

解 説

ニューラルネットによる学習型画像処理

張 健

三菱電機(株)中央研究所 T661 尼崎市塚口本町 8-1-1

(1991年8月8日受理)

Image Processing Based on Learning Neural Networks

Wei ZHANG

Central Research Laboratory, Mitsubishi Electric Corporation,
8-1-1, Tsukaguchi-Honmachi, Amagasaki 661

1. はじめに

画像処理とは何らかの対象を観測して得られた画像データを入力として対象を抽出、計測、分類あるいは認識することである。本解説でいう画像処理は主に前の段階の処理、例えば、ノイズ除去、エッジ抽出、圧縮、テクスチャ解析などのいわゆる low-level の処理を指す。一般的にいえば、自然界から得られた画像データを対象とする画像処理には一般的に次のような特徴がある。

- (1) 入力データに多数の要因が複雑かつダイナミックに絡まっており、誤差を含んでいるため、問題の全体を明確に定義する、あるいはモデル化することが難しい。
- (2) 多段階、非線形な処理が必要である。
- (3) データ量が莫大であるため、並列高速処理が重要である。

従来開発されてきた画像処理手法は問題の数学的解析によるものが多い¹⁾。つまり、まず問題を分解し簡単化する。そして、それぞれの部分問題を定式化して処理方法を決める。最後に、それらの部分処理を多段階、あるいは並列に組み合わせ、問題を解決していく。実際、問題を分解、定式化するのは非常に手間がかかり、すべての要素を調べることは不可能である。そのため、解析手法は理想的な合成画像にはうまく働くが、実画像や前段の処理が不完全な場合には結果が思わしくないことが多い。さらに、各段階の部分処理の役割分担の最適化を考慮することが困難であるため、問題の複雑さとともに、処理の手順が増え、システムが膨大になる場合が多い。

また、各部分処理のメカニズムはかなり異なる場合が多いので、その並列処理を実現するハードウェアは汎用性の高いものが要求される。

最近、情報処理技術の新しい方法として、脳に学ぶニューロコンピューティングが注目を集めている^{2,3)}。その特徴としては

- (1) 入出力の例に基づいて内部パラメータを調整する、いわゆる学習あるいは自己組織化によってシステムの入出力特性を定めるので、変換規則はわからなくてもよい。したがって、解析の困難な問題に対して有力である。
- (2) 三層モデルの場合、中間層のニューロンの数が十分あれば、任意の変換関数を実現でき⁴⁻⁷⁾、しかも、その非線形、多段階処理の最適役割分担を学習によって自動的に行う。
- (3) 処理素子が単純でかつ一様であるので、ハードウェア化するのが容易である。

などが掲げられる。それらは上に述べた画像処理の特徴とよくマッチングしているのがわかる。そこで、近年、ニューラルネットによる画像処理が盛んに研究され、その応用分野、モデルの提案が数えきれないほど報告されている。それらの多くは階層型ニューラルネットに入力画像あるいは入出力画像を与えて学習させておき、学習の後、新しく入力した画像を処理していくものである。応用例としては、画像の圧縮⁸⁻¹⁰⁾、特徴抽出^{11,12)}、予測¹³⁾、二値化¹⁴⁾、自動診断^{15,16)}、修復¹⁷⁾、テクスチャ解析¹⁸⁾などが報告されている。そのほかに、メディアンフィルタなどの従来のフィルタをニューラルネットの接

統重みパターンを見なし、学習で最適化を行う研究もある^{19,20)}。それらは全部、自然画像を対象にして学習でネットワークのパラメータを自動的に修正するので処理対象の解析をしなくてすむ。しかし、学習の効果は普通、学習画像例だけを用いて評価するので、未知の画像に対する振舞いは全然保証されない。それはいわゆる「汎化」の問題で、ニューラルネットの実用化にかかわる鍵ともいえる²¹⁻²³⁾。

そこで、本解説では、階層型ニューラルネットの学習による画像処理のモデル、応用例、および学習の汎化に焦点を当て、筆者の研究に基づいて解説を試みる。

以上述べた例以外に、対象問題を一般的な制約条件を付加した最適化問題として定式化し、その目的関数を相互結合型のニューラルネットによって最小化するものがある。その処理例としては、画像修復^{24,25)}、特徴抽出²⁶⁾、二値化²⁷⁾、動画像処理^{28,29)}などが報告されている。また、相互結合型と階層型のニューラルネットを複合し、その学習による処理例も報告されている^{30,31)}。前者は本題の「学習型」から外れており、後者は複雑すぎると本解説では触れないことにする。

2. ニューラルネットによる画像処理

2.1 画像圧縮

入力層と出力層が同じ個数 $n \times n$ 個のユニットからなり、中間層がそれより少ないユニットからなる階層型ニューラルネット、いわゆる砂時計モデル（図1(a)）のメカニズムを情報圧縮に応用する考えは、Cottrell らに提案されている⁸⁾。ニューラルネットは、画像から任意に選ばれた $n \times n$ の部分を次々と入力層および出力

層に提示することによって、圧縮を学習する。学習が終わった後、新しい画像が入力層に提示される。入力層と中間層の間の変換を圧縮、中間層と出力層間の変換を復元と見ることができる。詳しくは文献1)に紹介されている。

三層砂時計モデルについて、Cottrell ら³²⁾、Bourlard ら³³⁾や船橋²⁾が特異値分析（主成分分析）による線形な方法により情報圧縮率を上げることができないことを理論的に示している。それに対して、非線形の長所を十分活用できるように片山ら³⁴⁾と入江ら³⁵⁾が五層ペーセプトロン（図1(b)参照）を情報圧縮に用いる実験を試みている。

また、Linsker³⁶⁾は Hebb 学習によって得られる階層型ニューラルネットは、情報伝達効率をよそ最大にするように自己組織化していることを明らかにした。情報保持最大化は情報の圧縮、特微量の抽出などと深く関わっている。応用例として、Sanger⁹⁾の提案した generalized hebbian algorithm(GHA)による画像圧縮がある。256×256 画素、量子化レベル 8 の顔写真に対して、8×8 個の入力ユニットと 8 個の出力ユニットを持つ線形ニューラルネットを用いている。そして写真の 8×8 の部分を任意に選んで回路網に入力し、GHA に従って自己組織化を行う。十分学習した後にでき上がったニューラルネットによって写真の 8×8 画素を 8 画素に圧縮でき、またその逆の変換で復元できることを示している。

2.2 特徴抽出

特徴抽出に関する研究が多く報告されているが、紙面の制限で、ここで角膜内皮細胞写真から細胞膜を抽出する実験についてのみ紹介する。

角膜内皮細胞の形状は、患者の角膜の状態を知る上できわめて重要な情報である。しかし、現在撮影可能な角膜内皮細胞写真はノイズが多く、低コントラストであるため（図3(a)参照）、直接、形状計測を行うのは困難である。そこで、筆者らが位置不变の階層型ニューラルネットを前処理に、従来の画像処理の手法を後処理に用いたシステムを提案して、細胞膜の抽出処理を行った^{11,42,51)}。

提案した位置不变のペーセプトロン型ニューラルネットモデルは、通常のペーセプトロン型ニューラルネットの接続重みに位置不变の制限を加えたものであり、図2に示されている^{11,37)}。このモデルには、次に示す四つの特徴がある。（1）階層型である。（2）各層はいくつかのクラスタ（図中の小さい正方形）に分割されており、各

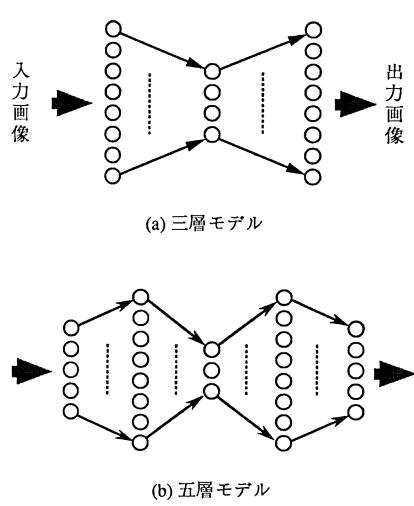


図 1 情報圧縮砂時計モデル

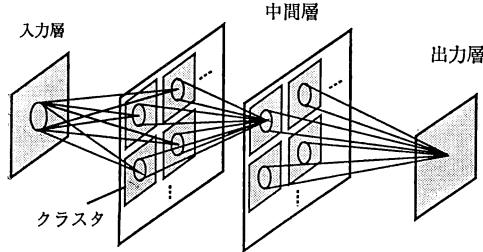


図2 位置不变パーセプトロン型モデル

クラスタ中にはユニットが2次元的に配置されている。

(3)各クラスタ間の接続は位置不变である。つまり、同じクラスタに属するユニットが同じ接続パターンを持っている。ただ、その中心がユニットの位置に応じて移動する。(4)ユニットの受容野は制限されている(図中の小さい円)。このような構造を持つニューラルネットは処理が入力パターンの位置によらず、その局所的な変形にも強いなどの特徴があるので、福島の自己組織化モデル、Neocognitron³⁸⁾で提案されて以来、他の学習モデルにも広く使われている^{39,40)}。

図2のモデルにおいて、 $l+1$ 層目のクラスタ q に属するユニット (x, y) の総入力を $N_q^{l+1}(x, y)$ とし、出力を $O_q^{l+1}(x, y)$ とするとき、信号の流れは次のように与えられる。

$$N_q^{l+1}(x, y) = \sum_{p=1}^{P^l} (O_p^l * W_{p,q}^l)_{(x,y)} + b_q \quad (1)$$

$$O_q^{l+1}(x, y) = f(N_q^{l+1}(x, y)) \quad (2)$$

ここで、* は畳み込み積分、 $W_{p,q}^l$ はクラスタ p とクラスタ q 間の接続重みパターン、 b_q はバイアス入力をそれぞれ表す。また、 f は、

$$f(x) = \frac{2}{1 + \exp(-x)} - 1 \quad (3)$$

であり、値域は $[-1, 1]$ である。

学習には、テスト画像(画素数 239×239)から切りとった、コントラストの異なる二つの部分画像(画素数 97×97)を用いた。図3(a)に、テスト画像を示す。図中、白線で囲まれた部分が学習に用いた部分である。また、教師画像には、細胞膜のトレース画像を用いた(図3(b))。学習は、入力画像、教師画像を $[-1, 1]$ で表し、誤差逆伝搬学習法を用いて行った。ただし、学習を行う際、常に各クラスタ間の接続に位置不变の制限を加えた。アルゴリズムの詳細は文献の11)と33)に述べられている。学習後のニューラルネットを用いて、テスト画像全体を処理した。さらに、その出力に対して後処理を行い、最終的な画像を得た(図4(a))。後処理は從

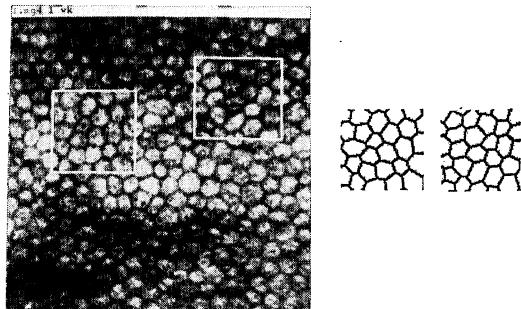


図3 (a)角膜内皮細胞写真と(b)教師画像

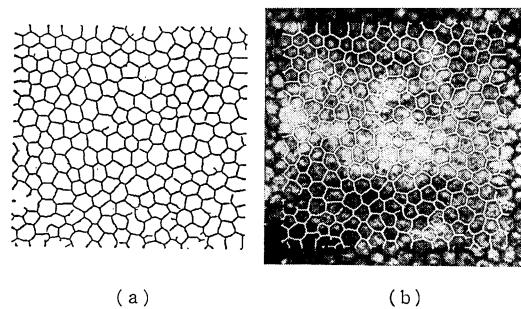


図4 処理結果。(a)抽出された細胞膜、(b)原画像と(a)と重なった像

来の画像処理の手法で、適応2値化と数学的形態学フィルタからなる^{41,42)}。処理結果の有効性を示すため、原画像と重ねて表示した結果を図4(b)に示す。図4により、本手法は正確に細胞膜を抽出できることがわかる。

3. 学習の汎化問題

ニューラルネットの学習は入出力標本点 $\{x_n, y_n : n=1, 2, \dots, N\}$ からその変換関数 $f(x)$ を推定する問題と見なせる。通常の学習法は入力標本点 x_n に対するニューラルネットの出力と理想出力 y_n との差が小さくなるように接続重み変更していくものであるので、標本点以外の点でニューラルネットの変換関数 $f_n(x)$ が本来の関数 $f(x)$ に近い値を取るという保証はない。このように、学習で得られたニューラルネットの変換関数が本来の変換関数にどれくらい近いかをニューラルネットの汎化能力という。汎化能力はニューラルネットの規模あるいは結合の数と学習標本数によって決められることが実験的に明らかになっている^{11,15,16)}。

上の2.2の実験で、規模の異なる4種類のニューラルネットに対して比較を行った。これら4種類に対し、学習した部分の入力に対する誤差が等しくなるまで学習し

表 1 比較した 4 種類のネットワーク構造・規模

	1-7-5-1 型	1-3-2-1 型	1-5-1 型	1-1 型
層の数	4	4	3	2
クラスタ数	1→7→5→1	1→3→2→1	1→5→1	1→1
ユニット数	97 ² , 87 ² , 77 ² , 67 ²	97 ² , 87 ² , 77 ² , 67 ²	97 ² , 81 ² , 67 ²	97 ² , 67 ²
受容野	11 ² , 11 ² , 11 ²	11 ² , 11 ² , 11 ²	17 ² , 15 ²	31 ²

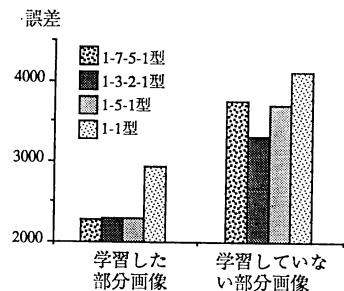


図 5 学習した部分に対する誤差を一定にした時の、学習していない部分に対する誤差

た後、学習していない部分に対する誤差を調べた。表 1 に、比較した 4 種類のニューラルネットの層の数、クラスタの数、1 クラスタ内のユニット数、受容野の大きさを示す。学習した部分に対する誤差を一定にした時の、学習していない部分に対する誤差を図 5 に示す。ただし、1-1 型に関しては、収束しないため、学習を途中で打ち切った。図 5 から、1-3-2-1 型が最適と判断される。

以上の例からわかるように、ニューラルネットの規模がその汎用能力に大きな影響を与える。ニューラルネットは簡単過ぎる場合 (1-1, 1-5-1 型) ではもちろんのこと、複雑過ぎる場合 (1-7-5-1 型) でも汎化能力が落ちる。Baum らは VC 次元の理論に基づいて、学習標本数の十分条件を与えた⁴³⁾。また、Abu-Mostafa が学習標本の情報量とニューラルネットの結合数との関係について、理論的な基準を導いた⁴⁴⁾。しかし、二つとも理論的な厳しい基準で、実際の応用には使われにくいと思

われる。

4. 付加制限による学習の汎化

学習の汎化は生理学では知識の転移ともいわれている。人間の場合、今までの知識に従って、新しく習った事例から一般的なルールを帰納するのである。ニューラルネットの学習の汎化を行う場合、同じようなアプローチが考えられる。限られた学習標本以外に、他の知識あるいはヒントをニューラルネットに与えることである。具体的な方法としては、学習する際ニューラルネットの構造に対して何らかの付加制限を加えるものが多い。2.2 で述べたように、位置不变な処理を実現するため、ニューラルネットの接続を位置不变に制限するのもその一例である。

Weigend らは時系列信号の予測⁴⁵⁾、 J_i らは連続閾数の近似問題において⁴⁶⁾、小さい接続を打ち消す評価閾数を学習の誤差閾数に加えることによって、ニューラルネットの複雑さを制限する方法を提案した。松岡らは入力の微変動に対する出力の変動が最小になる評価閾数を学習の誤差閾数に加える方法を報告した⁴⁷⁾。また、筆者らが 2.2 で述べたモデルにおいて、接続パターンのエントロピーをニューラルネットの接続の複雑さあるいは接続の有効範囲 (connectivity) の評価閾数として導入し、学習においてこれを最小化させることにより、汎化能力の向上を試みた⁴⁸⁾。以下で、この minimum-entropy back propagation (MEBP) の原理について少し詳しく説明する。

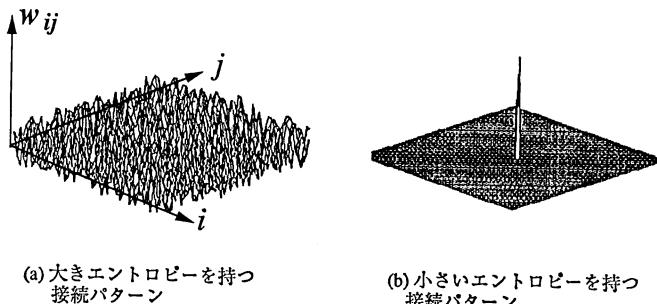


図 6 接続パターンとエントロピー

接続パターンのエントロピーの定義を次の式で与える。

$$E_w(l, p, q) = - \sum_{i,j} \tilde{w}_{p,q}^l(i, j) \ln \tilde{w}_{p,q}^l(i, j) \quad (4)$$

$$\tilde{w}_{p,q}^l(i, j) = \frac{[w_{p,q}^l(i, j)]^2}{\sum_{m,n} [w_{p,q}^l(m, n)]^2} \quad (5)$$

ニューラルネットの複雑さは、各接続パターンのエントロピーの和、

$$E_w = \sum_{l, p, q} E_w(l, p, q) \quad (6)$$

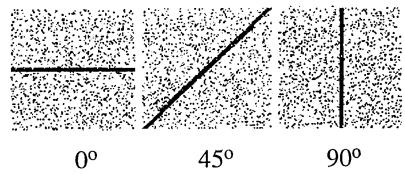
で定義される。上の定義によると、ある接続パターンが大きいエントロピーを持つ場合、その接続パターンが広い分布（図6(a)）をもつ。したがって、それによる変換は複雑である。逆の場合、接続パターンが δ 分布（図6(b)）を持ち、それによる変換は簡単である。

学習の評価関数は、

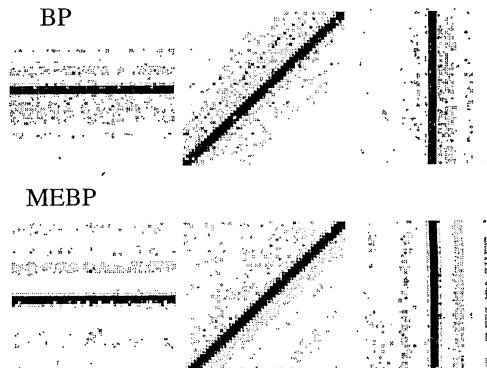
$$E = E_0 + kE_w \quad (7)$$

となる。ただし、 E_0 は出力と教師画像の間の2乗誤差で、 k はパラメータである。学習する際、式(3)の評価関数 E を最小にすることによって、与えられたサンプルパターンを満足し、しかも構造が一番簡単なニューラルネットが得られる。図7、8は線状の構造を抽出する応用の一例である。図7(a)は学習パターンである。これ

らに対し、エントロピー最小の制限をつけた場合とつぶない場合、両方で同じ出力が得られている（図7(b)）。



(a) 学習パターン



(b) 学習結果

図7 線抽出の学習結果

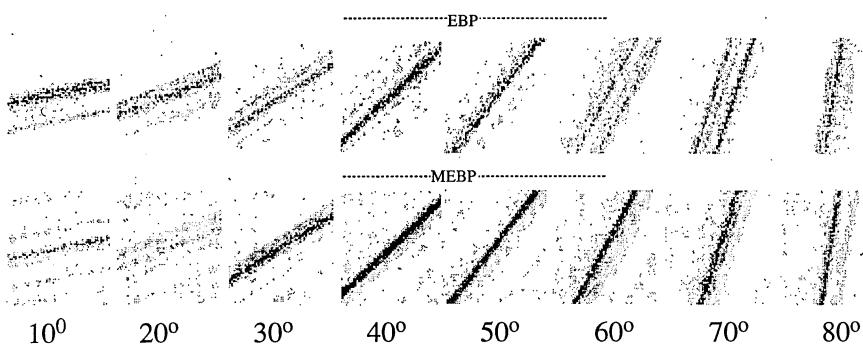
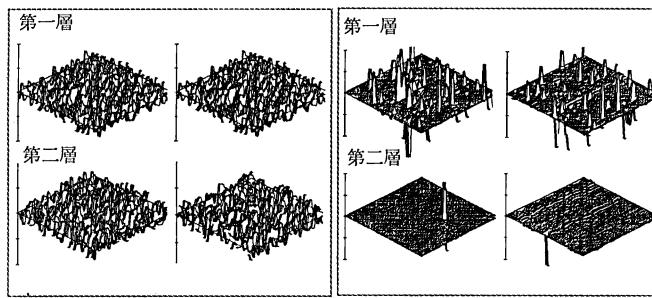


図8 テスト入力に対する出力(上: BP学習法による結果; 下: MEBP学習法による結果)



(a) BP学習で得られた重み

(b) MEBP学習で得られた重み

図9 学習後の接続パターン

ニューラルネットは3層、中間層のクラスタ数は2個、ユニットの受容野は 31×31 である。図8は制限ありと制限なしの場合のテストパターンに対する出力を表す。図8でわかるように、制限を加えることにより学習の汎化能力が高められている。学習の後、両方の場合の接続パターンが図9(a)と(b)に示されている。図9からわかるように、エントロピー最小制限つき学習で得られたニューラルネットはより簡単な構造を持っている。

5. む　　す　　び

学習型画像処理の概念、モデル、応用例、および学習の汎化について、その最近の動きのごく一部を解説した。ここでは詳しく述べることのできなかった研究、あるいは全く触れなかった重要な研究も多い。従来の方法とニューラルネットと結合して、システムの汎化能力を上げ、学習時間を短縮する試みもその一つである^{49,50)}。

学習の汎化はニューラルネットの応用に対して、非常に重要な課題である。しかし、これについての研究は個別問題を対象とし、しかも直観的なものが多いのが現状といえる。

筆者の研究を進めるにあたり、ご指導いただいた、大阪大学工学部応用物理学の岡芳樹教授、伊東一良助教授に感謝します。本解説の内容について、貴重な助言をくださった、神戸大学工学部電子工学科の野村孝徳博士に感謝します。共にご研究いただいた、大阪大学工学部応用物理学の長谷川玲氏に感謝します。また、本論文の作成において貴重な情報と知見をお教えいただいた、三菱電機中央研究所の久間和生博士、高橋正信氏、石井俊直氏に感謝します。

文　　献

- 1) 高木幹雄、鳥嶋純一郎、田村秀行：画像処理アルゴリズムの最新動向、編集二版、別冊O plus E（新技術コミュニケーションズ、1986）。
- 2) 麻生英樹：ニューラルネットワーク情報処理、第二版（産業図書、東京、1988）。
- 3) D.E. Rumelhart, et al.: *Parallel Distributed Processing*, 1st ed. (The MIT Press, Cambridge, Massachusetts, 1986).
- 4) K. Hornik, M. Stinchcombe and H. White: "Multi-layered feedforward networks are universal approximators," *Neural Networks*, 2 (1989) 359-366.
- 5) N.E. Cotter: "The stone-weierstrass theorem and its application to neural networks," *IEEE Trans Neural Networks*, 1 (1990) 290-295.
- 6) B. Irie and S. Miyake: "Capabilities of three-layered perceptrons," *Proc. ICNN* (IEEE, San Diego, 1988) pp. I641-I648.
- 7) 船橋賢一："ニューラル・ネットワークの capability について", 信学技報, MBE 88 (1988) 52-65.
- 8) G. W. Cottrell, P. Munro and D. Zipser: "Learning internal representations from gray-scale images: An example of extensional programming," *Proc. of Cognitive Science Soc. Annual Conference*, 9 (1987) pp. 461-471.
- 9) T. D. Sanger: "Optimal unsupervised learning in a single-layer linear feedforward neural network," *Neural Networks*, 2 (1989) 459-474.
- 10) 船橋賢一："三層ニューラル・ネットワークによる恒等写像の近似的実現についての理論的考察", 電子情報通信学会誌, J 73-A (1990) 139-145.
- 11) W. Zhang, A. Hasegawa, K. Itoh and Y. Ichioka: "Image processing of human corneal endothelium based on a learning network," *Appl. Opt.* (in press).
- 12) A. P. Dhawan and T. Dufresne: "Low-level image processing and edge enhancement using a self organization neural network," *Proc. IJCNN* (Int. NN Soc., San Diego, 1990) pp. I 503-I 510.
- 13) N. M. Nasrabadi, S. A. Dianat and S. Venkataraman: "Non-linear prediction using a three-layer neural network," *Proc. IJCNN* (Int. NN Soc., Seattle, 1991) pp. I 689-I 694.
- 14) 馬場口登、山田耕児、黄瀬浩一、手塚慶一："コネクションモデルによる画像2値化の実験的検討", 電子情報通信学会誌 D-II, J 73-D-II (1990) 1281-1287.
- 15) R. H. Silverman and A.S. Noetzel: "Image processing and pattern recognition in ultrasonograms by backpropagation," *Neural Network*, 3 (1990) 593-603.
- 16) M. Ozkan, H. G. Sprenkels and B. M. Dawant: "Multi-spectral magnetic resonance image segmentation using neural networks," *Proc. IJCNN* (Int. NN Soc., San Diego, 1990) pp. I 429-I 434.
- 17) J. R. P. Angel, P. Wizinowich*, M. Lloyd-Hart and D. Sandler: "Adaptive optics for array telescopes using neural-network techniques," *Nature*, 348 (1990) 221-224.
- 18) H. Greenspan and R. Goodman: "Texture analysis via unsupervised and supervised learning," *Proc. IJCNN* (Int. NN Soc., Seattle, 1991) pp. I 639-I 644.
- 19) C. H. Chu: "A spatial summation model for image processing by artificial neural networks," *Proc. IJCNN* (Int. NN Soc., San Diego, 1990) pp. I 537-I 542.
- 20) A. Asano, K. Itoh and Y. Ichioka: "Optimization of the weighted median filter by learning," *Opt. Lett.*, 16 (1991) 168-170.
- 21) Y. S. Abu-Mostafa: "Information theory, complexity, and neural networks," *Tutorial Notes of IJCNN* (Int. NN Soc., Seattle, 1991) pp. Abu-Mostafa 1-Abu-Mostafa 70.
- 22) 小河英光："逆問題としてのニューラルネット理論", 電子情報通信学会誌, 73 (1990) 690-695.
- 23) 上坂吉則："ニューロン回路網の可能性", 電子情報通信学会誌, 71 (1988) 1241-1247.
- 24) Y. T. Zhou, R. Chellappa, A. Vaid and K. Jenkins: "Image restoration using a neural network," *IEEE Trans. Acoust. Speech Signal Process.*, 36 (1988) 1141-1151.
- 25) W. Zhang, K. Itoh, J. Tanida and Y. Ichioka: "Hopfield model with multistate "neurons" and its optoelectronic implementation," *Appl. Opt.*, 30 (1991)

- 195-120.
- 26) M. Sato : "Rotation invariant formulation for line process," *Proc. IJCNN* (Int. NN Soc., San Diego, 1990) pp. II-891-II-896.
- 27) 曽根原登: "画像の最適二値化を行う緩和型神経回路モデルとその並列コンピュータによる実現", 電子情報通信学会誌 D-II, **J74-D-II** (1991) 678-687.
- 28) J. Hutchinson, C. Koch, J. Luo and C. Mead : "Computing motion using analog and binary resistive networks," *Computer*, **21** (1988) 52-63.
- 29) Y. T. Zhou and R. Chellappa : "A network for motion perception," *Proc. IJCNN* (Int. NN Soc., San Diego, 1990) pp. II-875-II-888.
- 30) S. Grossberg, E. Mingolla and D. Todorovic : "A neural network architecture for preattentive vision," *IEEE Trans. Biomed. Eng.*, **36** (1989) 65-84.
- 31) D. Cruthirds, S. Grossberg, A. Gove and E. Mingollo : "Preattentive texture segmentation and grouping by the boundary contour system," *Proc. IJCNN* (Int. NN Soc., Seattle, 1991) pp. I-655-I-660.
- 32) G. W. Cottrell and P. Munro : "Principal component analysis of images via back propagation," *SPE 1001, Visual Communications and Image Processing* (1988) pp. 1070-1076.
- 33) H. Bourlard and Y. Kamp : "Auto-association by multilayer perceptrons and singular value decomposition," *Biol. Cybern.*, **59** (1988) 291-294.
- 34) 片山泰男, 大山公一: "自己組織逆伝搬ニューラルネットの諸特性", 平1信学春季全大 (1989) SD-1-14.
- 35) 入江文平, 川人光男: "多層パーセプトロンによる内部表現の獲得", 電子情報通信学会誌 D-II, **J73** (1990) 1173-1178.
- 36) R. Linsker : "Self-organization in a perceptual network," *Computer*, **21** (1988) 105-117.
- 37) W. Zhang, K. Itoh, J. Tanida and Y. Ichioka : "Parallel distributed processing model with local space-invariant interconnections and its optical architecture," *Appl. Opt.*, **29** (1990) 4790-4797.
- 38) K. Fukushima, S. Miyake and T. Ito : "Neocognitron: a neural network model for a mechanism of visual pattern recognition," *IEEE Trans. Syst. Man Cybern.*, **SMC-13** (1983) 826-834.
- 39) B. Widrow and R. Winter : "Neural nets for adaptive filtering and adaptive pattern recognition," *Computer*, **21** (1988) 25-35.
- 40) 藤井真人: "両眼視差抽出機構の神経回路モデルー等視差面における輪郭線の特定ー", 電子情報通信学会論文誌 D-II, **J73** (1990) 1288-1296.
- 41) A. Hasegawa, K. Itoh and Y. Ichioka : "An algorithm for detecting string-like structures," *Conference Record of OC '90, Proc. Soc. Photo-Opt. Instrum. Eng.*, **1359** (1990) 351-352.
- 42) 長谷川玲, 張偉, 伊東一良, 一岡芳樹: "ニューラルネットワークと最小・最大平均値フィルタによる角膜内皮細胞膜の抽出", 第21回画像コンファレンス論文集 (1990) pp. 135-138.
- 43) E. B. Baum and D. Haussler : "What size net give valid generalization?", *Neural Comput.*, **1** (1989) 151-160.
- 44) Y. S. Abu-Mostafa : "Lower bound for connectivity in local-learning neural networks," *J. Complexity*, **4** (1988) 246-255.
- 45) A. S. Weigend, D. E. Rumelhart and B. A. Huberman : "Generalization by weight-elimination applied to currency exchange rate prediction," *Proc. IJCNN* (Int. NN Soc., Seattle, 1991) pp. I-837-I-841.
- 46) C. Ji, R. R. Snapp and D. Psaltis : "Generalizing smoothness constraints from discrete samples," *Neural Comput.*, **2** (1990) 188-197.
- 47) 松岡清利: "誤差逆伝搬法の汎化問題に対する一手法", 電子情報通信学会論文誌 D-II, **J73** (1990) 897-905.
- 48) 張偉, 長谷川玲, 伊東一良, 一岡芳樹: "ニューラルネットワークによる学習型画像処理", 第21回画像コンファレンス論文集 (1990) pp. 109-112.
- 49) W. Zhang, A. Hasegawa, K. Itoh and Y. Ichioka : "Error back propagation with minimum-entropy weights: A technique for better generalization of 2-D shift-invariant NNs," *Proc. IJCNN* (Int. NN Soc., Seattle, 1991) pp. I-645-I-648.
- 50) S. Kong and B. Kosko : "Adaptive fuzzy system for transform image coding," *Proc. IJCNN* (Int. NN Soc., Seattle, 1991) pp. I-609-I-614.
- 51) 長谷川玲, 張偉, 伊東一良, 一岡芳樹: "既知情報を利用したニューラルネットワーク画像処理", 第38回応用物理学関係連合講演会予稿集 (1991春) 31p-A-7.