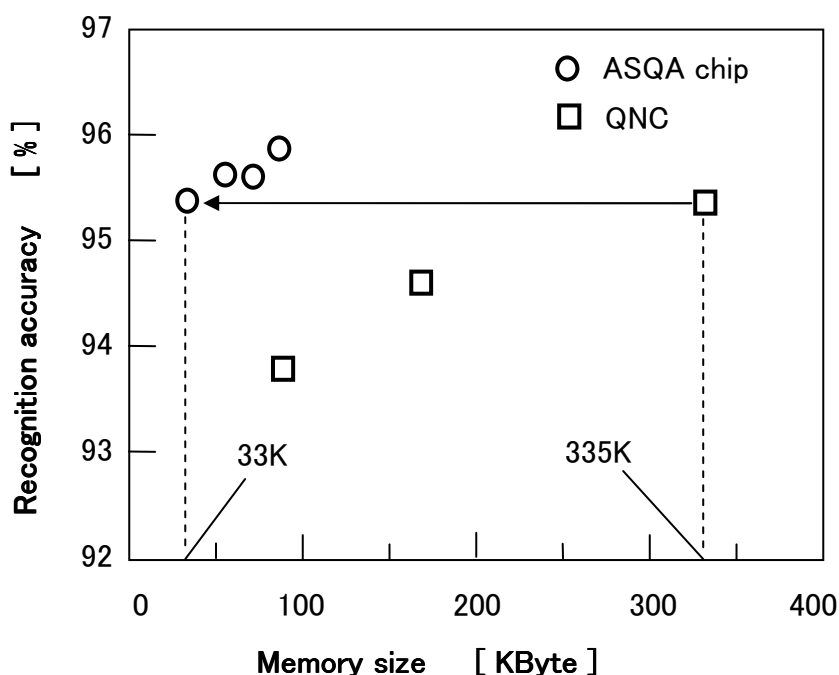


図 5.4 認識精度とメモリサイズ

以上の結果に基づき、2,965文字からなる漢字認識システムを開発実用化した結果、16フォント学習後の3フォントの未学習認識率97.4%、1フォントの未学習認識率98.8%、毎秒570文字の認識速度を、わずか6MBのメモリサイズで実現することができた。

表5.1に、ASQAチップの諸元を、図5.5に写真を示す。

表 5.1 ASQA チップの諸元

No. of simulation neurons	
Quantizer neurons	64
Input dimensions	512 (=64X8)
Output neurons	128 (X32b)
No. of proliferations	8,192
No. of synapses	1M (X16b)
No. of subnetworks	128
No. of categoriesw	16,384
Clock rate	40 MHz
Power supply	3.3 V
Power dissipation	280mW @3.3V, 40MHz
Chip size	6.92mm X 7.08 mm
No. of gates	250,000
Process technology	0.5 μ m CMOS 1PS2AL
External memories	32k X 8 bit
	1M X 8 bit




図 5.5 ASQA チップの写真

5.3 適応増殖量子化ニューロンハードウェア化のまとめ

適応増殖量子化ニューロンモデルは、通常の量子化ニューロンモデルに比べ、メモリの使用効率が非常に高く、また、ベクトル量子化に拡張することで、その学習認識性能を格段に向上させることができた。また、そのハードウェア化は、実用化を進める上で重要な取り組みであった。適応増殖量子化ニューロンのハードウェア化に際し最大の課題は、分裂増殖によるネットワーク自動生成を、いかにしてチップレベルでハードウェア的に行うかであった。この課題に対し、

- (1) 分裂増殖の履歴を含めたネットワーク構造とニューロン同士の結合荷重を、外付けのメモリ中に記憶させる構造にするとともに、
- (2) ネットワーク構造をバイナリツリーとしてTRAM中のテーブルに展開し、ニューロンのアドレッシングと結合荷重へのアクセスを効率的に行わせる構造を実現する

ことにより、TRAM中のテーブル操作だけで、分裂増殖によるネットワーク生成を、非常に簡単に管理可能なLSIを実現できた。

手書きの数字認識に適用した場合、実行速度は、 $17.5\mu\text{sec}$ /文字、(每秒57,000文字)で、ワークステーション(SPECint92=04、SPECfp92=172)の約11倍の高速処理が可能となった。またすでに開発している量子化ニューロンチップと比較した場合、同等の認識性能を得るのに必要なメモリサイズを約9%まで大幅に削減できた。

以上の結果に基づき、2,965文字からなる漢字認識システムを実用化した結果、わずか6MBのメモリサイズで認識率98.8%、每秒570文字の認識速度を実現することができた。

第6章 量子化ニューロンモデルの実用システムへの展開

本章では、量子化ニューロンによるニューラルネットワークを用いた実用システムの開発と、実現したシステムの性能について述べる。産業分野での展開では形状検査装置を開発実用化、民生分野ではビデオムービーのガンマ補正に適用、簡易ネットワークによるハードウェア化により、実用的商品を開発した。また、事務機器分野では、すでに述べたように、英数字、さらには漢字の認識が可能な、各種文字認識装置の開発実用化を行った。何れのシステムにおいても、世界最高レベルの性能を実現できた。

以下、産業分野での形状検査装置、並びに民生分野でのビデオムービーへの展開を中心に述べる。

6.1 形状検査装置への適用と実用化

形状検査装置等では極めて正確な物体の認識精度が要求されるが、カメラによる可視光自然画像の入力により認識を行わせる場合、自然画像中から物体画像を切り出したうえで、その形状の認識を行う必要がある。この時、画像自身に含まれるノイズや切り出しに伴うノイズの影響で切り出された物体形状は大きく変化する。また、同じ物体であっても回転や移動により、2次元座標上でのパターンは異なることが多い。このような自然画像中の物体形状の認識には、形状の変化に対して柔軟な認識処理が必要となる。

そこで、2次元物体の形状を時系列データに変換する ϕ -s 特徴変換を新たに提案するとともに、適応増殖量子化ニューロンによるネットワークを時系列パターンの認識が可能なモデル(TASQA: Temporal Pattern Recognition Network with ASQA)に発展させ、これを用いることにより高い物体形状認識性能を実現、す

で説明した ASQA チップを用いて実装を行うことにより形状検査装置を実用化した。

本節では、TASQA の構造と動作、その性能について詳しく述べる。

6.1.1 TASQA の構造と動作

図 6.1 に TASQA の基本構造を示す。TASQA は ASQA 層と時系列統合ニューロン層から成る。ASQA 層は、各時刻の入力に基づいた認識結果を出力し、時系列統合ニューロン層は ASQA 層の出力及び自己フィードバックによって、一定時間内の ASQA 層の出力値に基づいた認識結果を出力する。学習時は時系列統合ニューロン層の出力が教師信号と一致するように ASQA 層内の結合荷重を変更する。

6.1.2 時系列統合ニューロン層の構造と動作

時系列統合ニューロンは ASQA 層の出力ニューロンと 1 対 1 対応し、図 6.1 に示すように ASQA 層の出力と、自己出力のフィードバックが入力される。時刻 T における p 番目の時系列統合ニューロンの出力 $U_p(T)$ を式で表現すると式(6.1)となる。

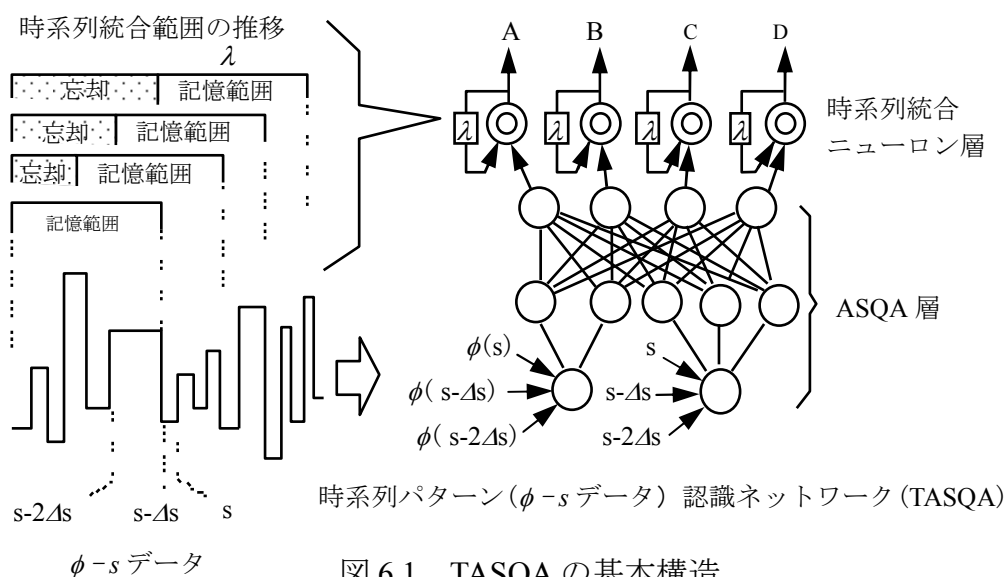


図 6.1 TASQA の基本構造

$$U_p(T) = h\left(\int_0^T r(t)y_p(T-t)dt\right) \quad (6.1)$$

ここで、 $y_p(T-t)$ は時刻 $T-t$ における ASQA 層の p 番目のニューロンの出力、 $r(t)$ は自己フィードバック強度の時間依存性を表す関数、 $h()$ はしきい値関数である。今回の実験で用いた $r(t)$ は図 6.2 に示すような時間幅 λ で利得 1、他の部位で利得 0 の矩形関数である。すなわち、時系列統合ニューロンの出力は ASQA 層の出力を過去 λ にわたって積分したものになっている。積分を行うことで、時間的に広い範囲の系列情報を反映した認識が可能となる。また、自己フィードバックは時間方向の出力の平滑化も合わせて行っており、これにより、入力系列に含まれるノイズが出力に与える影響を軽減することができる。




図 6.2 自己フィードバック強度の時間依存性

6.1.3 TASQA の学習

図 6.3 は、2次元の入力を2つのカテゴリ(A、B)に分離する課題に TASQA を適応した例と、ネットワークの自己生成の様子を示した模式図である。ASQA 層の入力層を1個の2次元ベクトル量子化ニューロンによって構成し、ASQA 層の出力層及び時系列統合ニューロン層には、カテゴリA、Bに対応した2個のニューロンを配置した。

ASQA 層の p 番目の出力ニューロンの出力 y_p は式(6.2)に示すように、下層のニューロンから送られた信号 $t\tau_{ij}$ と学習によって形成される結合荷重 τ_{ijp} との積和をとり、閾値関数 f に基づいて発火出力 y_p を出力する。

$$y_p = f\left(\sum_{i=1}^N \sum_{j=1}^{\max} t \tau_{ij} \tau_{ijp}\right) \quad (6.2)$$

$$\tau_{ijp}' = \tau_{ijp} + \delta \quad (6.3)$$

ASQA 層の出力を受けて、時系列統合ニューロン層は式(6.1)に基づいた認識結果を出力し、A に対応するニューロンの出力値が最大であれば、認識結果は A とし、B に対応するニューロンの出力値が最大であれば、認識結果は B と判断する。

学習過程において、時系列統合ニューロン層の出力が学習データのカテゴリと異なる場合、教師信号で示される最大値を出力すべき ASQA 出力層のニューロンと中間層ニューロンとの間の結合荷重 τ_{ijp} を、式(6.3)に示すように、 δ だけ強化する。結合荷重の変更とともに、すでに 2.1.3.1 及び 2.1.3.2 で述べたように、過去の平均 A_{imo} 、分散 σ_{imo} 、結合荷重変更回数 n_{imo} 及び入力データ \vec{x} を用い、新たな平均 A_{im} 、分散 σ_{im} 、結合荷重変更回数 n_{im} 及び内部状態 E_{im} を近似式(4.19)～(4.22)に基づいて演算させる。内部状態 E_{im} が式(4.23)に示す分裂条件を満たせば ASQA 層の量子化ニューロンの量子化ユニットを分裂させ、量子化ユニットに連結した中間層のニューロンを複製する。図 6.3(a)に示すように、初期状態では ASQA 層のニューロンの量子化ユニット数は 1 であるが、図 6.3(b)、(c)に示すように、学習の進行に伴い、中間層のユニットが増殖し、ネットワークの自己生成が行われる。

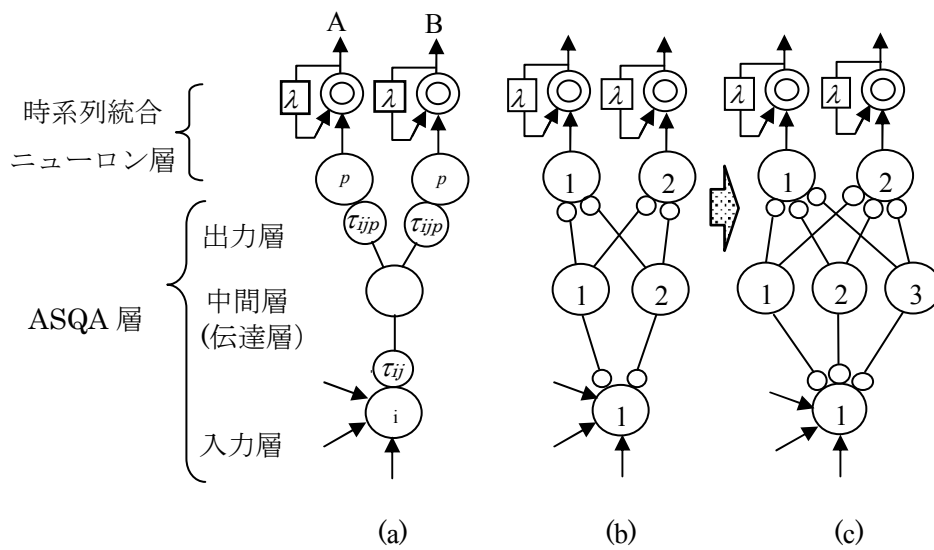


図 6.3 TASQA におけるネットワークの自己生成

6.1.4 形状の ϕ - s 特徴変換

本項で提案する ϕ - s 特徴変換は、2次元線図形から1次元の系列データへの変換を行うものである。概要を図 6.4 に示す。図 6.4(a) の太線図形を ϕ - s 変換して得られた系列データが図 6.4(b) である。図 6.4(a) のように対象となる図形の輪郭線上の任意の点を起点 p として定め、反時計回りに輪郭線をトレースし、各点での接線の傾き ϕ を系列データとして発生する。図 6.4 (b) の横軸 s は起点からの輪郭線の長さ(系列の順番)を表わし、縦軸は接線の角度 ϕ 表す。このように ϕ - s 特徴変換で得られる系列データは、輪郭線上の各点における接線の傾きを基点からの輪郭線長の関数として表したものである。図のような多角形の場合には、 ϕ - s 変換後、階段状の系列に変換される。ここで、図形が回転した場合の回転角 $\delta\phi$ は、変換後の系列データの ϕ 軸上での平行移動となり、また、輪郭線上の起点の位置の変化は s 軸上での平行移動に対応するため、図形の回転や移動による形状データの変動の影響を容易に吸収することができ、また、輪郭線の起点からの距離 s を時間 t とみなせば、時系列データとして、取り扱うことができる。本節における検討では認識図形の輪郭形状を多角形近似し、 ϕ - s 特徴変換を

行った。得られた階段の i 番目の立ち上がり(または立ち下がり)の点の ϕ , s 値をそれぞれ ϕ_i , s_i としてベクトル系列 $\vec{X}_i = (\phi_i, s_i)$ [$i = 1, 2, \dots, M$; M は多角形の辺の数] を生成し、差分 $\vec{X}_i - \vec{X}_{i-1}$ 及び $\vec{X}_i - \vec{X}_{i-2}$ を求めることで、図形の回転成分として現われる ϕ のシフト $\delta\phi$ を吸収し、実際の入力データとした。

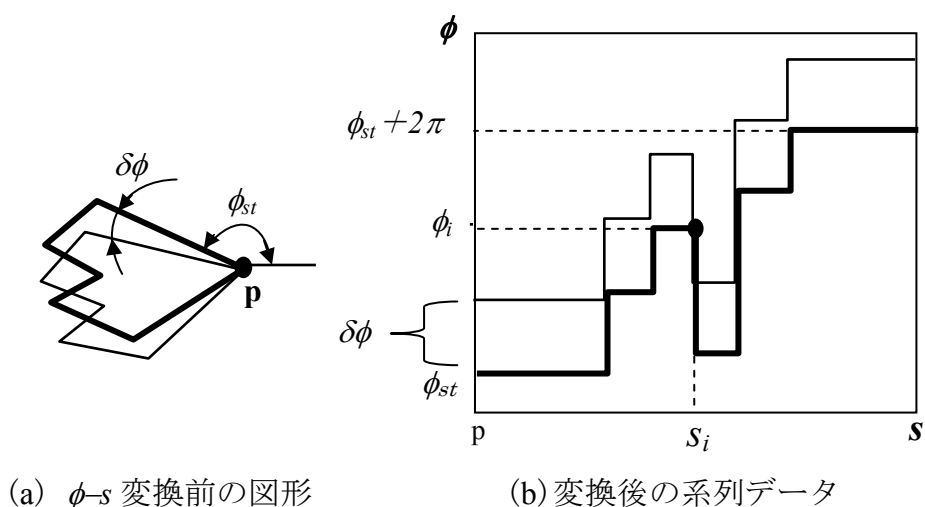


図 6.4 ϕ - s 特徴変換

6.1.5 T A S Q A による形状認識

6.1.5.1 実験に用いたデータ

図 6.5 に示す、複数の機械部品が配置されたグレースケール画像から、図 6.6 を例として示す、輪郭線の多角形近似による機械部品の形状データを取得し、図 6.6 中の A~E に示す部品形状を実験対象とし、認識対象(識別のターゲット)を、B 及び C とした。機械部品の輪郭は、撮影条件や各部品の回転などによって大きく変化する。そこで、撮像条件の異なる 5 枚のグレースケール画像(図 6.7 No.1~No.5)のそれぞれから部品形状データを取得、A~E のそれぞれの部品について各 5 形状データ、合計 25 形状データを実験に用いた。これら 25 個の部

品形状データを ϕ - s 特徴変換し、ベクトル系列 $\vec{X}_{fi} = (\phi_{fi}, s_{fi})$ を得た。(サフィックス f はグレースケール画像 No. : 1~5、図 6.5 中の画像 No.4 は、図 6.7 の画像 No.4 と同じもの)




図 6.5 実験に用いた画像例
(画像 No.4)







図 6.6 輪郭を多角形近似した図形
(画像 No.4)




(画像 No.1)




(画像 No.2)



(画像 No.3)



(画像 No.4)



(画像 No.5)

図 6.7 撮像条件の異なる 5 枚のグレースケール画像

6.1.5.2 ネットワークの構成

図 6.8 にネットワークの構成を示す。ASQA 層の入力層は 2 個の量子化ニューロンで構成され、それぞれ 2 次元のベクトル特徴入力端子を持つ。前述したように、各形状の ϕ - s データ中で、輪郭線の起点からの距離 s を時間軸とみなし、各ニューロンに対し、時刻 s における差分 $\vec{X}_i - \vec{X}_{i-1}$ を一方のニューロンに、他方に $\vec{X}_i - \vec{X}_{i-2}$ を入力する。時系列統合ニューロン層は 3 つのニューロンで構成し、それぞれ 2 種類の認識対象及びリジェクトに対応している。各時系列統合ニューロンは、 λ の時定数で出力結果を積分して出力する。




図 6.8 実験に用いたネットワーク構造

6.1.5.3 学習認識実験方法

図形の学習を行う前に、多数の乱数ベクトルを量子化ニューロンに入力し、これらの入力に対してリジェクトニューロンが最大出力を出すようにネットワークを学習させ、また、中間層ニューロンを、最大 40 個を上限として分裂増殖させた。

5枚の画像より得られた25形状データのうち、図6.9(a)、(b)に示す2つの形状データを認識対象B及びCの学習用データとして用い、残り23形状データを認識実験に用いた。また、学習に用いた2つの形状データの全ての ϕ - s 特徴の入力による学習を1回の学習としてカウントした。分裂条件 α は、学習の高速化を狙いとし、学習による結合荷重変更回数を15回以内に留めることを目的に15とした。



(a) 画像 No.2 部品 B (b) 画像 No.1 部品 C

図 6.9 学習した形状データ

6.1.5.4 学習結果

前述の2つの形状データの学習は、6回の繰り返し学習(SPARC Station 2で5秒、1.3GHz Pentium4換算で1.5秒程度)で認識率が全て100%となり、実用的に十分な速度での学習処理を行うことができた。初期段階での中間層ニューロン数は40であったが、学習が進むにつれて分裂増殖を繰り返し、1回目の学習終了時点で185個に、2回目の学習終了時点には中間層ニューロンの上限である210個まで増殖を繰り返した。従って、2回目までの学習でネットワーク構造ができ上がり、3回目以降の学習過程では、結合荷重の変更のみで学習が行われたことがわかる。


6.1.6 認識実験結果と考察

6.1.6.1 TASQAの応答と認識結果

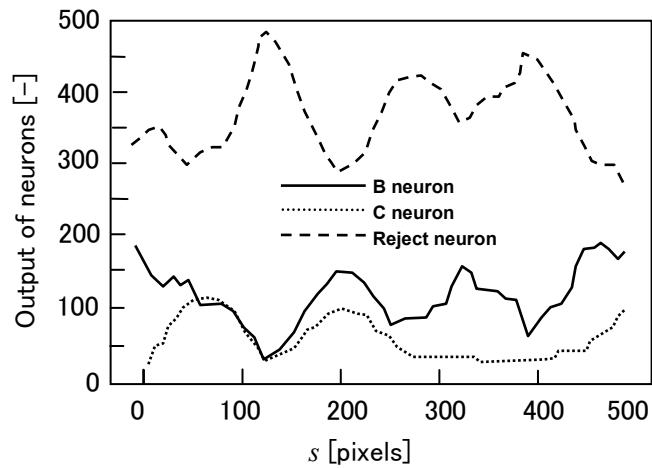
図6.10(a)~(c)はTASQAに形状データを入力したときの出力の変化を表すグラフである。グラフの横軸は、輪郭線上の起点からの距離 s を時間とみなした

ものであり、縦軸はニューロンの出力値を表わす。横軸の表示範囲は、形状データの入力開始から終了までを表示している。グラフの 3 本の線は、それぞれ時系列統合ニューロン層の 3 つのニューロンの出力を表しており、実線は B ニューロン、破線は C ニューロン、長い破線はリジェクトニューロンの出力である。なお自己フィードバック定数は、 $\lambda=3$ として実験を行った。図 6.10(a) は、図 6.6 に示す画像 No.4、部品 C の形状データを入力したときの TASQA の応答を示す。 ϕ -s 特徴変換された系列データを入力するに伴い各出力ニューロンの出力は変化するが、入力形状が学習形状(画像 No.1、部品 C)に酷似しているため、C を担当するニューロンが常に最大出力、つまり正解を出している。図 6.10(b) は図 6.6 に示す画像 No.4、部品 A の形状データを入力したときの TAQSA の応答を示す。学習図形と形状が完全に異なるために、リジェクト担当のニューロンが常に最大出力を出していることがわかる。

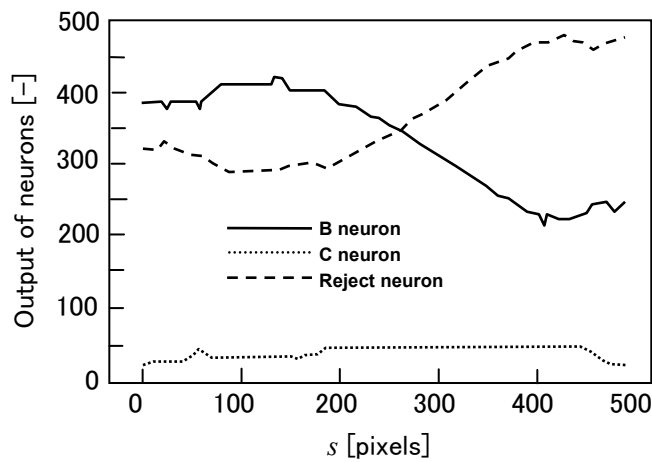
図 6.10(c) は図 6.11 及び図 6.6 に示す画像 No.4、B の形状データを入力したときの TASQA の応答を示す。図 6.11 に示すように、画像 No.4、B の形状データの左部分は、元の部品形状を反映しているため、入力系列の前半では部品 B を担当するニューロンが最大出力を出している。しかしながら、右部分はノイズの影響で形状が大きく変形しているため、後半の入力ではリジェクトを担当するニューロンが最大出力を出している。以上のことから TASQA は、部分的な形状一致度の出力が可能であることがわかる。



(a) 画像 No.4、部品 C の形状データ入力時



(b) 画像 No.4、部品 A の形状データ入力時



(c) 画像 No.4、部品 B の形状データ入力時

図 6.10 TASOA の応答




図 6.11 画像 No.4、B の形状データ

6.1.6.2. 認識率の λ 依存性

時系列統合ニューロンの自己フィードバックの時定数 λ の値を有限の値で変化させ、認識率の λ 依存性を調べた結果を図 6.12 に示す。図に示すように、認識率は特定の λ で最大値となる山型の特性を持つ($\lambda=7$ で 100%)。6.1.2 項で述べたように、TASQA は λ によって規定される自己フィードバック定数により、ある時間範囲での出力の統合を行う。有限の λ を用いることは時間的に特定の範囲を注視することに相当し、適切な注視範囲を選択することで、形状全体のマクロな一致度を出力させることで、高い認識性能を得ることができた。 λ が小さいときには系列信号に含まれるノイズの影響で誤認識すると考えられ、逆に λ が大きいつきには、系列信号固有の特徴が平滑化によって失われるために誤認識すると考えられる。 λ の値を 6 から 8 の間に設定することで、5 つの画像より得られた 23 個の未学習の部品形状に対して 100%の認識率が得られた。




図 6.12 TASQA の応答の λ 依存性

6.1.7 形状検査装置への適用と実用化のまとめ

自然画像中の物体の認識を行う場合、画像自身に含まれるノイズや切り出しに伴うノイズ、あるいは物体の回転や移動等の影響で、切り出された形状は大きく変化し、このような切り出し図形の認識には形状の変化に対して柔軟な認識処理が必要となる。我々は時系列パターン認識ネットワーク TASQA 及び ϕ - s 特徴変換を提案、形状検査装置に必要な物体形状認識に適用した。

ニューラルネットワークを構成する上で最大の課題の一つは、認識課題に対して最適なネットワーク構造をいかにして決定するかである。TASQA はすでに説明した ASQA を応用することで、学習過程において、入力した学習データに応じて適応的に中間層ニューロンが増殖し、ネットワークを自己生成可能であることを示した。また学習に要する時間も、学習回数 6 回、標準的な PC (1.3GHz Pentium4 換算) で 1.5 秒程度であり、実用的には十分な速度での学習が可能となった。

提案する ϕ - s 特徴変換により図形形状を時系列データとして取り扱うことができ、図形が回転した場合の回転角 $\delta\phi$ は変換後の系列データの ϕ 軸上での平行移動、輪郭線上の起点の位置の変化は s 軸上 (等価的に時間軸上) での平行移動に対応する。従って変換により得られた $\vec{X}_i = (\phi_i, s_i)$ の差分 $\vec{X}_i - \vec{X}_{i-1}$ 及び $\vec{X}_i - \vec{X}_{i-2}$ を入力データとすることで、 ϕ 軸上での平行移動は打ち消され、完全に回転フリーの特徴データとして扱うことが可能となった。

TASQA は時系列統合ニューロン層により時系列データの学習認識が可能であり、上記 ϕ - s 特徴変換による形状データを適用することで、形状の輪郭線上に沿った、部分的な一致度が出力可能である。従ってノイズによる形状の大きな歪がある場合でも、部分的形状の一致度に基く認識判断が可能で、認識精度の高い形状検査装置を構築できた。すでに説明した ASQA チップを ASQA 層に用いることにより、毎秒 143 画像の形状認識が可能な形状検査装置を実用化した。

6.2 逆光フリービデオムービーへの展開

民生用ビデオカメラの開発は、誰でもどこでもきれいに撮れることの実現を目的とし、様々な制御技術を用いている。中でも露出制御は、さまざまな照明条件のもとでレンズの絞り開度を最適に制御するもので、ファジィルール⁽⁵⁷⁾⁽⁵⁸⁾やニューラルネットワークの学習⁽⁵⁹⁾を用いた技術が発表されている。しかしながらこれらの絞り補正技術を用いても、コントラストが極端に大きな被写体に対しては、暗部と明部の両方の階調を再現することは困難である。被写体の輝度に対して、撮像画像上で階調を再現できる範囲を制限している要因には、撮像素子と表示デバイスのダイナミックレンジがある。撮像素子のダイナミックレンジが広い場合には、撮像素子の出力信号から表示デバイスへの入力信号への階調変換特性を工夫することにより、表示デバイス上で階調を再現できる被写体の輝度の範囲を広げることができる。

このような階調再現を改善する技術として用いられるヒストグラムイコライゼーションでは、輝度の累積ヒストグラムを格納して輝度の変換テーブルとするためのメモリが必要である。また、輝度分布が極端に集中している領域において、入力輝度レベルの少しの差が強調されるために発生する偽輪郭などを抑制するためには、さらに追加回路を要する⁽⁶⁰⁾。被写体の照明条件に応じて絞り制御と信号処理特性を変化させる技術⁽⁶¹⁾もあるが、一般的にすべての被写体に対して、照明条件の判定を正確に行うことは、これらの関係があまりにも非線形であり、算術的に記述することは非常に困難である。

一方人間は、複数のガンマ特性を適用した画像を比較することにより、画像全体の明暗のバランスやトーン等に基き、明示的、論理的説明はできなくとも、最適なガンマ特性をマクロな視点で選択することは可能であり、またこの人間の判断や選択ルールを、ニューラルネットワークに学習させることも可能である⁽⁶²⁾⁽⁶³⁾。

我々は、逆光条件などでダイナミックレンジの広い被写体の階調を暗部から

明部まで再現することを目的として、画像の状況に応じてガンマ特性を変化させることが可能な、量子化ニューロンを用いたニューロガンマ処理方式の確立と実用化に取り組んだ。この方式では、順光の被写体には従来と同じ 0.45 乗のガンマ特性を適用、逆光の被写体には 0.45 乗の特性よりも暗部を明るく補正することで、明部のコントラストも保てるようなガンマ特性を適用し、画像ごとに適用すべきガンマ特性の選択を、人間の選択ルールを学習させた量子化ニューロンによるネットワークに行わせた。本方式により、非常にダイナミックレンジの広い、高画質な撮像を、全自動で行える民生用ビデオムービーを実用化できた。

本節では、ニューロガンマ処理の階調変換特性、量子化ニューロンによるガンマ特性の選択ルールの学習、ニューロガンマ処理を小規模回路で実現するための構成、および絞り制御やノイズリダクションとの連動について述べる。

6.2.1 ニューロガンマ処理の入出力特性

ガンマ処理部は図 6.13 に示す構成を持ち、従来の 0.45 乗の固定のガンマ処理後の信号 (R, G, B) を入力として、階調変換を行った信号 (R', G', B') を出力する。入力信号の輝度 Y の分布に基づく特徴量を抽出し、予め学習した結果に基

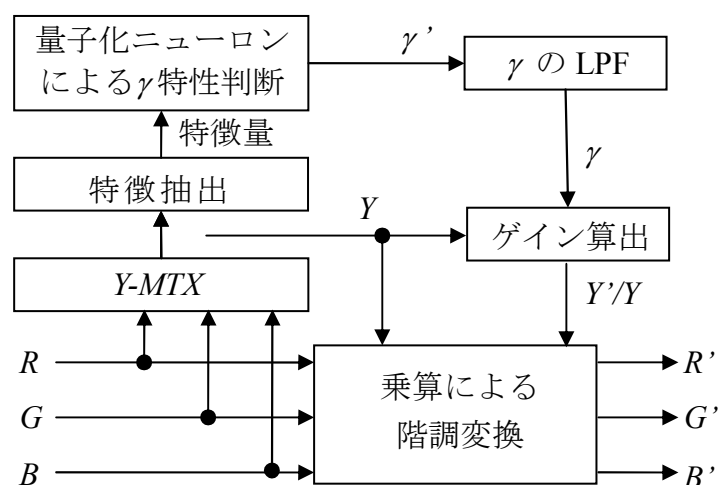


図 6.13 ニューロガンマ処理のブロック図

き、各フィールドに対して適用すべきガンマ特性を判断し、パラメータ γ' を出力する。階調変換に用いる特性パラメータ γ は、過去のフィールドに対して徐々にガンマ特性を変化させるよう設定する。輝度 Y と特性パラメータ γ によってゲイン Y'/Y を画素毎に算出し、乗算によって階調変換を行い、出力信号(R', G', B')を得る。

6.2.1.1 輝度信号の入出力特性

階調変換の出力(R', G', B')から生成される輝度 Y' の特性および階調変換のゲイン特性を、図 6.14 および図 6.15 に示す。これらの特性は入力輝度 Y と特性パラメータ γ に関する式(6.4)の多項式で設定し、階調変換を乗算器と加算器のみで実現した。この構成によって、 γ を細かい精度で制御することができる。

$$Y' = \frac{Y}{1024} \left[(512 - x_a) \left\{ \left(\frac{Y}{512} - A \right) \frac{Y}{512} + B \right\} + x_a \right] \quad (6.4)$$

ここで $x_a = Y_{ave} + 128(C - \gamma)$

A, B, C : 近傍画素の平均輝度

また、ルックアップテーブルを用いない構成にできるため、回路規模も小さくできる。図 6.14 の入出力特性は、傾きの積分値が一定 $\left(\int_0^{512} \frac{dY'}{dY} dY = 255 \right)$ の関係を満たす必要があるため、 $Y=0$ におけるゲイン $\left(\frac{dY'}{dY} \Big|_{Y=0} \right)$ を大きくしすぎると他の Y の値において特性の傾きが小さくなり、コントラストが低下する。

以上の考察と実画像を用いた階調変換の特性検討に基づき、 $\gamma = 4$ の特性として、 $Y=0$ における階調を 3 倍に強調し、かつ、明るい部分の階調も再現できるように設定した。これによって、テレビ画面上で視覚的に階調を再現できる被写体の輝度下限と上限との比を 3 倍に広げた。




図 6.14 ニューロガンマ処理における輝度の入出力特性





図 6.15 ニューロガンマ処理における輝度のゲイン特性

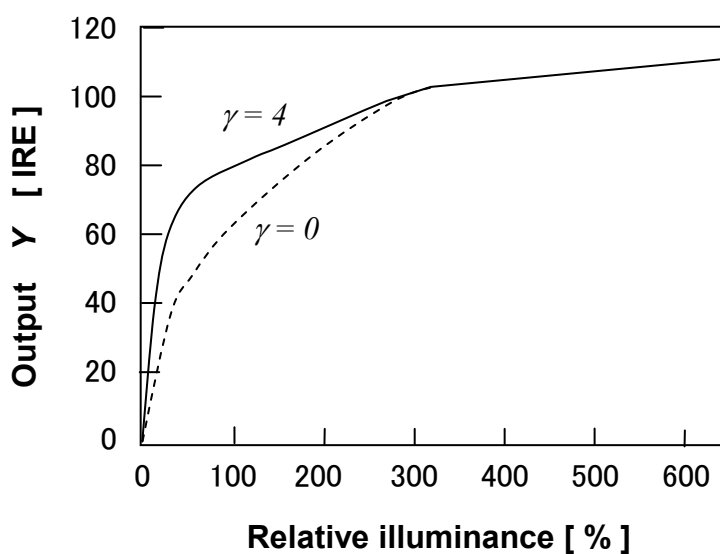
図 6.16 に、従来の処理によるカメラの出力特性(a)と、ニューロガンマ処理を用いたカメラの出力特性(b)を示す。グラフの横幅は、従来のカメラにおいて 100 IRE の出力輝度が得られる被写体照度を基準(100%)として、相対的に表わした被写体照度である。従来のダイナミックレンジ 200%のカメラは、100%の被写体照度までは 0.45 乗の特性を持ち、(被写体照度, 出力) = (200%, 110 IRE) までニー特性を持つ。図 6.16(b) は、ダイナミックレンジ 200%の従来のカメラの絞り開度を(a)の状態の約 1/3 にし、(被写体照度, 出力) = (300%, 100 IRE) まで 0.45 乗の特性で、(被写体照度, 出力) = (600%, 110 IRE) までニー特性を持つ信号(図 6.16(b)の $\gamma=0$ の特性)にニューロガンマ処理を施した信号の特性である。 $\gamma=4$ の特性によって、暗い画素については従来のカメラ(a)と同じ階調再現を得ることができ、明るい画素についても 600%の被写体照度まで階調を再現できる。

入力信号(R, G, B)の量子化精度を 9 ビットとし、最大 3 倍のゲインアップによって偽輪郭が発生しないようにした。一般的に、アナログで 0.45 乗のガンマ処理を行っている民生用ビデオカメラでは 8 ビット精度で量子化を行っている。アナログで 0.45 乗のガンマ処理を行った後に、AD変換を行い、ニューロガンマ処理においてデジタルで最大 3 倍のゲインを掛ける構成では、計算上は 10 ビット精度で量子化する必要がある。しかしながら、イメージセンサ出力信号に 0.45 乗のガンマ特性を掛けた後の暗部の信号の S/N を考慮すると、量子化精度として 10 ビットは不必要と考えられ、また、実際の撮像画像においても、9 ビット精度で量子化を行っても偽輪郭の発生がなく、10 ビットで量子化した場合と比べても S/N の劣化はないことを確認した。輝度のゲインアップによってノイズも増幅される問題については、6.2.2 項で述べるノイズリダクションとの連動によって解決した。また、図 6.14 の特性で、傾きが小さい領域の輝度においてもコントラストを保つために、階調変換の多項式は、近傍画素の平均輝度 Y_{ave} の項を持たせるようにし、入力輝度 Y と特性パラメータ γ が等しい画素でも、 Y_{ave} に応じて近傍画素との差を 1.2 倍に強調するように、異なるゲインを掛

けて階調変換を行った。



(a) ダイナミックレンジ 200%の従来カメラの出力特性



(b) ニューロガンマ処理を用いたカメラの出力特性

図 6.16 従来カメラとニューロガンマ処理を用いたカメラの出力特性の比較

6.2.1.2 色信号処理方式

式(6.5)に示す輝度信号 Y に対してガンマ補正を行う訳であるが、この時に、色相、彩度の変化を如何にして少なくし、色信号 (R, G, B) を決定できるかが、自然な再現を行う上で大きなポイントになる。そこで、式(6.6)に示す「色差一定変換」、式(6.7)に示す「色比一定変換」、式(6.8)に示す、新たに提案した「色差色比混合型変換」の3つの方式について以下に検討を加え、最終的に、「色差色比混合型変換」を用いることにした。以下、その詳細検討について述べる。

$$Y=0.299R+0.587G+0.114B \quad (6.5)$$

「色差一定変換」

$$\begin{bmatrix} Y' \\ R' \\ B' \end{bmatrix} = \begin{bmatrix} \gamma(Y) \\ R + Y' - Y \\ B + Y' - Y \end{bmatrix} \quad (6.6),$$

「色比一定変換」

$$\begin{bmatrix} R' \\ G' \\ B' \end{bmatrix} = \begin{bmatrix} R\gamma(Y')/Y \\ G\gamma(Y')/Y \\ B\gamma(Y')/Y \end{bmatrix} \quad (6.7)$$

「色差色比混合型変換」

$$\begin{bmatrix} R'_c \\ G'_c \\ B'_c \end{bmatrix} = \begin{bmatrix} mR'_r + (1-m)R'_d \\ mG'_r + (1-m)G'_d \\ mB'_r + (1-m)B'_d \end{bmatrix} \quad (6.8)$$

[色差一定変換の特徴]

色差一定変換では、補正前後の色差を一定に保って、色信号を求めるものである。図 6.14 に示したように、ガンマ補正は中間調領域でのゲインアップを主体として行う訳であるが、式(6.6)に示す「色差一定変換」を用いると、ゲインアップによって輝度信号のレベルは大きくなるが、色差信号のレベルが一定に

保たれるため、補正により色光の 3 原色の比が小さくなり、各色とも彩度が低下することになる。一方、色相に関しては式(6.11)で示すように、補正の前後で変化しない。

$$R' - Y' = R - Y \quad (6.9), \quad B' - Y' = B - Y \quad (6.10)$$

$$\therefore \frac{R' - Y'}{B' - Y'} = \frac{R - Y}{B - Y} \quad (6.11)$$

[色比一定変換の特徴]

色比一定変換は、補正前後の色比を一定に保って色信号を求めるものである。色(6.7)に示す「色比一定変換」を用いると、色光の 3 原色の比が保たれるため、ゲインアップによって輝度信号のレベルが大きくなると同時に彩度が増加することになる。一方色相に関しても、色差一定変換と同様に変換の前後で変化しない。以下にその詳細について説明する。

均等知覚色空間での 2 色の座標値(補正前と補正後)を $[L_1^*, u_1^*, v_1^*]$ 、及び $[L_2^*, u_2^*, v_2^*]$ とすると、補正による各色の彩度の変化 ΔS_{uv} は式(6.12)となり、色相の変化を同じ単位で評価するために、各色に対する色相の変化 ΔH_{uv} を式(6.13)とする。

$$\Delta S_{uv} = S_1 - S_2 \quad (6.12)$$

$$\text{但し } S_1 = (u_1^{*2} + v_1^{*2})^{1/2}, \quad S_2 = (u_2^{*2} + v_2^{*2})^{1/2}$$

$$\Delta H_{uv} = \frac{S_1 + S_2}{2} |\theta_1 - \theta_2| \quad (6.13)$$

$$\text{但し } \theta_1 = \tan^{-1}\left(\frac{u_1}{v_1}\right), \quad \theta_2 = \tan^{-1}\left(\frac{u_2}{v_2}\right)$$

色相の変化という観点で考えた場合、「色比一定変換」は補正前後における 3 刺激値 $[X, Y, Z]$ の比も一定に保たれる。一方 3 刺激値から $L^* u^* v^*$ 均等知覚色空間への変換は式(6.14)～(6.16)で表わされる。

補正前後の 3 刺激値の比が一定に保たれる場合、式(6.14)～(6.16)における u^* 、 v^* は補正によらず同一の値を保ち、補正後の u^* 、 v^* の変化は L^* の変化に比例する。この関係と式(6.12)より彩度の変化は明度 L^* の変化に比例し、さらに式(6.13)から色相は変化しないことがわかる。

$$L^* = 16 (Y/Y_0)^{1/2} - 116 \quad (6.14)$$

$$u^* = 13L^*(u^* - u_0) \quad (6.15)$$

$$v^* = 13L^*(v^* - v_0) \quad (6.16)$$

$$\text{但し } u^* = \frac{4X}{X+15Y+3}, \quad v^* = \frac{9}{X+15Y+3}$$

【色差色比混合型変換の提案と採用】

上記の検討に基き、彩度変化、色相変化を含めた色度変化を抑えるよう、両補正法の内分値を用いる「色差色比混合型変換」を提案し採用することにした。

この「色差色比混合型変換」は、式(6.8)に示すように、 R 、 G 、 B 信号の「色比一定型」による補正值 $R'r$ 、 $G'r$ 、 $B'r$ と「色差一定型」による補正值 $R'd$ 、 $G'd$ 、 $B'd$ との内分比を m とし、補正後の信号 R'_c 、 G'_c 、 B'_c を求めるものであり、色差一定変換のゲインアップによる彩度低下と、色比一定変換の彩度増加を相殺することができるとともに彩度変化も無い。具体的な内分費 m は 0.5 として開発を行った。

6.2.2 量子化ニューロンによるガンマ特性選択

民生用ビデオムービーへの実装を考えた場合、すでに述べた量子化ニューロンチップや ASQA チップを用いるのは得策ではない。民生用としてリーズナブルな、さらに簡便な実装が必要となる。そこで、量子化ニューロンチップを用いてガンマ特性選択ルールの学習を行わせ、学習結果を簡便なハードウェアとして実装することを基本に開発を行った。

6.2.2.1 ガンマ特性選択ルールの学習に用いる画像


様々な撮像条件による画像 300 枚を用意し、6.2.1.1 条で説明した 5 種類のガンマ特性を用いて補正した画像を被験者に提示、最も良好な再現が行われている画像の番号(ガンマ特性)を選ばせて、その画像の教師信号 γ_s とした。

このプロセスを 2 回繰り返す、同じ画像に対し異なる階調補正曲線が選ばれた場合には、どちらか一方を再度選択させた。

6.2.2.2 ガンマ特性選択に用いる画像特徴量

画像の状態を代表する特徴量として、画像のブロック毎の輝度等さまざまな特徴量を入力、ネットワークに学習させて比較した結果、画像中の低輝度画素数、中輝度画素数、高輝度画素数の 3 種類の特徴量(L, M, H)を用いた場合に、学習に用いた画像に対しても、未学習(学習に用いなかった)画像に対しても、人間が選択したガンマ特性と最もよく一致し、この特徴量を採用した。

具体的特徴量の事例を図 6.17 に示す。この事例では輝度レベルを 4 レベルに均等分類し、レベル 1 を低輝度、レベル 2、3 を中期度、レベル 4 を高輝度と定義、それぞれのレベルに属する画素数をカウントし、特徴量(L, M, H)とした。



(a) 逆光画像

(b) 順光画像

図 6.17 ガンマ特性選択に用いる画像特徴量

6.2.2.3 学習に用いるネットワーク構造

画像特徴量に基づくガンマ特性選択を行わせるネットワーク構造として、2.2 節で説明した、量子化ニューロンを用いた 5 層の MFLN を用いることにし、図 2.3 で示す、入力層の量子化ニューロン数 I を 1 に設定、画像特徴量各 (L, M, H) を、それぞれ入力層から第 3 層目の量子化ニューロンに入力し、学習を行った。各層の量子化レベルは 8 とし、線形で量子化した。

最終出力層のニューロン数 p は、 $\gamma=0$ から $\gamma=4$ に対応する 5 に設定した。学習には、すでに説明した量子化ニューロンチップを搭載した量子化ニューロンボードを用いて行った。

6.2.2.4 ガンマ選択ルールの学習結果

ガンマ選択ルールを小規模回路で実現するために、学習終了後の MFLN の、入力特徴量に対する出力 γ の分布を分析するとともに、この γ の出力分布を学習結果としてハードウェア実装した。

各フィールド画像に対して特徴抽出に用いる画素の数 (L+M+H) は一定なので、入力特徴量 (L, M, H) は (L, M) 平面の上で表わすことができる。入力特徴量 (L, M, H) の値を変化させて、MFLN の出力 γ の値を (L, M) 平面上にプロットし

たものを図 6.18 に示す。なお図において、未学習の画像に対する出力に関しては、近傍にある学習画像の γ_s から補間した値と極端に異なる場合には、誤動作を避ける意味から、 γ_s の補間値と置換することで、安定した出力分布を得た。




図 6.18 ガンマ選択ルールの学習結果
(画像特徴量入力に対する MFLN の出力分)

6.2.2.5 ガンマ選択ルール学習結果の分析

図 6.18 の(L, M)平面上において、Lが最大値となる特徴量は暗い画像に相当し、Mが最大値となる画像は順光の画像に相当し、L=M=0となる特徴量は明るい画像に相当する。これらの画像に対しては、MFLNの出力は $\gamma=0$ 、すなわち、階調補正を行わないとしている。逆光の画像は、図 6.17 の特徴量の分布における輝度あたりの画素数が、低輝度部や高輝度部において中輝度部よりも極端に多い場合と考えられる。Mに相当する輝度のレベル幅をLに相当する輝度のレ

ベル幅の 2 倍に設定しているため、 $(M-2L)$ が少ないほど $\gamma=4$ に近い特性パラメータとなり、 L が極端に多い領域では再び $\gamma=0$ となっている。

6.2.2.6 ガンマ判定部の小規模回路での実現

図 6.18 のガンマ選択を実現する回路を図 6.19 に示す。ガンマ選択部に、量子化ニューロンの簡易構造を用い、2 つの特微量の差 $(M-2L)$ および特微量 H を量子化する量子化 RAM (QRAM) を設けてある。これらの RAM を信号処理 LSI に内蔵してあり、LSI のパワーオン時に EPROM からデータをロードした後は、ルックアップテーブル ROM として機能する。 $M-2L$ を量子化する QRAM は、図 6.18 の (L, M) 平面上の $M=2L$ に垂直な方向の軸上で、入力特微量を量子化する機能を持つ。同様に、 H を量子化する QRAM は、 $M=L$ の方向の軸上で入力特微量を量子化する機能を持つ。出力 RAM (ORAM) は、それぞれの量子化値に対して特性パラメータ γ_n を割り当てる機能を持つ。このように、特微量を量子化した値を入力とするルックアップテーブル上で、ガンマ特性選択を実現した。以上の構成によって、ガンマ選択部を 1 個のルックアップテーブル (64k word \times 5b) で実現する場合と比べ、メモリ容量を 1/100 以下 (2.4 kb) で実現することができた。




図 6.19 2 段の RAM によって構成したガンマ選択部のブロック図

6.2.2.7 ガンマ特性の過渡応答

照明条件が変化する動画像入力において、ガンマ特性の急激な変化による違和感をなくすため、ガンマ選択部が出力する特性パラメータ γ に対し、図 6.20 に示す時間軸方向のローパスフィルタ (LPF) を掛けて、画像に適用する特性パラ

メータ γ を得るようにした。これにより、照明条件の変化によって γ が4から0に急激に変化した場合時でも、 γ の値は図6.21に示すように、徐々に変化させることができた。また図6.20のシフトレジスタにおけるシフト量を調整することにより、レンズの絞り開度の変化の速度と同程度の速さで、自然に階調変換特性を変化させることを可能にした。また、 γ をは8ビット精度で表現することで、図6.18や図6.19の γ よりも細かく滑らかな特性の制御を可能にした。




図 6.20 γ を徐々に変化させるための LPF の構成




図 6.21 ガンマ特性切り替わり時の経時変化

6.2.3 カメラの他のブロックとの協調動作

6.2.3.1 過順光被写体の階調再現

逆光でも過順光でも適正な露出を得るために、イメージセンサ出力の平均輝度と最高輝度がともに目標値に近づくように、マイコンはレンズの絞り開度を制御する。この絞り制御によって、逆光の被写体に対しては明るい部分が適正な露出になるように絞り開度を調整し、暗い部分の階調も再現されるようにニューロガンマ処理によって非線形な階調変換を行う。過順光の被写体でも明るい部分が適正な露出になるように絞り開度を調整する。過順光と逆光では画面全体の輝度の分布は似ており、ともに明るい画素と暗い画素が多く、中間輝度の画素が少ない分布を持っている。マイコンは画像の周辺部と中央部の輝度の平均を比較し、周辺部に比べて中央部が明るい場合には過順光と判断、ガンマ判定部が出力する γ の値を減じてLPFに供給する。これによって、過順光の画像の暗部のゲインアップを抑制し、黒浮きを抑えることができた。

6.2.3.2 S/Nの保持方法

暗部の輝度のゲインアップによるノイズレベルの増加を抑えるために、ニューロガンマ処理はAGC、ノイズ抑圧、および輪郭強調回路と連動している。被写体の輝度が低いためにAGCでゲインアップしている画像に対しては、ニューロガンマ処理においてはゲインアップを行わない。ノイズ抑圧回路はフィールドおよびフレーム巡回型で、1フィールドおよび1フレーム前の信号と現フィールドの信号との差信号に対して、ガンマ特性パラメータ γ に応じた非線形特性の変換を掛けて、現フィールドの信号から引く。 γ 値が大きいときには、フィードバックループにおける非線形特性の振幅を大きくすることにより、ノイズを強く抑圧した。輪郭強調回路はレベルディペンデント型で、輝度信号の高周波成分に対し、各画素の輝度およびガンマ特性パラメータ γ の値に応じた非線形特性を掛けた上で、もとの輝度信号に加えた。 γ の値が大きいときには、高周波成分に

掛ける非線形特性の振幅を小さくすることにより、輪郭強調を抑えるようにした。これらの動作によって、ニューロガンマ処理によるゲインアップに伴うノイズの増幅を抑え、S/N を保持した。

6.2.4 ニューロガンマ処理による撮像画像

最終的に得られた、ニューロガンマ処理による撮像画像を図 6.22 に、従来の絞り補正によって得られる画像と比較して示す。図 6.22 に示すような、暗部と明部との輝度の差が大きく、絞り補正では暗部と明部との両方の階調を再現することができない場合でも、本方式によれば暗部の階調が適度に強調され、暗部と明部の両方を最適な階調性を持たせて再現することができた。

図 6.22 中のニューロガンマ処理による画像(a)は、従来の絞り処理による画像(b-1)に比べ、D レンジが約 12dB 向上している。

**(a) ニューロガンマ
処理による撮像**

室内の人形
屋外の景色ともに
良好な階調性で
撮像可能



**(b-1) 従来の絞り
補正による撮像**

屋外に合わせると、
室内の人形が黒つ
ぶれになる



**(b-2) 従来の絞り
補正による撮像**

室内の人形に合わ
せると、屋外が白飛
びする



図 6.22 ニューロガンマ処理による撮像画像(従来法との比較)

6.2.5 逆光フリービデオムービーへの展開のまとめ

どのような照明条件においても望ましい階調再現特性を持つビデオカメラの実現に向けて、量子化ニューロンを用いたニューロガンマ処理方式を開発し、逆光フリービデオムービーを実用化した。本節で述べたような画像の評価において、人間は定性的なレベルでの評価を非常に得意としているが、この評価ルールは非常に非線形で、定量的、算術的に記述することには困難を伴う。本節では、この人間の判断ルールを量子化ニューロンを用いた手法により機械学習させることで、民生レベルの機器の知的な処理として実装、実用化することができた。

本方式の基本的コンセプトは、被写体の照明条件に応じて自動的にガンマ特性を変化させる点にある。この基本コンセプトを以下の 3 つの技術によって具現化し、ビデオカメラのダイナミックレンジを等価的に 3 倍に拡大することができた。

- (1) 逆光でも暗部、明部ともに階調を再現できるように、入力輝度 Y とガンマ特性パラメータに関する多項式で階調変換特性を表現
- (2) ニューラルネットワークの学習機能によって、人間の視覚特性に合ったガンマ選択ルールを構築
- (3) ガンマ判定部を 2 段の RAM の縦続接続で構成することにより、従来のルックアップテーブル方式に比べ 1/100 の小規模回路で実現

第7章 総括

7.1 本研究の成果

ユーザーの好みや使用される環境に適応して行く知的機器の開発が望まれている中で、学習性を有し、柔軟な処理を行える可能性を秘めたニューラルネットワークによる実現が期待されている。筆者は、上記知的機器の実現に向けて、(1) 高速な学習認識と現場での追加学習が可能で、しかもハードウェア実装が容易な「量子化ニューロン」モデル、さらにはネットワークの自動生成が可能な「適応増殖量子化ニューロン」モデルを提案し、(2) そのハードウェア化を行い、文字認識装置、画像認識装置、画像処理装置等への実用化展開を図ることができた。

本研究の成果を以下に総括する。

7.1.1 量子化ニューロンの基本モデルと処理アルゴリズム

第2章では、新たなニューラルネットワークモデルである量子化ニューロンを提案し、その基本構造と基本処理アルゴリズム、並びに量子化ニューロンを用いたネットワーク構造と学習認識アルゴリズムについて明らかにし、従来の閾値処理ニューロンによるニューラルネットワークと比較して、ハードウェア化が容易で、高速な学習と認識処理が可能であることを示した。

典型的なアプリケーションである文字認識への適用事例では、従来の階層型ニューラルネットワークと比較して、10倍以上の高速学習認識が可能で、実用性の観点で、飛躍的な性能向上が可能なことを実証できた。

7.1.2 量子化ニューロンモデルを用いたニューラルネットワークのハードウェア化

第3章では、量子化ニューロンによるネットワークを高速実行可能な量子化ニューロンチップの実現に取り組んだ。

量子化ニューロンによるネットワークは、ソフトウェアによる実行でも実用的には十分な高速学習認識性能を有するが、日本語文字認識等の大規模なネットワークを必要とするアプリケーションや、産業分野における超高速な画像認識においては、専用 LSI 化による更なる高速化が望まれる。そこで、これらを実現すべく、量子化ニューロンチップの開発と実用化を行った。

作製した専用 LSI(QNC)は、量子化ニューロンによるネットワークをハードワイヤードで構成したものである。4,736 ニューロンからなるネットワークを実行可能で、第1層(入力層)64 ニューロン、第2層 64×8 ニューロン、第3層 64×8×8 ニューロン、第4層 64×8×8×8 端子、出力層 64 ニューロンを有する。量子化ニューロンによるネットワーク演算を高速に実行可能で、20.5G CPS、20M CUPS の性能を実証した。

QNC を用いたニューロボードと、これを用いた手書き数字認識システムを開発実用化し、毎秒 1,030 文字の認識速度を実現した。また QNC を並列に結合することにより、日本語認識等に用いる大規模なネットワークを構成することも可能にした。

7.1.3 適応増殖量子化ニューロン(ASQA)への拡張

第4章では、ニューロンの分裂増殖によるネットワークの自動生成が可能な、適応増殖量子化ニューロンモデルへの拡張に取り組んだ。

一般的にニューラルネットワークでは、ネットワーク構成そのものは最初的设计事項として固定であり、試行錯誤的に決定するしか方法がなかった。

この課題に対応すべく、学習状況に応じて、ニューロンが分裂、増殖、結合し、最適なネットワークを形成可能な、適応増殖量子化ニューロンへの拡張を行った。これにより、ネットワーク構成そのものも、学習により自動形成させることが可能になり、実用面で、飛躍的な適応性を確保できた。

7.1.4 適応増殖量子化ニューロン(ASQA)のハードウェア化

第5章では、適応増殖量子化ニューロンのハードウェア化に取り組んだ。

自己増殖によるネットワーク自動生成を実現すべく、ニューロン同士の結合荷重を外付けのメモリによって構成、ニューロ演算をシミュレートする演算部と、外付けメモリに保管したネットワーク中のニューロン同士の結合荷重をアドレッシングするネットワークアクセス部とによって構成し、ASQA チップとして LSI 化を図った。また、大規模カテゴリの学習認識に対応させるため、複数ネットワークを構造的に結合した、構造化ニューラルネットワークを実行可能な構成を実現した。

作製した ASQA チップを用いて、2,965 文字種からなる漢字の認識システムを開発実用化し、毎秒 570 文字の認識速度と、認識率 98.8%を実現した。

7.1.5 量子化ニューロンモデルの実用システムへの展開

第6章では、第5章で述べた文字認識システムの開発実用化に加え、量子化ニューロンによるニューラルネットワークを用いた、他の実用システムの開発に取り組んだ。

産業分野での展開では、形状検査装置を開発実用化、民生分野では、ビデオムービーのガンマ補正に適用、簡易ネットワークによるハードウェア化により、実用的な商品展開を可能とした。何れのシステムにおいても、世界最高レベルの学習認識性能を実現できた。

7.2 今後の展開

情報通信システムや情報機器、さらには情報サービスの分野においても、知能化に対する要望は益々大きくなりつつある。量子化ニューロンは、シンプルな構成と高速実行性を有し、ハードウェア実装が容易なモデルであり、実用性の高いニューラルネットワークを実現可能である。

基本的なハードウェアとして、QNC や ASQA チップを実現したと同時に、数多くの実用製品ですでに用いられつつある。知的な認識処理を必要とする産業分野から、家電製品における知的制御まで、幅広い商品分野での今後の実用展開が期待される。

謝辞

本研究は、筆者がパナソニック株式会社にて行ったニューラルネットワークに関する研究成果をまとめたものであり、多くの皆様のご支援とご協力により完遂することができました。

本研究をまとめるにあたり、包括的なご指導とご鞭撻を賜りました大阪大学大学院工学研究科電気電子情報工学専攻の杉野隆教授に謹んで感謝の意を表します。

また、本論文をまとめるにあたり、ご親切なご指導、ご検討、ご助言を賜りました、大阪大学大学院工学研究科電気電子情報工学専攻の八木哲也教授、谷野哲三教授、並びに大阪大学大学院情報科学研究科マルチメディア工学専攻の岸野文郎教授に心より深く感謝申し上げます。

また、本論文をまとめるにあたり、数々のご検討、ご助言を賜りました、大阪大学大学院工学研究科電気電子情報工学専攻の伊藤利道教授、森勇介教授、片山光浩教授、尾崎雅則教授、栖原敏明教授、近藤正彦教授、谷口研二教授、森田清三教授に心より深く感謝申し上げます。

本論文の発表の機会を与えて頂き、また数多くのご指導とご助言を賜りました、パナソニック株式会社本社 R&D 部門先端技術研究所の上田大助所長に、謹んで感謝の意を表します。

また、本研究を進めるにあたり、数多くのご支援、ご助言、ご協力を賜りました、パナソニック株式会社本社 R&D 部門戦略半導体開発センターの丸山征克様、崎山史朗様、中平博幸様に深く感謝申し上げます。

本研究を完遂するに当たり、多大なご支援とご協力を頂いた、パナソニック株式会社 AVC ネットワークス社の阪上茂生様、パナソニックシステムネットワークス株式会社の香田敏行様、パナソニック株式会社本社 R&D 部門先端技術研

究所知能情報技術研究所の今川太郎様、パナソニック株式会社本社 R&D 部門コーポレート R&D 戦略室の近藤堅司様に、心より深く感謝いたします。

本研究は以上に記載し切れませんでした多くの皆様のご協力、ご助言、ご支援の下に完遂したものであり、ここに深く感謝申し上げます。

そして最後に、日常生活面で苦勞をかけながらも、全面的にサポートしてくれた、妻の純子と長女の聖未、長男の兼治に感謝いたします。

<参考文献>

1. Herman H. Goldstine 著, 末包良太, 米口肇, 犬伏茂之 共訳, “パスカルからノイマンまで”, 共立出版, 1979.
2. 佐々木能章, “ライプニッツ術”, 工作舎, 2002.
3. G. W. Leibniz 著, 沢口昭聿訳, “ライプニッツ著作集(1)論理学”, 工作舎, 1988.
4. G. W. Leibniz 著, 原亨吉, 三浦伸夫, 斎藤憲, 倉田隆, 佐々木力, 馬場郁, 安藤正人, 下村寅太郎, 中村幸四郎, 山本信 共訳, “ライプニッツ著作集(2)数学論・数学”, 工作舎, 1997.
5. G. W. Leibniz 著, 原亨吉, 三浦伸夫, 倉田隆, 長島秀男, 横山雅彦, 馬場郁, 西敬尚, 下村寅太郎, 中村幸四郎, 山本信 共訳, “ライプニッツ著作集(3)数学・自然学”, 工作舎, 1999.
6. B. Randell, “From Analytical Engine to Electronic Digital Computer: The Contributions of Ludgate, Torres, and Bush”, *Annals of the History of Computing*, Vol.4, No.4, 1982.
7. C. Shannon, “A Mathematical Theory of Communication”, *Bell System Technical Journal*, Vol. 27, pp. 379–423 and 623–656, 1948.
8. N. Wiener 著, 池原止戈夫, 彌永昌吉, 室賀三郎, 戸田巖 共訳, “サイバネティックス 第2版”, 岩波書店, 1962.
9. J. McCarthy, M. Minsky, N. Rochester and C. Shannon, “A proposal for the Dartmouth summer research project on artificial intelligence”, 1955.

10. W.S. McCulloch and W. H. Pitts, “A logical calculus of the ideas immanent in nervous activity”, *Bulletin of Mathematical Biophysics*, Vol.5, pp.115-133, 1943.
11. F. Rosenblatt, “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”. *Psychological Review*, Vol.65, No.6, pp.386-408, 1956.
12. J. J. Hopfield, “Neural network and physical systems with emergent collective computational abilities” *Proc. NAS. U.S.A.*, Vol.79, No.8 , pp.2554-2558, 1982.
13. 中野馨, “アソシエートロン-連想記憶のモデルと知的情報処理”, 昭晃堂, 1979.
14. 福島邦彦, “コグニトロンのパターン分離能力の向上”, *電子通信学会論文誌 A*, Vol.J62-A, No.10 , pp. 650-657, 1979.
15. D. E. Rumelhart, G. E. Hinton and R. J. Williams, “Learning Internal Representations by Error Propagation”, *Parallel Distributed Processing*, Vol.1, pp.318-362, M.I.T. Press, 1986.
16. T. Kohonen, “Learning Vector Quantization”, *Self-Organization and Associative Memory*, pp.199-202, Springer-Verlag, 1984.
17. E. McDermott, “LVQ3 for Phoneme recognition”, *Proc. 1990 .Conf. ASJ*, 2-16, pp.151-152, 1990.
18. D. Reilly, L. Cooper and C. Elbaum, “A Neural Model for Category Learning”, *Biol. Cybern.*, Vol.45, pp.35-41, 1982.
19. 安井湘三, “多出力ニューラルネット:刈り込み,構造整合,機能モジュール”, *電子情報通信学会技術研究報告*, NC95-172, Vol.95, No.599, pp.137-142, 1996.
20. 大平岳将, 山内康一郎, 大森隆司, “メタ学習による追加学習の高速化”, *電子情報通信学会技術研究報告*, NC2002-193, Vol.102, No.730, pp.119-124, 2003.

21. W. J. Freeman, "Lessons from Neurobiology for Feedback Architectures and Oscillatory Dynamics in Pattern Recognition with Artificial Neural Networks", Proc. Int. Conf. on Fuzzy Logic & Neural Networks. IIZUKA'90, Vol.1, pp.27-30, 1990.
22. W. Fakhr and M. I. Elmasry, "A Fast Learning Technique for the Multi Layer Perceptron", Proc. IJCNN'90, Vol.3, pp.257-262, 1990.
23. S. Maruno and A. Schoenberg, "Voice command recognition system for handicapped persons using multi-layered networks", Proc. Annual Int. Conf.of IEEE Eng. in Medicine & Biology Society Vol.10, Part 4/4, pp.1590-1591, 1988.
24. S. Maruno, "Multi Functional Layered Network using Quantizer Neurons", Computer World '90, pp.202-209, 1990.
25. T. J. Guillerm and N. E. Cotter, "Neural Networks in Noisy Environment: A Simple Temporal Higher Order Learning for Feed-Forward Networks", Proc. IJCNN'90, Vol.3, pp.105-112, 1990.
26. M. Stinchcombe and H. White, "Approximating and Learning Unknown Mapping Using Multilayer Feedforward Networks with Bounded Weights", Proc. IJCNN'90, Vol.3, pp.7-16, 1990.
27. H. Yang and C. C. Guest, "High Order Neural Networks with Reduced Numbers of Interconnections Weights", Proc. IJCNN'90, Vol.3, pp.281-286, 1990.
28. Y. H. Kong and A. S. Noetzel, "The Piecewise Linear Neural Network: Training and Recognition", Proc. IJCNN'90, Vol.3, pp.245-250, 1990.
29. T. Matsumoto and M. Koga, "A High-Speed Learning Method for Analog Neural Networks", Proc. IJCNN'90, Vol.2, pp.71-76, 1990.

30. T. K. P.guyen, R. P. Lippmann, B. Gold and D. B. Paul, "A Physiologically Motivated Front-End for Speech Recognition", Proc. IJCNN'90, Vol.2, pp.503-508, 1990.
31. W. Pedrycz, "Relational Structure in Fuzzy Sets and Neurocomputation", Proc. Int. Conf. on Fuzzy Logic & Neural Networks IIZUKA'90, Vol.1, pp.235-242, 1990.
32. A. Iwata, K. Hotta, H. Matsuo, N. Suzumura, S. Matsuda and M. Yoshida, "A Large Scale Neural Network 'CombNet' on a Neural Network Accelerator(Neuro-Turbo)", Proc. Int. Conf. on Fuzzy Logic & Neural Networks IIZUKA'90, Vol.1, pp.329-333, 1990.
33. K. Fukushima and N. Wake, "Neocognitron: A Hierarchical Neural Network Model for Pattern Recognition", Proc. Int. Conf. on Fuzzy Logic & Neural Networks IIZUKA'90, Vol.1, pp.387-390, 1990.
34. M. Okada and K. Fukushima, "Neocognitron Learned by Backpropagation", Proc. Int. Conf. on Fuzzy Logic & Neural Networks IIZUKA'90, Vol.2, pp.667-670, 1990.
35. H. Takagi, T. Kouda and Y. Kojima, "Neural Network Designed on Approximate Reasoning Architecture and Its Application to the Pattern Recognition", Proc. Int. Conf. on Fuzzy Logic & Neural Networks IIZUKA'90, Vol.2, pp.671-674, 1990.
36. 岩田彰, 當麻孝志, 松尾啓志, 鈴木宣夫, "大規模 4 層ニューラルネット "CombNET"", 電子情報通信学会論文誌 D2, Vol.J73-D2, No.8, pp.1261-1267, 1990.
37. 堀田健一, 岩田彰, 諏訪喜久, 鈴木宣夫, "CombNET II による多数カテゴリの分類", 1991 年電子情報通信学会春季全国大会講演論文集, D-64, 1991.

38. 高木英行, 香田敏行, 小島良宏, “ファジィ推論アーキテクチャに基づくニューラルネット”, ファジィ学会誌, Vol.3, No.1, pp.133-141, 1991.
39. 小島良宏, 香田敏行, 高木英行, 鈴木泰治, “ニューラルネットワークの汎化性に関する一検討”, 1990年電子情報通信学会春季全国大会講演論文集, D-5, 1990.
40. 高木英行, 鈴木規之, “ファジィ推論アーキテクチャに基づくニューラルネットの VTR テープ走行調整行程への適用”, ファジィ学会誌, Vol.3, No.4, pp.186-194, 1991.
41. Y. Linde, A. Buzo, and R. M. Gray, “An algorithm for vector quantizer design”, IEEE Trans.Commun., COM-28, 1, pp.84-95, 1980.
42. 寺野寿郎, 浅居喜代治, 菅野道夫, “ファジィシステム入門”, オーム社, 1987.
43. D. E. Rumelhart, G. E. Hinton and R. J. Williams, “Learning representations by backpropagating errors”, Nature, Vol.323, No.9, pp.533-536, 1986.
44. 香田敏行, 阪上茂生, 山本浩司, 鈴木泰治, “パターン認識に適したニューラルネットワークの高速学習法”, 1990年電子情報通信学会秋季全国大会講演論文集, D-18, 1990
45. 蔵富靖規, 瀧本昭雄, 筒井博司, 小川久仁, “相対特徴抽出光ニューラルネットワークによる手書き文字認識”, 電子情報通信学会技術研究報告, CPSY, Vol.94, No.15, pp.47-54, 1994.
46. 小島良宏, 香田敏行, 丸野進, 阪上茂生, 山本浩司, 鈴木泰治, “構造化ニューラルネットワーク(NARA)によるマルチフォント漢字認識”, 電子情報通信学会技術研究報告, NC91-31, Vol.91 No.231, pp.9-16, 1991.

47. 山本浩司, 阪上茂生, 丸野進, 木泰治, “神経回路網を用いた文字切り出し手法の検討”, 1992年電子情報通信学会春季全国大会講演論文集, D-71, 1992.
48. 丹羽寿男, 萱嶋一弘, 木泰治, “文字認識後処理法と後処理による効果の分析”, 電子情報通信学会技術研究報告, PRU91-135, Vol.91, No.478, pp.71-78, 1992.
49. 丸野進, 木泰治, “機能別階層ネットワークを用いた文字認識システム”, 平成2年度画像電子学会全国大会予稿, No.18, pp.77-80, 1990.
50. H. Nakahira, S. Sakiyama, M. Maruyama, K. Hasegawa, T. Kouda, S. Maruno, Y. Shimeki, T. Satonaka and Y. Nagano, “A Digital Neuropurocessor using Quantizer Neurons”, Digest of technical papers of 1993 Symposium on VLSI Circuits, pp.35-36, 1993.
51. T. Kohda, S. Maruno, Y. Shimeki, S. Sakiyama, H. Nakahira, M. Maruyama, T. Satonaka and Y. Nagano, “Quantizer Neuron Chip(QNC) and Neuroboard with QNC for personal Computer”, World Congress on Neural Networks Vol.IV, pp.779-782, 1993.
52. B.E. Boser, E. Sackinger, J. Bromley, Y. Le Cun and L.D. Jackel, “An Analog Neural Network Processor with Programmable Topology”, IEEE J. Solid-State Circuits, Vol.26, No.12, pp.2017-2025, 1991.
53. Y. Arima, M. Murasaki, T. Yamada, A. Maeda and H. Shinohara, “A Refreshable Analog VLSI Neural Network Chip with 400 Neurons and 40K synapses”, IEEE J. Solid-State Circuits, Vol.27, No.12, pp.1854-1861, 1992.
54. K. Uchimura, O. Saito and Y. Amemiya, “A High-Speed Digital Neural Network Chip with Low-Power Chain-reaction Architecture”, IEEE J. Solid-State Circuits, Vol.27, No.12, pp.1862-1867, 1992.

55. 池田光男, “色彩工学の基礎”, 朝倉書店, 1980.
56. 社団法人 日本印刷学会編, “印刷工学便覧”, p.468, 1993 年 1 版 4 刷
57. 春木俊宣, “ファジィ理論を用いたオートアイリスシステム”, テレビジョン学会誌, Vol.44, No.8 , pp.1053-1059, 1990.
58. 江草洋, 森勉, 五島雪絵, 藤本眞, “逆光・過順光度合の導出にファジィ理論を用いた露出制御方式の検討”, テレビジョン学会技術報告, Vol.16, No.30, pp.19-24, CE'92-98, BCS'92-21, 1992.
59. 山中篤, 大西一幸, 高浜健吾, 山根康邦, 賀好宣捷, “ニューラルネットを応用したムービーのオートアイリス”, テレビジョン学会技術報告, Vol.16, No.6, pp.25-30, 1992.
60. S.M. Pizer, E.P. Amburn, J.D. Austin, R. Cromartie, A. Geselowitz, T. Greer, B.T.H. Romeny and J.B. Zimmerman, “Adaptive Histogram Equalization and Its Variations”, Computer Vision, Graphics & Image Processing, 39, 3, pp.355-368, 1987.
61. A. Morimura, K. Uomori, Y. Kitamura, A. Fujioka, J. Harada, S. Iwamura and M. Hirota, “Digital Video Camera System”, IEEE Trans. Consum. Electronics, 36, 4, pp.866-876, 1990.
62. 石原秀志, 山下春生, 阪上茂生, 丸野進, “適応的階調補正法(I)階調補正法の検討”, 画像電子学会第 125 回研究会予稿, pp.37-42, 1991.
63. 丸野進, 阪上茂生, 山本浩司, 山下春生, 木泰治, “適応的ガンマ補正法(II)量子化ニューロンによる学習型ガンマ補正法の検討”, 画像電子学会第 125 回研究会予稿, pp.43-48, 1991.

64. 田村彰浩, 阪上茂生, 中山正明, 丸野進, “ニューロガンマ処理によるカメラのDレンジ拡大”, テレビジョン学会技術報告, Vol.18, No.72, pp.13-18, 1994.
65. 丸野進, 香田敏行, 小島良宏, 阪上茂生, 山本浩司, 木泰治, “量子化ニューロンを用いた能別階層ネットワークによる文字認識”, 1991年電子情報通信学会春季全国大会講演論文集, D-66, p.6-66, 1991.
66. 香田敏行, 丸野進, 小島良宏, 阪上茂生, 山本浩司, 木泰治, “量子化ニューロンを用いた機能別階層ネットワークの追加学習”, 1991年電子情報通信学会春季全国大会講演論文集, D-65, p.6-66, 1991.
67. 丸野進, 香田敏行, 小島良宏, 阪上茂生, 山本浩司, 木泰治, “適応増殖量子化ニューロン(ASQA)による文字認識”, 電子情報通信学会技術研究報告, NC91-51, Vol.91, No.302, pp.23-28, 1991.
68. S. Maruno, T. Imagawa, T. Kohda, Y. Kojima, H. Yamamoto and Y. Shimeki, “Adaptive segmentation of quantizer neuron architecture (ASQA)”, IJCNN '93-Nagoya. Proceedings of 1993 International Joint Conference on Neural Networks, Vol.1, pp.367-370, 1993.
69. 丸野進, チャウ・イエツティ, 阪上茂生, 木泰治, “ASQAによる時系列認識ネットワーク(TASQA)を用いた形状認識”, 1992年電子情報通信学会創立75周年記念秋季大会講演論文集, Vol.6, p.6-38, 1992.
70. 丸野進, 今川太郎, 阪上茂生, 木泰治, “ASQAによる時系列認識ネットワーク(TASQA)を用いた形状認識”, 1992年画像電子学会研究会予稿, pp.25-30, 1992.

71. S. Maruno, T. Kohda, H. Nakahira, S. Sakiyama and M. Maruyama, “Quantizer neuron model and neuroprocessor-named quantizer neuron chip” IEEE Journal on Selected Areas in Communications, Vol.12, Issue 9, pp.1503-1509, 1994.
72. M. Fukuda, H. Nakahira, S. Sakiyama, M. Maruyama, T. Kouda, T. Imagawa and S. Maruno, “A digital neuro chip with adaptive segmentation quantizer neuron architecture (ASQA)”, Neural Networks for Signal Processing [1996] VI. Proceedings of the 1996 IEEE Signal Processing Society Workshop, pp.559-568, 1996.
73. 川島毅, 石黒章夫, 大熊繁, “小規模回路で実現可能なニューラルネットワークのハードウェア化手法”, 電子情報通信学会技術研究報告, NC99-90, Vol.99, No.612, 613, pp.23-28, 2000.
74. 中條直也, 黒柳奨, 道木慎二, 橋山智訓, 大熊繁, “FPGA 実装用の反復計算型ニューロン”, 電子情報通信学会技術研究報告, NC99-88, Vol.99, No.612, 613, pp.7-13, 2000.
75. 梅崎智, 高橋貞夫, “雑誌表紙からの文字切り出し”, 電子情報通信学会技術研究報告, NC2002-154, Vol.102, No.729, pp.125-130, 2003.
76. 西村晃一, 岸田悟, 渡部徹, “ニューラルネットワークを用いた指紋照合システムの構築”, 電子情報通信学会技術研究報告, NC2003-146, Vol.103, No.732, pp.65-70, 2004.
77. 井上恵介, 下ノ村和弘, 八木哲也, “シリコン網膜と FPGA による並列画像処理”, 電子情報通信学会技術研究報告, NC2005-68, Vol.105, No.419, pp.31-34, 2005.

78. 卜楠, 濱本泰治, 福田修, 辻敏夫, “FPGA による確率ニューラルネットワークのハードウェア実現”, 電子情報通信学会論文誌 D, Vol.J88-D2, No.2, pp.390-397, 2005.
79. 志賀勇太, 横井博一, “仮想学習システムの二足歩行ロボットへの応用”, 電子情報通信学会技術研究報告, NC2008-64, Vol.108, No.281, pp.31-35, 2008.
80. 渡辺優介, 松本直樹, “声道情報を用いたニューラルネット話者照合システム”, 電子情報通信学会技術研究報告, NLC2008-52, SP2008-107, Vol.108, No.337, 338, pp.167-172, 2008.
81. 須藤明人, 平山学, 張シンリ, 佐藤彰洋, 長谷川修, “自己増殖型ニューラルネットワークを用いたパターン情報ベースの推論機”, 電子情報通信学会論文誌 D, Vol.J91-D, No.6, pp.1634-1647, 2008.
82. 齊藤健, 関根好文, “パルス形ハードウェアカオスニューロンモデルを用いた NN の局所情報処理(アナログ信号処理)”, 電子情報通信学会論文誌 A, Vol.J-92-A, No.9, pp.588-595, 2009.
83. 佐藤大輔, 岩井俊哉, “カオスニューラルネットワークダイナミクスへの記憶パターン間相関の影響”, 電子情報通信学会技術研究報告, NLP2008-148, Vol.108, No.442, pp.95-100, 2009.

主要業績

<論文>

1. S. Sakaue, T. Kohda, H. Yamamoto, S. Maruno and Y. Shimeki, “Reduction of required precision bits for back-propagation applied to pattern recognition”, IEEE Transactions on Neural Networks, Vol.4, Issue 2, pp.270-275, 1993.
2. 阪上茂生, 香田敏行, 山本浩司, 丸野進, 𠄎木泰治, “パターン認識を学習する誤差逆伝搬法に必要な演算精度の削減”, 電子情報通信学会論文誌 D, Vol. J76-D2, No.3, pp.672-679, 1993.
3. S. Maruno, T. Kohda, H. Nakahira, S. Sakiyama and M. Maruyama, “Quantizer neuron model and neuroprocessor-named quantizer neuron chip”, IEEE Journal on Selected Areas in Communications, Vol.12, Issue 9, pp.1503-1509, 1994.
4. M. Maruyama, H. Nakahira, S. Sakiyama, T. Kohda, S. Maruno and Y. Shimeki, “Quantizer Neuron Chip (QNC) with Multichip Extendable Architecture” (Special Issue on Super Chip for Intelligent Integrated Systems), IEICE transaction on electronics, Vol.E77-C, No.7, pp.1057-1064, 1994.
5. 山本浩司, 阪上茂生, 丸野進, 𠄎木泰治, “ホップフィールド型神経回路網を用いた文字切出し手法”, 電子情報通信学会論文誌 D, Vol.J78-D2, No.2, pp.374-377, 1995.
6. 丹羽寿夫, 山本浩司, 小島良宏, 𠄎木泰治, 丸野進, 萱嶋一弘, “パターンと記号の統合化処理による文字認識”, 電子情報通信学会論文誌 D, Vol.J78-D2, No.2, pp.263-271, 1995.

7. S. Sakaue, M. Nakayama, A. Tamura and S. Maruno, “Adaptive gamma processing of the video cameras for the expansion of the dynamic range”, IEEE Transactions on Consumer Electronics, Vol.41, Issue3, pp.555-562, 1995.
8. 阪上茂生, 田村彰浩, 中山正明, 丸野進, “ニューロガンマ処理によるビデオカメラのダイナミックレンジ拡大”, テレビジョン学会誌 Vol.50, No.2, pp.288-294, 1996.
9. M. Maruyama, H. Nakahira, H. Fukuda, S. Sakiyama, T. Kouda, T. Imagawa and S. Maruno, “A selfconfigurable digital neuro chip addressing to multi-network architecture”, Digest of Technical Papers, 1996 Symposium on VLSI Circuits, pp.38-39, 1996.
10. 丸野進, 今川太郎, “量子化ニューロンを用いた学習適応型階調補正法によるフルカラープリント画像の高画質化”, 画像電子学会誌, Vol.38, No.5, pp.762-771, 2009.
11. 丸野進, 今川太郎, “量子化ニューロンによる時系列パターン認識ネットワーク(TASQA)と ϕ -s 特徴変換を用いた形状認識”, 画像電子学会誌, Vol.38, No.5, pp.772-780, 2009.
12. 丸野進, 今川太郎, “適応増殖量子化ニューロン(ASQA)チップを用いた高速形状認識システム-TASQA のハード化による実用システム構築”, 画像電子学会誌, Vol.39, No.2, 2010(採録決定, 掲載予定)

<査読付国際学会論文(Proceedings)>

1. S. Maruno and A. Schoenberg, “Voice command recognition system for handicapped persons using simple multi-layered networks”, Engineering in Medicine and Biology Society, 1988. Proceedings of the Annual International Conference of the IEEE, Vol.4, pp.1590-1591, 1988.
2. S. Maruno, T. Kohda, Y. Kojima, S. Sakaue, H. Yamamoto and Y. Shimeki, “Multi Functional Layered Network using Quantizer Neurons”, IJCNN'91 Singapore, Proceedings of 1991 IEEE International Joint Conference on Neural Networks, pp.541-546, 1991.
3. S. Maruno, T. Kohda, Y. Kojima, S. Sakaue, H. Yamamoto and Y. Shimeki, “Multifunctional layered network with quantizer neurons”, 1991 IEEE International Joint Conference on Neural Networks, Vol.1, pp.541-546, 1991.
4. S. Sakaue, T. Kohda, H. Yamamoto, S. Maruno and Y. Shimeki, “Reduction of necessary precision for the learning of pattern recognition”, 1991 IEEE International Joint Conference on Neural Networks, Vol.2, pp.1795-1800, 1991.
5. S. Maruno, Chow Yuet-ih, Y. Shimeki, T. Anezaki and Y. Okahashi, “Object Recognition using Temporal Pattern Recognition Networks with Adaptive Segmentation of Quantizer Neuron Architecture (TASQA)”, MVA '92 IAPR Workshop on Machine Vision Applications, pp.145-148, 1992.
6. S. Maruno, T. Imagawa, T. Kohda, Y. Kojima, H. Yamamoto and Y. Shimeki, “Adaptive segmentation of quantizer neuron architecture (ASQA)”, IJCNN '93-Nagoya, Proceedings of 1993 International Joint Conference on Neural Networks, Vol.1, pp.367-370, 1993.

7. Y. Kojima, H. Yamamoto, T. Kohda, S. Sakaue, S. Maruno, Y. Shimeki, K. Kawakami and M. Mizutani, "Recognition of handwritten numeric characters using neural networks designed on approximate reasoning architecture", IJCNN '93-Nagoya. Proceedings of 1993 International Joint Conference on Neural Networks, Vol.3, pp.2161-2164, 1993.
8. S. Maruno, T. Imagawa, T. Kohda and Y. Shimeki, "Object recognition system using temporal pattern recognition networks with quantizer neuron chip", IJCNN '93-Nagoya. Proceedings of 1993 International Joint Conference on Neural Networks, Vol.2, pp.1285-1288, 1993.
9. H. Yamamoto, S. Sakaue, S. Maruno and Y. Shimeki, "Segmentation of handwritten Japanese character strings with Hopfield type neural networks", IJCNN '93-Nagoya. Proceedings of 1993 International Joint Conference on Neural Networks, Vol.3, pp.2073-2076, 1993.
10. H. Nakahira, S. Sakiyama, M. Maruyama, K. Hasegawa, T. Kouda, S. Maruno, Y. Shimeki, T. Satonaka and Y. Nagano, "A digital neuroprocessor using quantizer neurons", Digest of Technical Papers. 1993 Symposium on VLSI Circuits, pp.35-36, 1993.
11. T. Imagawa, T. Kohda, M. Moriya and S. Maruno, "Jigsaw puzzle solving using temporal pattern recognition networks with quantizer neuron chip", International Joint Conference of the Fourth IEEE International Conference on Fuzzy Systems and The Second International Fuzzy Engineering Symposium, Proceedings of 1995 IEEE International Conference on Fuzzy Systems, Vol.5, pp.59-60, 1995.
12. S. Sakaue, A. Tamura, M. Nakayama and S. Maruno, "Dynamic range expansion of video cameras by adaptive gamma processing", Proceedings of IEEE International Conference on Consumer Electronics, pp.118-119, 1995.

13. M. Fukuda, H. Nakahira, S. Sakiyama, M. Maruyama, T. Kouda, T. Imagawa and S. Maruno, “A digital neuro chip with adaptive segmentation quantizer neuron architecture (ASQA)”, Neural Networks for Signal Processing [1996] VI, Proceedings of the 1996 IEEE Signal Processing Society Workshop, pp.559-568, 1996.
14. K. Kondo, T. Imagawa and S. Maruno, “Structured neural networks for multi-font Chinese character recognition using a newly developed digital neural network chip with adaptive segmentation of quantizer neuron architecture (ASQA)”, Neural Networks for Signal Processing[1996]VI, Proceedings of the 1996 IEEE Signal Processing Society Workshop, pp.330-339, 1996.

<招待講演>

1. S. Maruno, “Multi Functional Layered Network using Quantizer Neurons”
Proceedings of International Symposium Computer World '90, pp.202-209, 1990.
2. S. Maruno, “Smart consumer products using neural networks in Japan” Invited
talk, Neural Networks for Computing, Snowbird, Utah, U.S.A., 1993.
3. 丸野進, “ユビキタス時代のインタフェースに向けた情報処理技術”, 平成 16
年度日本人間工学会, アーゴデザイン部会シンポジウム, 2004.
4. S. Maruno, “Technical Trends of Information Processing on Five Senses”,
IMFEDK2006 Tutorial, 2006.

<学会発表>

1. 丸野進, “機能別階層ネットワークを用いた文字認識システム”, 平成 2 年度
第 18 回画像電子学会全国大会予稿, No.18, pp.77-80, 1990.
2. 丸野進, 香田敏行, 小島良宏, 阪上茂生, 山本浩司, 木泰治, “量子化ニュー
ーロンを用いた機能別階層ネットワークによる文字認識”, 1991 年電子情報
通信学会春季全国大会講演論文集, Vol.6, D-66, p.6-66, 1991.
3. 香田敏行, 丸野進, 小島良宏, 阪上茂生, 山本浩司, 木泰治, “量子化ニュー
ーロンを用いた機能別階層ネットワークの追加学習”, 1991 年電子情報通信
学会春季全国大会講演論文集, Vol.6, D-65, p.6-65, 1991.
4. 山本浩司, 丸野進, 阪上茂生, 香田敏行, 木泰治, “適応的バイアス入力法
による自然画像の復元-バイアス制御関数の検討”, 1991 年電子情報通信学
会春季全国大会講演論文集, Vol.6, D-54, p.6-54, 1991.

5. 山本浩司, 阪上茂生, 丸野進, 木泰治, “神経回路網を用いた文字切り出し手法の検討”, 1992 年電子情報通信学会春季大会講演論文集, Vol.6, D-71, p.6-71, 1992.
6. 丸野進, チャウ・イエッティ, 阪上茂生, 木泰治, “ASQA による時系列認識ネットワーク(TASQA)を用いた形状認識”, 1992 年電子情報通信学会創立 75 周年記念秋季大会講演論文集, Vol.6, D-38, p.6-38, 1992.
7. 小島良宏, 山本浩司, 香田敏行, 阪上茂生, 丸野進, 木泰治, 川上和隆, 水谷幹男, “構造化ニューラルネットワーク(NARA)による手書き数字認識”, 1992 年電子情報通信学会創立 75 周年記念秋季大会講演論文集, Vol.6, D-40, p.6-40, 1992.
8. 丸野進, 小島良宏, 山本浩司, 丹羽寿男, 萱嶋一弘, 木泰治, “パターンと記号の統合化処理 CoPS による文書認識(1)”, 1992 年電子情報通信学会創立 75 周年記念秋季大会講演論文集, Vol.6, D-313, p.6-315, 1992.
9. 山本浩司, 小島良宏, 丹羽寿男, 丸野進, 木泰治, “CoPS による文書認識(2) 神経回路網による文字切り出し処理-フィードバック情報に基づくパラメータ制御”, 1992 年電子情報通信学会創立 75 周年記念秋季大会講演論文集, Vol.6, D-314, p.6-316, 1992.
10. 山本浩司, 小島良宏, 丹羽寿男, 丸野進, 木泰治, “CoPS による文書認識(3)-複数特徴量を統合した構造化ニューラルネットワークによる漢字認識”, 1992 年電子情報通信学会創立 75 周年記念秋季大会講演論文集, Vol.6, D-315, p.6-317, 1992.

11. 今川太郎, 香田敏行, 丸野進, 木泰治, “適応増殖量子化ニューロンを用いた構造化ニューラルネットワーク”, 1993 年電子情報通信学会春季大会講演論文集, Vol.6, D-17, p.6-17, 1993.
12. 丸山征克, 中平博幸, 崎山史朗, 香田敏行, 丸野進, 木泰治, “量子化ニューロンを用いたデジタルニューロ LSI”, 1993 年電子情報通信学会秋季大会講演論文集, Vol.6, D-32, p.6-34, 1993.
13. 小島良宏, 山本浩司, 丹羽寿男, 萱嶋一弘, 丸野進, “ニューラルネットワークと記号処理の統合による手書き宛名認識(1):システムとその概要”, 1994 年電子情報通信学会秋季大会ソサエティ先行大会講演論文集, 情報・システム, D-318, p.326, 1994.
14. 小島良宏, 丹羽寿男, 萱嶋一弘, 丸野進, “ニューラルネットワークと記号処理の統合化による手書き宛名認識(2):文字切出しと認識、後処理の統合化”, 1994 年電子情報通信学会秋季大会ソサエティ先行大会講演論文集, 情報・システム, D-319, p.327, 1994.
15. 丹羽寿男, 山本浩司, 小島良宏, 萱嶋一弘, 丸野進, “ニューラルネットワークと記号処理の統合による手書き宛名認識(3):住所要素の範囲推論を用いた後処理”, 1994 年電子情報通信学会秋季大会ソサエティ先行大会講演論文集, 情報・システム, D-320, p.328, 1994.
16. 森家みち代, 今川太郎, 小原和昭, 丸野進, “領域分割ニューロガンマ補正法を用いた輪郭抽出法の提案”, 1995 年電子情報通信学会総合大会講演論文集, 情報・システム Vol.1, D-51, p.56, 1995.

<研究会>

1. 小島良宏, 香田敏行, 丸野進, 阪上茂生, 山本浩司, 木泰治, “構造化ニューラルネットワーク(NARA)によるマルチフォント漢字認識”, 電子情報通信学会技術研究報告, NC91-31, Vol.91, No.231, pp.9-16, 1991.
2. 阪上茂生, 香田敏行, 山本浩司, 丸野進, 木泰治, “バックプロパゲーション学習に必要な演算精度の削減”, 電子情報通信学会技術研究報告, NC91-32, Vol.91, No.231, pp.17-24, 1991.
3. 丸野進, 香田敏行, 小島良宏, 阪上茂生, 山本浩司, 木泰治, “適応増殖量子化ニューロン(ASQA)による文字認識”, 電子情報通信学会技術研究報告, NC91-51, Vol.91, No.302, pp.23-28, 1991.
4. 香田敏行, 丸野進, 小島良宏, 阪上茂生, 山本浩司, 木泰治, “適応増殖量子化ニューロンによるニューラルネットの追加学習性”, 電子情報通信学会技術研究報告, NC91-52, Vol.91, No.302, pp.29-35, 1991.
5. 石原秀志, 山下春生, 阪上茂生, 丸野進, “適応的階調補正法(I)階調補正法の検討”, 画像電子学会第 125 回研究会予稿, pp.37-42, 1991.
6. 丸野進, 阪上茂生, 山本浩司, 山下春生, 木泰治, “適応的ガンマ補正法(II)量子化ニューロンによる学習型ガンマ補正法の検討”, 画像電子学会第 125 回研究会予稿, pp.43-38, 1991.
7. 丸野進, 今川太郎, 阪上茂生, 木泰治, “ASQA による時系列認識ネットワーク(TASQA)を用いた形状認識”, 1992 年画像電子学会研究会予稿, pp.25-30, 1992.

8. 丸野進, 今川太郎, 香田敏行, 木泰治, 中平博幸, 崎山史朗, 丸山征克, “量子化ニューロンチップ(QNC)を用いた時系列パターン認識ネットワーク:物体形状の時系列データ変換(ϕ - s 変換)による形状認識への適用”, テレビジョン学会技術報告, Vol.17, No.58, pp.13-18, 1993.
9. 伊藤哲, 丹羽寿男, 萱嶋一弘, 丸野進, 木泰治, “利用目的に応じて最適化可能なキーワード抽出手法”, 電子情報通信学会技術研究報告, NLC93-53, Vol.93, No.366,367, pp.41-46, 1993.
10. 中平博幸, 崎山史朗, 丸山征克, 香田敏行, 丸野進, 木泰治, “量子化ニューロンを用いたデジタルニューロプロセッサ”, 電子情報通信学会技術研究報告, ICD93-99, Vol.93, No.231, pp.39-46, 1993.
11. 田村彰浩, 阪上茂生, 中山正明, 丸野進, “ニューロガンマ処理によるカメラの D レンジ拡大”, コンシューマエレクトロニクス研究会, テレビジョン学会技術報告, Vol.18, No.72, pp.13-18, 1994.
12. 今川太郎, 森家みち代, 近藤堅司, 丸野進, “量子化ニューロチップによる手振り入力インタフェース”, テレビジョン学会技術報告, Vol.19, No.57, pp.19-24, 1995.

本学位論文に密接に関係しない発表論文等の業績

<論文>

1. S. Maruno, “Plain Paper Recording Process using Magnetic Fluids, Magneto-Fluid-Graphy”, Journal of Magnetism and Magnetic Materials, Vol.39, pp.187-191, 1983.

<査読付国際学会論文(Proceedings)>

1. S. Maruno, S. Nakata and H. Irie, “Thermo-Convergent Ink-Transfer Printing (TCIP)”, Proceedings of SPSE's 3rd. International Congress on Advances in Non-Impact Printing Technologies, pp.285-288, 1986.

<招待公演>

1. 丸野進, “磁性流体のラインプリンタへの応用,” 機会学会, 磁性流体工学に関する分科会, 1978.

<学会発表>

1. 丸野進, 中田忍, 入江宏之, “集中化熱転写法によるフルカラー画像の再現”, 画像電子学会昭和 60 年度全国大会予稿, Vol.15, pp.1-4, 1985.
2. 丸野進, 中田忍, 入江宏之, “集中化熱転写法(TCIP)によるフルカラー画像の再現”, 第 2 回ノンインパクトプリンティング技術シンポジウム論文集, pp.105-108, 1985.

3. 鶴海馨, 前田陽一郎, 水本雅晴, 小澤順, 松浦聰, 野口栄治, 丸野進, “仮想モデルにおける戦略付きエージェントによるオークション方式の提案”, ヒューマンインタフェースシンポジウム’99, No.1213, 1999.
4. 伊藤智祥, 佐藤潤一, 山口孝雄, 丸野進, “ユーザカスタマイズが可能なレート制御方式”, 情報処理学会第 59 回平成 11 年後期全国大会(3)講演論文集, pp.539-540, 1999.

<研究会>

1. 丸野進, 中川昌巳, 牛原正晴, 園田信雄, 入江宏之, 大東千秋, “マグネト・フルイドグラフィ(2)マルチスタイラス化”, 画像電子学会第 64 回研究会予稿, pp.1-6, 1982.
2. 丸野進, 中田忍, 入江宏之, “集中化熱転写法(TCIP)”, 画像電子学会第 88 回研究会予稿, pp.13-18, 1986.