TR－A－0069

# 神経回路モデルによる画像の情報処理について

曽根原　登　　川人　光男　入江　文平
佐藤　雅昭　中根　一成

1990年2月1日

ATR視聴覚機構研究所

# 目次

1. はじめに
2. マルコフランダム場に基づく確率緩和法
3. エネルギー最小化問題を解く緩和型神経回路モデル
3.1 画像の復元とエネルギー学習
  a. 雑音に汚れた幾何画像の復元
  b. エネルギー・パラメータ学習
3.2 粗い標本化からの面の復元
  a. フラクタル・ベースの標本化
  b. 画像の不連続性に基づく面の補間
3.3 エネルギー最小化による画像の量子化と復元
  a. 到る所誤差を最小にするエネルギー関数
  b. 文字と濃淡画像が混在する画像の２値化
  c. ２値画像の復元
4. 多重解像度の緩和型神経回路モデル
4.1 多重解像度緩和法
4.2 エネルギー関数と画像復元特性
  a. ブロック内標本化法
  b. 弁別しきいによる補正
5. 画像の次元圧縮
5.1 神経回路モデルによるデータ圧縮
5.2 多層パーセプトロンによるデータ圧縮
5.3 自然画像のデータ圧縮例
5.4 画像の復元手法を用いたデータ圧縮
4. まとめ

# 1.はじめに

画像処理に対する神経回路モデルの魅力は、(1)同一の演算形式を持つ多数のニューロンによる同時並列処理能力、(2)ニューロン間の結合荷重が可塑的に変化する学習能力、(3)複雑な非線形拘束条件の下で評価関数を最小化する最適化能力、等にある。

長大データを扱う画像処理では、神経回路モデルの局所並列処理性を利用することにより、大規模な最適化問題を高速に解くことができる。また、学習能力を用いることにより、様々な画像処理アプリケーションが、同じ形式の並列処理回路を用いて結合荷重を適応的に変化させることで実現できるため、汎用的なプログラムレスのパターン情報処理装置の開発を可能とする。さらに、観測量が非線形に変化する問題に対しては特徴ベクトルの抽出や、非線形な拘束条件下での最適化等を、線形システムを包含しつつ特性の改善が期待できる。

本文では、神経回路モデルを用いた画像の標本化、量子化、圧縮、復元等の画像処理の基本的問題への適用方法といくつかの実験結果について述べる[(1) (2) (3) (4) (5)]。第2章では、マルコフランダム場に基づく画像復元について述べ、第3章でこれをエネルギー最小化により実現する緩和型神経回路モデルについて述べる。緩和型神経回路モデルの応用として、雑音に埋もれた画像の復元、粗い標本化からの復元、画像の量子化等について述べる。第4章では、多重解像度緩和法と粗い標本化からの面の復元について述べる。第5章では、画像の次元圧縮への神経回路モデル適用方法について述べ、多層パーセプトロンによる画像のデータ圧縮等について述べる。

# 2. マルコフランダム場モデルに基づく確率緩和法

S. GemanとD. Geman[(10]は、マルコフ確率場モデルに基づいた最大事後確率推定を行う確率緩和（stochastic relaxation）と呼ばれるアルゴリズムを提案した。観測データをy、元の画像をxと表し、Πで確率を示す。データyが与えられた条件の下で、xのうち最も確からしいものを推定する最大事後確率推定は、

$$\prod(x|y)=\frac{\prod(y|x)\prod(x)}{\prod(y)} \qquad (1)$$

を最大にするxを見いだすことである。原画像の確率モデルとして、ある画素の状態が、その近傍だけに依存するというマルコフ確率場モデルを採用すれば、

$$\prod(x)=\frac{1}{Z}e^{-U(x)} \qquad (2)$$

$$U(x)=\sum_{c\in C} V_c(x) \qquad (3)$$

となり、Π(x) はGibbs分布となる。ここでZは定数（分配関数)、U (x) は画像の状態x に対応するエネルギーで、それは式 (3) に示すように、近傍系の局所的なエネルギー $V_c(x)$ の和として書ける。このとき事後確率Π(x | y) も、Gibbs分布で表せて、そのエネルギー$U_p$ (x) は、

$$U_p(x)=\sum_{c\in C} V_c(x)+\sum_{s}\phi(y_s,x_s) \qquad (4)$$

のように、事前分布Π (x) による第1項と、元の画像とデータから決まる局所的関数$\phi$の全格子点s∈ Sにわたる和である第2項との和になる。

結局、最大事後確率推定は、式 (4) を最小にするxを見つけることと定式化されたが、これを8ビット256x256の画像に対してしらみつぶしに行おうとすれば$256^{256\times256}$状態について式 (4) を計算しなければならず、現実的でない。確率緩和法は、事後確率Π(x | y) から決まる画素ごとの条件付確率が、局所的な相互作用エネルギーの計算だけで行えることを最大限に利用して、シミュレートされた焼きなましと局所並列繰返し演算でUp (x) の最小化を数学的に厳密に求める方法である。さらに、Gemanらは、ライン過程と呼ばれる画像の不連続（エッジ）を表す仮想の確率変数を、局所近傍を保ちながら、濃淡レベルを表す変数とともに統合した結合型マルコフランダム場モデルを実現している。

## 3. エネルギー最小化問題を解く緩和型神経回路モデル

Gemanらの確率緩和法は、確率の計算とシミュレートされた焼きなましを行うため長大な計算時間を要する。特に濃淡レベルの階調の数とともに計算時間が増大する。 Kochら[13]は、ライン過程が0（不連続がない）か1（不連続がある）のどちらかの値を取ることを、ニューロンのS字型非線形入出力関数とうまく対応させて、ホップフィールド型神経回路による巡回セールスマン問題の近似解法[11] [12] と同様に、非凸のエネルギー最小化問題を解く神経回路モデルを提案した。この神経回路モデルは決定論的に振る舞うから、確率緩和法などよりは、計算時間が少なくなる。このような局所的で繰り返し演算によって巨大な代数的システムを解く神経回路モデルを、ここでは緩和型神経回路モデル(Relaxation Neural Network Model)と呼ぶことにする。

彼らの神経回路モデルには、画像がNxNのサイズとすると、3xNxN個のニューロンが存在する（図 1)。つまり1つの画素に3種類のニューロンがあり、第1のニューロンは画素の濃

淡レベルを示し、その平均膜電位と発火頻度は等しく、$f_{ij}$で示される。第2のニューロンは垂直方向に隣りあう2つの濃淡レベル$f_{ij}$と$f_{ij+1}$の間に不連続があるかないかを決定する、水平ライン過程を表すニューロンで、その平均膜電位$m_{ij}$と発火頻度$h_{ij}$は次のシグモイド関数で関係づけられる。

$$h_{ij}=\frac{1}{1+e^{-2\lambda m_{ij}}} \qquad (5)$$

$m_{ij}$は$-\infty$から$+\infty$までの値をとる実数、$h_{ij}$は0から1までの値をとる実数である。$h_{ij}=0$であれば不連続はなく、$h_{ij}=1$であれば垂直にとなり合う画素の間に不連続がある。同様に垂直のライン過程の平均膜電位$n_{ij}$、発火頻度$v_{ij}$の間に（5）式が成り立つ。

ライン過程は実際の画像には直接現れない仮想の過程であるが、物体の輪郭や異種物体の接合部など物理世界の不連続に対応している。Gemanらが導入したライン過程は（5）式で表される1個のニューロンのシグモイド型入出力関数とうまく対応して、Kochらの神経回路モデルで表現されている。

事後確率エネルギーに対応して、Kochらは次のエネルギー関数を導入した。全体のエネルギーは次の3つの式の足し合わせである。

$$E_I+E_D=\sum_{ij}(f_{ij+1}-f_{ij})^2(1-h_{ij})+C_D\sum_{ij}(f_{ij}-d_{ij})^2 \qquad (6a)$$

$$E_L=C_V\sum_{ij}h_{ij}(1-h_{ij})+C_P\sum_{ij}h_{ij}h_{ij+1}+C_C\sum_{ij}h_{ij}$$
$$+C_L\sum_{ij}h_{ij}[(1-h_{i+1j}-v_{ij}-v_{ij+1})^2+(1-h_{i-1j}-v_{i-1j}-v_{i-1j+1})^2] \qquad (6b)$$

$$E_G=C_G\sum_{ij}\int_0^{h_{ij}}g_{ij}^{-1}(h_{ij})dh_{ij} \qquad (6c)$$

$E_I$はライン過程が$h_{ij}=0$、つまり不連続がない場合には、隣り合う2つの画素の濃淡値が互いに近い値をとることを要求するエネルギー項である。ただし、ライン過程が$h_{ij}=1$、不連続がある場合にはこの項は0となるので、隣り合う濃淡値はどれ程違っていてもよい。

$E_D$はデータの信頼性を表わす項で、これは（4）式の第2項に相当する。$d_{ij}$はij画素での濃淡値データで、分散$\sigma^2$のノイズに汚されており、$C_D=\frac{1}{2\sigma^2}$となる。

$E_L$はライン過程どうしの相互作用（不連続の連続性）に対する制限をエネルギーとして与える項である。$C_V$の項は$h_{ij}$が0または1の値をとって中間値を取らないことを要求する項、$C_P$の項は水平ライン過程が水平に2重に発生しないことを要求する項である。$C_C$はライン過程がアクティブになることそのものに対するペナルティーである。$C_L$はライン過程

が途切れたり、単独で存在したり、枝分かれやクロスがないことを要求する項である。

画像のモデルを規定するエネルギーEが各種のエネルギー$E_k$の重みつきの和で表わされているとする。

$$E=\sum_k C_k E_k \tag{7}$$

このときエネルギーEを最小化する神経回路網モデルのダイナミクスは次の微分方程式で表される。

$$\frac{df_{ij}}{dt}=-\sum_k C_k \frac{\partial E_k}{\partial f_{ij}} \tag{8a}$$

$$\frac{dm_{ij}}{dt}=-\sum_k C_k \frac{\partial E_k}{\partial h_{ij}} \tag{8b}$$

ただし、垂直のライン過程に関する式は示していない。式 (8) の右辺の各エネルギー項の状態変数に関する微分には、(i, j) 格子点の近傍の変数しか現れない。これが相互作用の局所並列性に対応している。

したがって、式 (6) で決められる緩和型神経回路モデルは、エネルギーEを式 (8) で最小化しながら最適化を行なう。このような神経回路モデルは、エネルギー関数を最小化することによって定式化される初期視覚の典型的な問題でもある。例えば、ステレオ・アルゴリズムにより、画像のなかでエッジなどの特定の位置でのみ奥行データ値がえられる場合、これら得られたデータ間の面を補間する必要がある。或は、データは到る所で得られるが、雑音に汚されており滑らかににする必要がある、といった問題に対応する。

## 3.1 画像の復元・エネルギー学習

ここでは、前述の緩和型神経回路モデルを用い、雑音に埋もれた画像の復元、川人ら[20][21] のエネルギーパラメータの学習について述べる。

まず、Geman兄弟の提案した雑音からの画像復元問題を、緩和型神経回路モデルで実現した場合の復元実験結果について述べる。次に、マルコフ確率場モデルが自然画像のモデルとしてどの程度豊かであるか、またエネルギー学習により対象画像のライン過程に関する特徴をどの程度獲得できるか、についての実験結果について述べる。

### a. 雑音に汚れた幾何画像の復元

図2は、離散的に6つの濃度レベルを持つ幾何学図形を原画像とし、ガウス雑音を付加した観測画像の復元緩和処理の様子を示している。(6)、(8) 式により定まる2次元のエネルギー関数の最小化を行なった100回毎の復元画像を同図に示す。従来の手法では、面が滑らかになり過ぎてしまい面の不連続性を忠実に反映出来ないという欠点が克服され、図2に示すように、画像の持つ不連続性を保存しつつ、画像の復元が行なわれていることが分かる。

## b.エネルギー・パラメータ学習

(6) 式に示すように、エネルギー関数に対する重み付け係数$C_k$は、データの信頼性$C_D$やライン過程の幾何学的構造（平行ライン過程$C_P$、交差ライン過程$C_L$、単独ライン過程$C_C$）に依存して定まる。しかし、これをアドホックに定めるのには問題がある。エネルギーの関数の形や、パラメータ係数は、画像のモデル、或は物理世界の拘束条件として導入されたものであるから、ある画像のセットに対しては、一意に定まるものと考えられる。そこで、川人ら[20] [1] は、これをエネルギー学習によって神経回路モデルに獲得する方法を提案している。

これは、各エネルギーを重みづけるエネルギーパラメータ$C_K$をシナプス荷重とみなし、次の学習則を与えるものである。

$$\frac{dC_k}{dt}=-\varepsilon\sum_{ij}\left[\frac{\partial E_k}{\partial f_{ij}}(f'_{ij}-f_{ij})+\frac{\partial E_k}{\partial h_{ij}}(h'_{ij}-h_{ij})\right] \qquad (9)$$

ここで、$f'_{ij}$, $h'_{ij}$はそれぞれ濃淡値とライン過程の真の値を表すシナプス学習の教師信号である。したがって、式(5)〜(6)までで決められる神経回路モデルは、エネルギーEを式(8)で最小化しながら、それが画像のモデルとして適当になるようにエネルギーパラメータを式(9)で学習する。

図3に、原画像からのエネルギーパラメータ学習とそれを用いた雑音からの復元についての実験結果を示す。用いた原画像を、図3 (a) に示す。ガウス雑音を付加した観測画像を図3 (b)、500回の繰返しによる復元画像 (e) に、学習に用いたエッジに関する教師信号を(c)に、復元されたエッジ信号を(d)に示す。学習回数は、50回であり、1回の学習に対して10回の復元処理を行う。教師信号のエッジ情報は、水平及び垂直方向の画素差分を適当なしきい値により2値化した信号を用いた。

同図に示すように、適当 なエネルギーパラメータを初期値として与えても、学習したパラメータにより、エッジ情報を再現しつつ、復元が可能であることが分かる。この時の平均信号パワーと雑音パワーの比（SN比）の改善は、約10dBである。

## 3.2 粗い標本化からの面の復元

面の復元は、不連続性を保存しながら滑らかな補間を要求するエネルギー関数の性質を示す良い例である。これらには、Koch[13] やTerzopoulas[30]、岡本ら[31] の例があるが、ここでは、フラクタルの考え方を用いて、自然画像を粗く標本化し、補間により原画像を再生する系でエネルギー関数の最小化による画像の復元特性を評価した[32] [33]。

### a. フラクタル・ベースの標本化

画像の特徴を保存しつつ粗い標本化を行なうには、画像の複雑さに対応した測度で標本化する必要がある。滑らかな低周波成分の場所では粗く、急峻な高周波成分の場所では細かくといったように行なう。そこで、標本化間隔 $t_i$ を濃度f (t) の微分df／dtに逆比例するように選ぶ。具体的には、2次元の画像をラスター走査した1次元画像に対して、次式で示すフラクタル次元測定法[40] の一つであるヤード (yardstick) 近似[41] により粗く標本化する場合について述べる。

$$t_i=[y^2-(f_{i+1}-f_i)^2]^{1/2} \tag{10a}$$

$$\mathrm{sgn}(t_i)=\mathrm{sgn}(f_{i+1}-f_i) \tag{10b}$$

ここで、yは一定であり、f (t) に沿って計測するヤード尺長である。yが一定長であるため、標本化画像は標本化間隔 $t_i$ と $t_i$ の極性sgn ($t_i$) のみで表現され、逐次的符号・復合化できる。用いた原画像は図2 (a) と同一である。図4 (a) に、フラクタルに基づく標本化で選択されたデータ点を示す。

### b. 画像の不連続性に基づく面の補間

粗く標本化されたデータからの濃度面の補間のための1次元のエネルギー関数は、(6) 式より、

$$E=\sum_i(f_{i+1}-f_i)^2(1-h_i)+Cd\sum_i(f_i-d_i)^2 \tag{11}$$

を用いる。$h_i=0$ の場合、エネルギー関数は1次微分による標準的な補間 (1次の自然スプライン) となる。標本化データの信頼性が高い場合、そのデータは強いスティフネスCdを持つので、消失データの補間は直線近似となる。そこで、滑らかな補間を行なうため、(11) 式の第1項は曲率に関係する2次微分評価関数を加えた次式のエネルギー関数の最小化を行

なう。

$$\sum_{i}(\tau f'^{2}_{i}+(1-\tau)f_i''^{2})(1-h_i) \qquad (12)$$

これは、テンション下（$\tau$）でのスプラインと呼ばれ、第1項はスプラインの長さに、第2項はその曲率に影響する[30]。

$f_i, m_i$ の更新は、(8) 式に基づき、重み係数を持った最急降下法形式で行なう。

$$f_i^{n+1}=f_i^{n}-\alpha\frac{\partial E}{\partial f_i} \qquad (13)$$

一方、ライン過程を考慮しないとエッジの情報が消失しぼけた画像となる。そこで、$t_i$、sgn（$t_i$）を用いて標本データを復号する際、

$$|\theta_i|=|\tan^{-1}\frac{(f_{i+1}-f_i)}{t_i}|\geqq\theta_L \qquad (14)$$

の時 $h_i=1$ と見なし補間処理を行なう。

図4（b）は、標本点の値をホールドした画像であり、(c) は1次元の緩和型神経回路モデルで復元した画像である。図5にヤード長yに対する、再生画像のSN比、標本化データのエントロピー、標本点の発生個数を示す。SN比は、ピーク信号パワーと平均復元誤差パワーの比によて求めた。画素当りの平均エントロピーは、長さtiの生起確率をP（ti）とするエントロピー $-\sum p(t_i)\log_2 p(t_i)$ と、微分係数の符号 $\mathrm{sgn}(f_{i+1}-f_i)$ の連続数rの生起確率をP（ri）とするランレングス・エントロピー　$-\sum p(r_i)\log_2 p(r_i)$ の和によって求めた。ヤード長32の時、画素当りのエントロピー0.54ビット、再生画像のSN比27.6dBである。また、緩和演算の繰り返し回数は、2000回である。

一方、この画像のフラクタル次元 $D_f$ は、

$$\log yN(y)=(1-D_f)\log y+C \qquad (15)$$

より求まる。ここで、N（y）はヤード長yでf（t）を計測したときの標本数である。(14) 式の直線回帰分析を行なうと、

$D_f=1.314$　　（相関度 $r=-0.984$）

となる。このように、画像の複雑度に応じてヤード長yを選択することにより、再生画像の品質、エントロピーを制御可能な画像の標本化、復元ができる。

また、(15) 式のフラクタル次元推定を用いて、標本点間のデータをフラクタル補

間'[42] [43]、滑らかな補間を緩和型神経回路モデルで行なうことにより、さらに効率的な画像復元ができる。これは、フラクタルの自己相似性に基づき、到る所でデータは得られるが、滑らかな復元を行なう必要があるという場合に対応する。

さらに、2次元方向にラインの標本化を行なう、或は、(6) 式に示す2次元の相互作用を考慮することで効率化が図れる。

このように、画像の「滑らかさ」と「不連続性」といった相反問題間の相互作用を同時に扱うことのできる画像のモデルは、様々な応用に使われていくのもと考えられる。また、フラクタルのような「制御されたランダムさ」は、画像のリアリティや自然性を記述上で重要である。今後は、「滑らかさ」「不連続性」「制御されたランダムさ」などを統一的に記述できるモデルに発展していくものと考えられる。

## 3.3 緩和型神経回路モデルによる画像の量子化と復元

ここでは、緩和型神経回路モデルを用いた画像の2レベル量子化と量子化画像の復元について述べる。実用的には、連続階調を有する画像を2レベルのデバイスに表示・印字することができれば有益である[50] [51]。これは、一般的には、明るい領域では、画素の多くを明るくするという空間的階調表現が必要である。問題は、明るくすべき画素と暗くすべき画素をどのように配置するかということになる。筆者らは、緩和型神経回路モデルのニューロンの1つに量子化画素を対応させて、その値が0か1のどちらかの値を取ることを、ニューロンのS字型非線形入出力関数と対応させて、非凸のエネルギー最小化によりこの問題を解いた[52] [32]。

## a. 到る所誤差を最小にするエネルギー関数

神経回路モデルには、画像がNxNのサイズとすると、2xNxN個のニューロンが存在する。第1のニューロンは画素の濃淡レベル$f_{ij}$を示し、第2のニューロンは量子化画素値を決定するニューロンで、その平均膜電位$m_{ij}$と発火頻度$h_{ij}$は次のシグモイド関数で関係づけられる。

$$h_{ij}=\frac{1}{1+e^{-2\lambda m_{ij}}} \qquad (16)$$

$h_{ij}=0$であればその画素は黒レベルとし、$h_{ij}=1$であれば白レベルとする。

この量子化緩和法では、各画素の量子化処理は、他の画素の量子化処理結果に依存して決定される。原画像が0から1の値をとるとき、2レベル量子化画素は、0または1となり、

その誤差は－1から＋1の範囲の値を採る。しかし、局所近傍系の誤差を画像全体に波及させることで、つまり、誤差を互いに相殺させることにより、到る所で誤差を最小とする2レベル画像が構成される。局所並列処理が可能となるような近傍系処理からなるモデルを採用すると、全体のエネルギーは次の3つの式の足し合わせとなる。

$$E_Q=\sum_{ij}\Big[\sum_{i'j'\in Vc}(f_{i+i'j+j'}-h_{i+i'j+j'})\Big]^2 \qquad (17a)$$

$$E_L=C_V\sum_{ij}h_{ij}(1-h_{ij}) \qquad (17b)$$

$$E_G=C_G\sum_{ij}\int_0^{h_{ij}}g_{ij}^{-1}(h_{ij})dh_{ij} \qquad (17c)$$

$E_Q$は、近傍系Vcの量子化画素と中間調画素の誤差の2乗が最小になることを要求するエネルギー項である。$C_V$の項は$h_{ij}$が0または1の値をとって中間値を取らないことを要求する項である。このときエネルギーEを最小化する神経回路網モデルのダイナミクスは（8）式の微分方程式で表される。

図6は、(a) を原画とした濃度レベル0～255からなる球面画像の緩和量子化処理結果(b) であり、原画像の局所的濃度レベルに応じ、空間的に密度変調された形式で2値画素が配置されている。このときの近傍系の$f_{ij}$、$h_{ij}$の相互作用としては、

$$\sum_{Vc}f_{i'j'}=5f_{00}+2(f_{-1,0}+f_{-1,1}+f_{0,1}+f_{1,1}+f_{1,0}+f_{1,-1}+f_{0,-1}+f_{-1,1})+(f_{-2,0}+f_{0,2}+f_{2,0}+f_{0,-2}) \qquad (18)$$

を用いた。同一の相互作用系を用いて、自然画像に適用した例を図7 (b) に示す。図7 (a) は、ベイヤー型の組織的ディザ法[50]（マトリックスサイズ 4X4）による2値量子化である。緩和型法では、組織的ディザ法でみられるようなテクスチャーは生じない。

階調表現レベルが数レベルであったり、S字型の非線形特性を持つデバイスに表示・印字する場合には、多値ディザ法が有効である。そこで、ニューロンのS字型特性で圧縮された画像の表現特性を求めた。図8に圧縮表現画像を示す。この時の（16）式のS字型特性のλは16である。また、近傍系の$f_{ij}$、$h_{ij}$の相互作用としては、

$$\sum_{Vc}f_{i'j'}=f_{00}+f_{-1,0}+f_{0,1}+f_{1,0}+f_{0,-1} \qquad (19)$$

を用いている。

## b. 文字と濃淡画像が混在する画像の２値化

２値画像と濃淡画像が混在する通常の原稿を光学系で読み取る場合、本来２値の文字部も濃淡レベルを持つ。ディザ法は分解能を落すことによって濃淡を再現するため、文字領域に対しても、画像領域と同一のディザマトリックスを適用すると、文字領域での分解能が劣化が著しい。このため、画像の濃淡変化に着目して、文字画像と濃淡画像を局所的に分離し、ディザマトリックスを制御する方法が提案されている[53]。緩和型量子化法は、近傍系誤差を最小にし、一つのエネルギー・パラメータでスレッショールドの制御可能である。

本来２値で表現されているフォント（24x24ドット）を（0.5,1.0,0.5）の係数を持つフィルタで濃淡レベルを作成して自然画像と結合し、原稿操作画像を作り、本量子化緩和法の特性を調べた。図９（a）は、組織的ディザ法、図９（b）（c）は、緩和型神経回路モデルによる２値化結果である。(b）は$Cv=10$,(c）は$Cv=0.5$のの場合の２値画像である。組織的ディザ法と比較すると、文字領域の分解能成分の劣化が少ない。

## c.2 値画像の復元

通常の線形低域フィルタの場合には、原画像の持つ不連続性が保存されないため、ディザ画像の低域成分のみを抽出するとぼけた画像となってしまう。 一方、Kochらのエネルギー関数は、ライン過程の検出と隣り合う2つの画素の濃淡値が互いに近い値をとることを要求するエネルギー項を定めている。そこで、(6) 式を用いて、２値画像から濃淡画像の復元を行なった。

復元処理の制御としては、雑音に埋もれた画像の復元処理と比べると、(8a) 式で示す画像の平均化処理に対し（8b）のライン仮定検出処理は2：1としておこなった。図10に図7 (a) を原画とした復元処理結果と検出したライン過程を示す。復元結果のSN比は15.9dBでああた。

画像の効率的表現の基本要素である量子化に対し、２値化を行なう緩和型神経モデルについて述べた。今後は、このような神経回路モデルがさらに高次の画像構造を処理可能なように発展させていく必要があると考えられる。

# 4. 多重解像度の緩和型神経回路モデル

多くの視覚の解析問題は、ある種の大域的特徴を扱う必要がある場合がある。ニューロン間の局所的な相互作用が与えられ、大域的特徴が繰り返し演算によってネットワーク格子を伝搬するという非直接的手法は、膨大な計算を必要とし収束が遅い。

計算の空間的局所性は、空間解像度に依存するので、粗い格子上に置ける最近傍等の領

域は、より細かな格子でのより大域的計算に対応する。そこで、Terzopolos(60) (63) はBrandtなど(61) のアルゴリズムを用いて、階層的な多重解像度表現を用いて、効率的に視覚の問題を解いている。Battiti ら(62) は、ライン過程を含めた形での多重　解像度表現により、視覚問題に適用している。本郷ら(21) は、人物の顔画像のような大域的構造が必要となる輪郭線の抽出問題への適用を提案している。

このような、多重解像度表現を用いた緩和型神経回路モデルは、人間の初期視覚システムでの空間周波数チャネルの多重解像度特性と類似しており興味深い(101)。

筆者らは、Brandtのアルゴリズムを用いた線形システムの多重解像度緩和法を用い、一様な粗い標本化と雑音に汚れた自然画像の復元特性と画像のスペクトル解析と、人間の視覚特性の一つである弁別しきい特性を用いた非一様標本化及びその復元について検討したので述べる(34)。

## 4.1 多重解像度緩和法

画像処理のある種の問題では、65536個というように膨大な数の方程式からなる線形システムを如何に効率的に解くかが一つの問題である。このような線形システムの解法は数値解析上も重要な問題であり、有限ステップで解を求める直接法や漸近的に解に収束する繰返し法等がある。ここでは、繰返し法の一つであるガウス・ザイデル（Gauss − Seidel）緩和法を用いた多重解像度アルゴリズムについて述べる。

この方法は、階層的により粗い格子との相互作用を行ないながら、与えられた格子上での離散方程式を繰返的に解く方法である。この方法は、細かい格子上での緩和法の収束を、誤差成分のスムージングにより加速するものである。図11に多重解像度表現を示す。この多重解像度表現では、ある格子から他の粗い格子にスイッチするとき、画素数は1／4となっている。

次に、このネットワークの緩和処理動作について述べる。今、解こうとしているシステムをＬ＊Ｖ＝Ｆとする。ここで、Ｌはマトリック、Ｆは観測画像を示すベクトル、Ｖは復元画像を示すベクトルである。図12に、多重解像度緩和アルゴリズムの処理フローを示す。

［ステップ（a)］FkにCkをセットして、最も細かい格子系(LEVELMAX)より処理を開始。

［ステップ（b)］緩和処理。

［ステップ（d)］そのときの誤差と所要精度とを比較し、解の収束性をテスト。

［ステップ（e)］もし現在の系が収束しており、最も細かい格子系であれば、アルゴリズム停止。

［ステップ（c')（d)（g)］収束速度をテストし、遅い場合には、一段階上の粗い格子系にスイッチ。もし、これが最も粗い格子系であれば、このレベルで十分な精度が得られるま

で、繰返処理を継続。
[ステップ (i)] 上位の系は、急速に0にならないような誤差ベクトルを持つので、この粗い系の右辺を誤差ベクトルとし、新しい解像度に対する初期状態を0とする。粗い格子系は、一つ下の格子系に対して1／4の画素数を持つため、インジェクション(Injection)と呼ばれる処理を行なう。以下、同様 (b) の処理を継続。
[ステップ (f)] 粗い格子系での解がうまく得られたら、インターポレーション(Interpolation)と呼ばれる処理により、細かい格子系の解を修正。以下、同様 (b) の処理を継続。

### (a) インジェクション

各レベルの各緩和処理で誤差画像が計算される。各画素の誤差は、より粗い格子系に伝達されなければならないが、二つの格子系のサイズは異なる。そこで、画像の復元問題に対して、より細かい格子系の隣接4近傍誤差の平均で、粗い格子系の計算を行なった。

### (b) インターポレイション

原理はインジェクションと同じであるが、情報は粗い格子系から細かい格子系に伝達される。粗い格子系では、細かい格子系の誤差が取り除かれたら、現在の解を修正するため、ここでは、粗い格子系の4点を境界値とする2次の多項式補間でデータを生成した。

## 4.2 エネルギー関数と画像復元特性

粗く標本化され、しかも雑音に汚れた画像の復元を、滑らかさの拘束条件に基づき多重解像度緩和法で復元するため、次式で示すシン・プレート(Thin plate)と呼ばれる曲げのエネルギー関数を用いた[63]。

$$E(v)=\frac{1}{2}\sum_{E\in t^{k}}\iint_{E} v_{xx}^2+2v_{xy}^2+v_{yy}^2\,dxdy+\frac{\beta}{2}\sum_{x_i,y_i\in C}[v(x_i,y_i)-c(x_i,y_i)]^2 \qquad (20)$$

ここで、$v_{xx}^2$、$v_{xy}^2$、$v_{yy}^2$ は偏導関数であり、位置 $(x_i,y_i)$ における $v(x_i,y_i)$ は復元画素を示し、$c(x_i,y_i)$ は観測画素値を示す。また、$\beta$はデータの信頼性を示すパラメータであり、スティフネスと呼ばれる。画素は、次式に示すように近傍系の画素によって補間される。

$$-\frac{8}{h^2}[v_{i,j}+v_{i+1,j}+v_{i,j-1}+v_{i,j+1}]+\frac{2}{h^2}[v_{i,j-1}+v_{i+1,j-1}+v_{i-1,j+1}+v_{i+1,j+1}]$$

$$+\frac{1}{h^2}[v_{i-2,j}+v_{i+2,j}+v_{i,j-2}+v_{i,j+2}]+\frac{20}{h^2}v_{i,j}+\beta v_{i,j}=\beta c_{i,j} \qquad (21)$$

以下では、この多重解像度緩和を用いて、画像の復元実験を行なった結果について述べる。用いた復元対象画像を図13 (a) に示す。これは、原画像に対して、ガウス雑音を付加し、これに一様な標本化をおこなった画像を、通常の一層の緩和法と多重解像度緩和法を用いて収束特性、SN比の改善特性を比較した。ガウス雑音の付加による初期画像のSN比は17.24dBであり、一様標本化の密度は1／3である。図13 (b) に復元画像を示す。復元画像のSN比は約20dBである。

図14は緩和処理回数に対する誤差特性である。繰返回数に対する収束特性は約2倍程度高速化されている。粗い格子系での緩和処理を一層の緩和処理量で規格化すると1.2倍の高速化となっている。SN比も誤差の収束とともに同様の改善効果が得られている。

## 4.3 スペクトル解析と弁別しきいによる2次元適応的標本化

前節の実験では、一様標本化に対する多重解像度緩和を用いた画像復元について述べた。ここでは、画像の特質である局所的な画像の複雑さと、弁別しきい特性に応じた2次元の標本化方法とその緩和復元特性について述べる[34]。

画像の複雑さに応じた2次元適応的標本化を行なうため、2次元画像を8X8のブロックに分割し、これを処理単位とした。各ブロックは、1、4、16、64のいずれかの標本点集合で表現する構成とした。これは、非均一な標本化を行ない、標本点情報で画像を表現する場合、そのアドレス情報が必要となるためである。したがって、画像情報はブロックの標本点数を示す番号（2ビット）と標本点の輝度成分（Nx8ビット,Nはブッロクの標本点数）で記述される。

### a. ブロック内標本化

直流成分を除く全周波成分と高周波成分に対して、パワー比Prを求める。これにより、各ブロックが高周波成分を含むか否かを定める。このときの、パワー比の算出は、全周波成分と低周波成分の比は、$(1／2)^p$ $(p = 1,2,3,4)$ の場合について求める。このため、ブッロクの離散フーリエ変換係数を $A_{ij}$ とすると、

$$Pr=\frac{\sum_{ij}^{M} A_{ij}}{\sum_{ij}^{N} A_{ij}} \quad , \quad M=N(\frac{1}{2})^p \qquad (22)$$

を用いてパワー比を評価する。ただし、8x8ブロックに対して4パターンの選択を行なうため、8x8を16x16画素に,2次の多項式補間してフーリエ変換を行なっている。この時、高

周波成分が低周波成分に比べて十分に小さければ、標本化定理より$2^p$の標本化で十分である。これは、各ブロックの標本点が1、4、16、64の何れかに対応する。

## b. 弁別しきい特性による補正

パワー比の計算で、低周波成分に直流成分を含むと、直流成分の変動に対してパワー比の変化が小さい場合、パワー比のスレショールドの設定が困難である。そこで、直流分に対しては、高周波成分の変化量が視覚的にどの程度検知されるかという弁別しきい特性に基づいて、その寄与率を設定した。

図15にCRTを用いた弁別しきい特性を示す。ただし、通常のCRT上の画像を見る環境では、周波数に対する輝度変化の寄与率は一定であるとした。図15は、刺激光Iに対する刺激光の増加量ΔIを計算機内の輝度表現レベルで示したものであり、輝度レベル50以上ではWeber則にしがっている。50以下ではCRTの非線形性により刺激量の増加量が増えている。図15より、ΔI＝f（I）特性を直線近似により求める。Iは$A_{00}$に対応するので、

$$A_{ij}\ (ij \neq 0) < f\ (A_{00}) \text{ ならば } A_{ij} = 0 \qquad (23)$$

としてPrを求める。次に、Prとスレショールドを比較し、標本化密度を決定する。標本化密度とブッロクの標本点数は一致するので、画像の2次元的複雑さに応じた標本化が可能となる。

図16（a）に上記手法において選択された2次元標本点を、（b）に（20）式のエネルギー関数の最小化緩和法により復元した画像例を示す。このときの復元画像のSN比は、約17dBであった。

# 5.画像の次元圧縮

神経回路モデルを画像のデータ圧縮に適用する利点は、(1)神経回路モデルの学習能力により、符号化の対象とする画像例から規則性を抽出して圧縮・伸長変換規則を獲得することができる、(2)この変換規則が、画像データの非線形な分布特性を反映できれば、主成分分析のような線形変換や線形予測を用いる場合より特性がよい、等の点が挙げられる。ただし、学習機械としての神経回路モデルにより変換規則を抽出する場合、学習データと同様の分布を持つ未知データに対しても同様の特性を得る必要がある。これを汎化能力と呼ぶ。また、非線形マッピングによる圧縮特性は、線形変換や線形予測の特性を包含することが実用上望ましい。

## 5.1 神経回路モデルによるデータ圧縮

次に、従来の画像データ圧縮方式[70][71]と対応して、神経回路モデルの適用形態について述べる。従来の符号化方式には、表1に示すように、(1)画像を直交変換し、変換成分の分散に応じて量子化する変換符号化、(2)符号化対象画素と近傍画素の相関を用いて予測誤差を量子化する予測符号化、(3) 複数の画素を一括してn次元の離散ベクトルに写像するベクトル量子化、(4)サブサンプルからの補間処理に基づく符号化[74]、(5)2次元画像から対象の3次元構造モデルを推定し、それを送受信で共有し変化の差分成分のみを通信するモデルベースの符号化[75]、等がある。

これらのデータ圧縮符号化方式と対応して、神経回路モデルの適用方式が考えられ、画像の学習により、それぞれ非線形の変換関数、予測関数、写像関数、補間関数を実現することを目指すことになる。モデルベースの符号化に対しては、神経回路モデルが内部表現として3次元の構造モデルを獲得することが必要となる。

非線形変換関数の実現へのアプローチには、次節で述べる多層パーセプトロンによるデータ圧縮[90][91][94][95]がある。同じく、多層パーセプトロンによる非線形の予測関数実現として、以下がある。成田ら[92]は3層パーセプトロンを用い近傍4画素からの非線形予測関数を実現し、細かい模様のある画像に対しては、画像情報の特殊な構造を学習するため線形予測関数より良い結果を得ている。斉藤ら[93]は、2値のファクシミリ画像に対し、4層で近傍10画素からの予測を行っており、同じく線形予測より高い予測を得ている。

ベクトル量子化に関しては、Jackelら[94]は、連想メモリチップを階層的に接続し、神経回路モデルの並列性を利用して、コードブック内の符号語選択を高速に行っている。

## 5.2 多層パーセプトロンによるデータ圧縮

神経回路モデルの一つである多層パーセプトロンは、フィードフォワードの多層構造で、各ニューロンには、非線形の演算要素をもつ。この神経回路モデルの応用の一つに、Rumelhartら[80]によって符号化問題として指摘された特徴空間の次元削減がある。
Cottrellら[81]は、これを画像のデータ圧縮に適用した。これは、砂時計のように入力層と出力層が全く同一で、中間層のニューロン数が入出力層より少なくなっている3層パーセプトロンである。出力層に与える教師信号を入力層の画像として、逆伝搬学習則(Back Propagation)を用い[80]、データ圧縮を学習で実現することを目指した。このモデルでは、256x256画素の画像に対して、入出力層が8x8画素の一つの砂時計型神経回路モデルが全画面を学習する。

Bourlardら[82] は、隠れ層が非線形で出力層が線形の3層パーセプトロンを特異値分解から解析している。隠れ層の非線形性は不要であり、データ圧縮特性は、学習が理想的である場合、2乗平均誤差を最小にするという意味で最適なK－L展開による特性と同じになる。また、隠れ層の非線形特性をべき級数展開で線形近似し、解からのずれについて解析している。船橋[83] は、隠れ層の線形近似を用いないで、隠れ層の非線形性が不要であることを理論的に証明している。

一方、入江ら[84] と船橋[85] は、3層パーセプトロンが任意の関数を実現可能であることを理論的に証明している。このため、多層パーセプトロンを用いて非線形の変換関数を実現して画像のデータ圧縮を行うには、少なくとも符号器に3層必要となる。データ圧縮・再生系として考えると、図17に示すような5層以上の多層パーセプトロンが非線形な変換・逆変換を実現するのに有効となる。次の問題は、(1) 5層以上のパーセプトロンでどの程度の非線形写像が学習可能か、(2)実用的には、従来技術の性能を大幅に改善するような非線形の特性が画像にあるか、ということになる。

(1)については、片山ら[86] は、入出力層が同一の5層パーセプトロン(ﾆｭｰﾛﾝ数：2-2-1-2-2, 2-8-1-8-2)で2次元の折れ曲がった分布や円形の分布を学習させ3層パーセプトロンのマッピング特性と比較している。5層では、パーセプトロンの非線形性を有効にするマッピングが学習により実現出来ることを実験的に確認している。さらに、第2層と第4層に十分なユニット数があれば、第3層は1ユニットでも任意のパターン数が完全再現可能と予想している。

入江[89] は、3次元の各種分布に対して、5層パーセプトロン(ﾆｭｰﾛﾝ数：3-10-2-10-3)を用い、片山らの結果と同様の結果を実験的に得ている。図18は、入江の実験結果であり、3次元半球面の50サンプルをランダムに学習させた後、第3層での出力値を連続的に(19x19ﾎﾟｲﾝﾄ)変化させた場合の第5層での再生値を3次元的に表示したものである。このように、5層パーセプトロンは、3次元半球面を非線形のマッピングにより、2次元の内部表現として獲得している。

一方、平藤ら[87] [88] は、神経回路モデルの学習過程が非線形の多変量解析であるとの解釈から、生物や生態系の等の非線形現象から生成される変量の分析や数量化に対して、多層パーセプトロンを用いて効率的に非線形回帰を求めている。また、未知データに対する予測値は、回帰曲線によって得られる内挿によって得られるとしている。

このように、非線形の分布を持つ変量を、その分布に応じて、次元削減した特徴量で表現できれば、圧縮や認識特性が改善できる可能性があると考えられる。

## 5.3 自然画像のデータ圧縮

筆者らは、多層パーセプトロンを用いた画像データ圧縮方式の圧縮特性や汎化特性を調べるため、図6に示す構成での実験を行った[95][96]。これは、画像を複数のブロックに分割し、各ブロック毎に逆伝搬学習する多層パーセプトロンを対応させる構成であり、画像の並列学習と局所的特徴の抽出を目指している。用いた画像は、128x128x8ﾋﾞｯﾄからなる顔画像であり、8x8画素を入力する256個の多層パーセプトロンが同時並列で学習とデータ圧縮を行う。

図19に、学習画像数に対する再生画像のSN比特性を示す。画像当りの学習回数が同じで、絞り込んだ隠れ層のニューロン数が同一である場合、第2、4層のニューロン数を多くした方がSN比特性は良い傾向にある。図7は、3枚の未学習画像に対するSN比特性であり、学習画像を増加すると改善される傾向にある。図20は、学習画像および未学習画像の例と、再生画像の例である。未学習画像の再生画像のSN比としては、約15dBとなっている。

## 5.4 画像の復元手法を用いたデータ圧縮

本章では、主に多層パーセプトロンを用いた次元圧縮について述べたが、前章の緩和型神経回路モデルの復元機能を用いた方式も考えられる。

(1) 復元機能を直接的に用いる方法には、画像をライン過程成分と低域成分とに分離して符号化する、シンセティック・ハイなど[72][73]の2元モデルによる符号化アプローチである。

(2) 3、4章で述べた緩和型神経回路モデルを用いた復元は、原画像からライン過程情報抽出し、これと粗く標本化した情報から原画像復元するので、この種の画像データ圧縮方式に対応する。

(3) 画像の生成モデルを用いた符号化へのアプローチとしては、森川、原島ら[104][105][106]の提案している3次元構造情報の抽出による符号化がある。これは、画像の持つ3次元構造情報を動画像から抽出し、積極的に符号化に利用するものである。3次元構造の復元は、動き情報から行なっており、その処理手順は (1) 輪郭に対応するゼロ交差での動きベクトル推定 (2) 動きベクトルからの3次元運動パラメータ、奥行の推定、(3) 奥行情報から面の補間による3次元構造の復元と濃度値の付与による3次元構造モデルの作成、からなっている。

人間の視覚情報処理システム[101]では、3次元構造を推定する手掛りとして、両眼視差、動きベクトル、テクスチャー勾配、陰影、などを用い、これら視覚情報を並列かつ独立なモジュールで処理していると言われている。中間視覚では、これらモジュールの出力の統合が行なわれる。このような、統合過程に関してもマルコフランダム場を持ちいたモデル

化がGamble, Poggioら(102)(103)によって行なわれている。

このような、視覚問題を解く神経回路モデルを適用し、画像の構造モデルや生成モデル等の効率的な内部表現を獲得する符号化方式も今後検討されるものと考えられる。

## 4. まとめ

本文では、雑音に埋もれた画像の復元、粗い標本化からの面の復元、画像の量子化、多重解像度緩和法によるR復元、2次元の適応標本化、画像の次元圧縮といった工学的課題とそれを解く神経回路モデルについて述べた。

人間は実に巧みに膨大な画像情報を記憶、想起、再認しているように見える。今後、このような、神経回路モデルに基づくアプローチが効率的な画像処理を可能にするものと考える。

## 謝辞

日頃熱心に御討論下さり、人間の視覚情報システムについて御討論頂いた乾　敏郎氏に感謝します。また、神経回路モデルのシミュレーション・プログラムの作成に御協力頂いた大本明氏に感謝します。本研究の機会を与え、御指導下さる淀川英司社長に感謝します。

## 参考文献

[0]全般に関する文献

(1) 川人、池田、曽根原、乾、三宅：画像情報処理と神経回路モデル、人工知能学会誌、Vol. 4, No. 2, pp. 27-34, 1988

(2)川人、池田、三宅：神経回路の学習と視覚情報処理、テレビジョン学会誌、Vol. 42, pp. 918-924, 1988

(3)曽根原、川人、三宅：ニューラルネットと画像処理、計測自動制御学会、講演会予稿「ロボットやビジョンの知能化」、1989, 10

(4)曽根原、川人、三宅：画像と制御、「ニューラルネットによる画像処理」、朝倉出版、1990 7(予定)

(5)曽根原、川人、三宅:ﾆｭｰﾛｺﾝﾋﾟｭｰﾃｨﾝｸﾞ、｢ﾆｭｰﾗﾙﾈｯﾄと画像処理｣、ｻｲｴﾝｽﾌｫｰﾗﾑ社、1990 6(予定)

[1]確率緩和、緩和型神経回路ﾓﾃﾞﾙに関する文献

(10)S.Geman and D.Geman: Stochastic Relaxation, Gibbs Distributions and the Bayesian Restoration of Images, IEEE Trans., PAMI-6, pp. 721-741, 1984

(11)J. J. Hopfield: Neurons with graded response have collective computational properties like those of two-state neurons, Proc. Natl. Acad. Sci. USA, Vol. 81, pp.3088-3092, May 1984

(12)J. J. Hopfield and D. W. Tank:"Neural" computation of decisions in optimization problems, Biol. Cybern. 52, pp. 141-152 1985

(13)C.Koch, J.Marroquin and A.Yuille: Analog "Neumal" Networks in Early Vision, Proc. Natl. Acad. Sci. USA, 83, pp. 4263-4267, 1986

[2]画像のｴﾈﾙｷﾞｰﾊﾟﾗﾒｰﾀ学習

(20) 池田、川人、三宅、ら:画像復元する神経回路ﾓﾃﾞﾙのｴﾈﾙｷﾞｰ学習、ﾃﾚﾋﾞｼﾞｮﾝ学会技報、Vol.12, No. 14,pp.31-36,1988

(21)本郷、川人、乾、三宅: ｴﾈﾙｷﾞｰ学習をする局所並列確率ｱﾙｺﾞﾘｽﾞﾑを用いた輪郭線抽出、信学技法、MBE88-181, pp. 151-156、1989.3

[3]粗い標本化画像の復元

(13)C.Koch, J.Marroquin and A.Yuille: Analog "Neumal" Networks in Early Vision, Proc. Natl. Acad. Sci. USA, 83, pp. 4263-4267, 1986

(30)D.Terzopoulos:Regularization of Inverse Visual Problems Involving Discontinuities, IEEE Trans. Vol. PAMI-8, No. 4, pp. 413-424, JULY 1986

(31)岡本、川人、三宅:確率的並列処理による画像圧縮・復元方式について、ﾃﾚﾋﾞｼﾞｮﾝ学会技報、Vol.13, No. 22, pp. 25-30, 1989

(33)N.Sonehara, M. Kawato, M. Sato, K. Nakane:Binary representation and surface interpolation of a grey level image using relaxation neural networks,IJCNN 90, 1990 (submitted)

(34)C. Fouquet, N. Sonehara:A 2D Local adaptive sampling and reconstruction for image data compression, INNC 90 Paris,1990 (submitted)

[4]ﾌﾗｸﾀﾙと画像処理

(40)B. B. Mandelbrot: The Fractal Geometry of Nature, San Francisco: W. H.

Freeman and Co., 1983
(41)E. Walach, E. Karnin: A Fractal Based Approch to Image Data Compression, ICASSP 86, TOKYO, pp.529-532
(42)横矢 、山本、舟久保 :ﾌﾗｸﾀﾙによる3次元自然形状の解析とその地形ﾓﾃﾞﾙ作成への応用、信学論 D, Vol. J70-D, No. 12, pp. 2605-2614, 1987
(43)中島 、安居院、坂本:ﾃﾞｼﾞﾀﾙ線図形に対する擬似的な符号化、信学論D, Vol. J68-D, No. 4, pp. 623-630, 1985

[5]画像の2値化

(50)B. E. Bayer: An optimum method for two-level rendition of continuous-tone pictures, International conference on communications, Vol. 1, pp. 26-11-26-15, June 1973
(51)R. Floyed and L. Steinberg:An adaptive algorithm for spatial grey scale, 1975SID International symposium digest of technical papers, 4.3, pp. 36-37, Apr. 1975
(53)鉄谷、越智:2値画像と濃淡画像の混在する原稿の2値化処理法、信学論B, Vol. J67-B, No. 7, pp.781-788, 1984
(32)N.Sonehara, M. Kawato, M. Sato, K. Nakane:Binary representation and surface interpolation of a grey level image using relaxation neural networks, IJCNN 90, 1990 (submitted)

[6]多重解像度緩和

(60)D.Terzopoulos: Image Analysis Using Multigrid Relaxation Method, IEEE Trans. Vol. PAMI-8, No. 2, MARCH 1986
(61)A.Brandt: Multi-Level Adaptive Solutions to Boundary-Value Problems, Mathematics of Computation, Vol. 31, Number 138, APRIL 1977, pp. 333-390
(62)R. Battiti, G. Fox, and W. Furmanski:A Multiscale Approach with Line Discontinuities for Low lev Vision, Caltec C$^3$P, pp. 26-34, April 1989
(63)A.Rosenfeld:Multiresolution Image Processing and Analysis; Sec.17, MultilevelReconstruction of Visual Surface:Variational Principles and Finite-Element Representations(D.Terzopoulos), Springer-Verlag, 1983
(21)本郷、川人、乾、三宅: ｴﾈﾙｷﾞｰ学習をする局所並列確率ｱﾙｺﾞﾘｽﾞﾑを用いた輪郭線抽出、信学技法、MBE88-181, pp. 151-156、1989.3

[7]画像のﾃﾞｰﾀ圧縮方式全般

(70)南、他:画像符号化小特集、電子情報通信学会誌、Vol.71、No.7、1988

(71)A. K. Jain: Image Data Compression: A Review, Proc. of The IEEE, Vol. 69, No. 3, March 1981

(72)W. F. Schreiber, C. F. Knapp and N. D. Kay: Synthetic hights, an experimental TV bandwidth reduction systems, J. Soc. Motion Pict. & Telev. Eng., 68, pp. 525-537, 1959

(73)A. K. Jain and S. H. Wang : Stochastic image models and hybrid coding, Dept. Elec. Eng., SUNY, Buffalo, NOSC N00953-77-C-003MJE, 1977

(74)D. Tricker: Progressive Recursive Binary Nesting, ISO/TC97/SC2/WG8, N461, 1987

(75)原島:知的画像通信と知的符号化、ﾃﾚﾋﾞｼﾞｮﾝ学会誌、Vol. 42, No. 6, pp. 519-525, 1988

[8]神経回路ﾓﾃﾞﾙによる次元圧縮

(80)D. E. Rumelhart, J. L. MaClelland, and the PDP Research Group:Parallel Distributed Processing,Explorations in the Microstructure of Cognition,Vol. 1, Chapter 8,The generalized delta rule,The Encoding Problem,MIT Press, Cambrige, 1986

(81)G. W. Cottrell, P. Munro and D. Zipser:Image compression by back propagation: an example of external programing,ICS Rep.8702,Univ.of California, San Diego, Institute for Cognitive Science

(82)H. Bourlard and Y. Kamp: Auto-Association by Multilayer Perceptrons and Singular value decomposition, Biol. Cybern. 59, 291-294,1988

(83)船橋: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、信学技報MBE88-174、1989

(84) 入江、三宅:. Capabilities of Three layered Pereceptrons, IEEE ICNN, Vol. 1, pp.641-648, 1988

(85)船橋:ﾆｭｰﾗﾙ･ﾈｯﾄﾜｰｸのcapabilityについて、信学技報MBE88-52、1988

(86)片山、大山:自己組織逆伝搬ﾆｭｰﾗﾙ･ﾈｯﾄの諸特性、信学全大会、SD-1-4、pp.309-310、1989

(87)平藤:ﾆｭｰﾗﾙ･ｴｷｽﾊﾟｰﾄｼｽﾃﾑ「M-NCS」、Inter AI, pp. 47-53, 1989

(88)平藤、小野、小林:ﾆｭｰﾗﾙ･ﾈｯﾄによる多変量解析とｴｷｽﾊﾟｰﾄｼｽﾃﾑ実現法、日本ｿﾌﾄｳｴｱ科学会、第5回大会、pp. 113-116, 1988

(89)入江、他:ﾆｭｰﾗﾙﾈｯﾄによる内部表現の学習、(発表予定)

[9]多層ﾊﾟｰｾﾌﾟﾄﾛﾝによる画像ﾃﾞｰﾀ圧縮

(90)G. W. Cottrell, P. Munro and D. Zipser:Image compression by back propagation: an example of external programing, ICS Rep. 8702, Univ. of California, San Diego, Institute for Cognitive Science

(91)片山:ﾆｭｰﾗﾙ･ﾈｯﾄによる画像符号化、PCSJ88、3-5、pp37-38、1988

(92)成田、岩田、相沢、羽鳥:画像符号化へのﾆｭｰﾗﾙ･ﾈｯﾄの応用、信学会全大会、D-130、1989

(93)斉藤、中、吉田:ﾆｭｰﾗﾙ･ﾈｯﾄを用いた二値画像予測、信学会全大会、D-562、1989

(94)L. D. Jackel, R. E. Haward, J. S. Denker, W. Hubbard and S. A. Solla: Building a hierarchy with neural networks: an example-image vector quantization, Applied Optics, Vol. 26, page 5081-5084, December 1, 1987

(95)曽根原、川人、三宅、中根:ﾆｭｰﾗﾙ･ﾈｯﾄによる画像ﾃﾞｰﾀ圧縮(Neuro-CODEC)の検討、信学技報, IE88-62, pp. 57-64, 1988

(96)N. Sonehara, et:Image Data Compression Using Neural Network, IJCNN, 1989

[10]視覚ｼｽﾃﾑ

(101)乾:ﾊﾟﾀｰﾝ認知と学習のﾓﾃﾞﾙ、計測自動制御学会、ﾋｭｰﾏﾝｲﾝﾀｰﾌｪｲｽ部会講習会、1989. 10. 25

(102)E. B. Gamble and T. Poggio:Visual integration and Detection of Discontinuities: The Key oRole of Intensity Edges, MIT AI memo, No. 970, 1987

(103)T. Poggio, E. B. Gamble and J. J. Little:Parallel in Integration of Vision Modules, Science, 242, 436-440

(104)森川、相沢、原島 、斉藤 : 動画像における3次元構造復元の基礎検討、昭和63年信学秋全大、SD-1-3

(105)森川、原島 、斉藤:3次元構造情報の自動抽出と符号化への応用、PCSJ 1988, 5. 6

(106)森川、原島、斉藤:3次元構造情報抽出による動画像符号化方式の基礎検討、SITA 1988, 14. 4, pp. 335-340

# ニューラル・ネットによる画像処理（図面集）

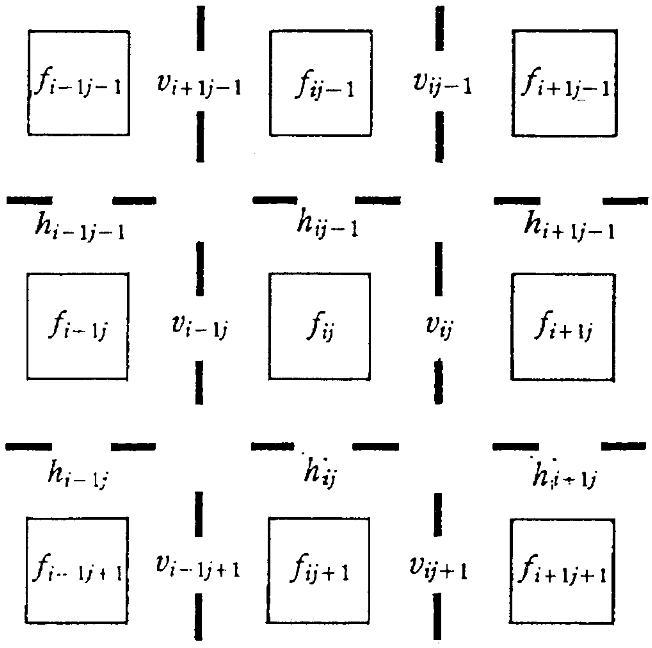


( a )

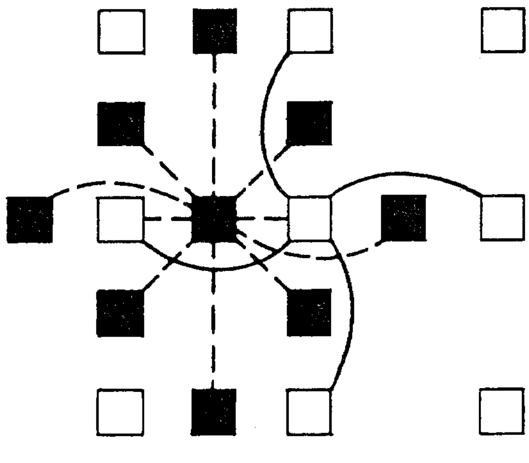

( b )

# 図1 緩和型神経回路モデルの構造[1][3]

(a) 奥行データと不連続を示すライン過程
(b) 奥行（□）とライン過程（■）を示すニューロン間の相互作用

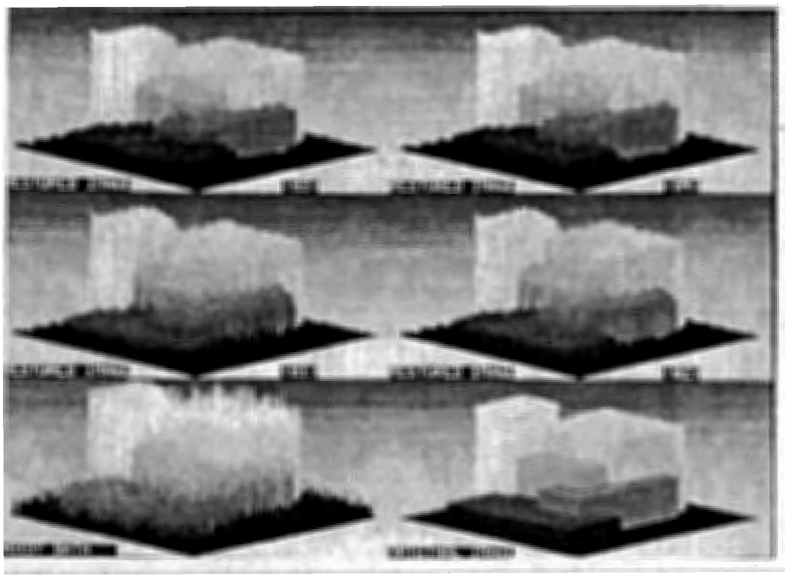

図２ 幾何画像の復元
［下段右］原画像 （濃度　レベル5）
［下段左］雑音に汚れた観測画像 （ガウス雑音）
［中段、上段］復元画像 （各繰り返し回数100）

図３（a）原画像 (SIDBA.GIRL256x256x8)

図3 （b） 雑音に汚れた自然画像
SNR＝ 10.8dB （信号平均パワー対雑音平均パワー）

図3 （c） 教師エッジ信号

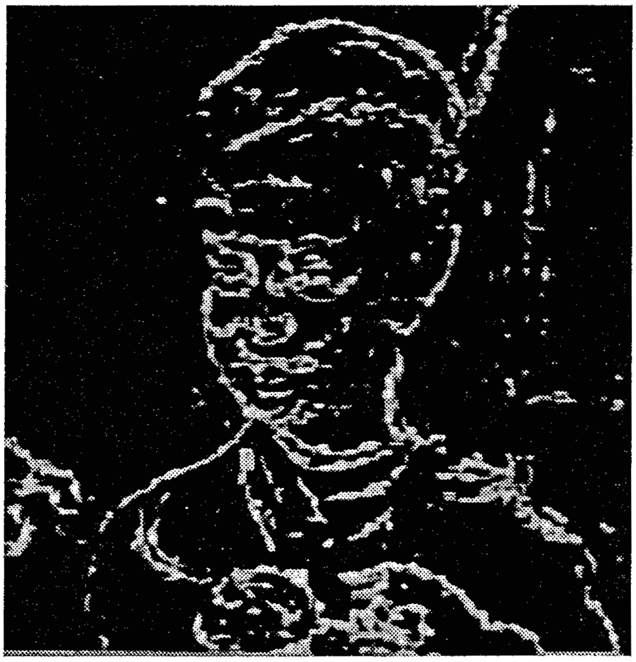

図3 (d) 復元エッジ信号

図3 (e) 雑音からの復元画像
SNR = 19.1dB

図4 （a） 標本化点画像
Yardstick = 32

図4 （b） 量子化画像 SN比= 26dB

図4 （c） 復元画像

Yardstick＝32、エントロピー0.54 ［bits／pel］、
SN比＝27.6dB

［緩和実験条件］ テンション＝0.5、繰り返し回数＝2000、画素値の更新係数＝0.005、ライン過程検

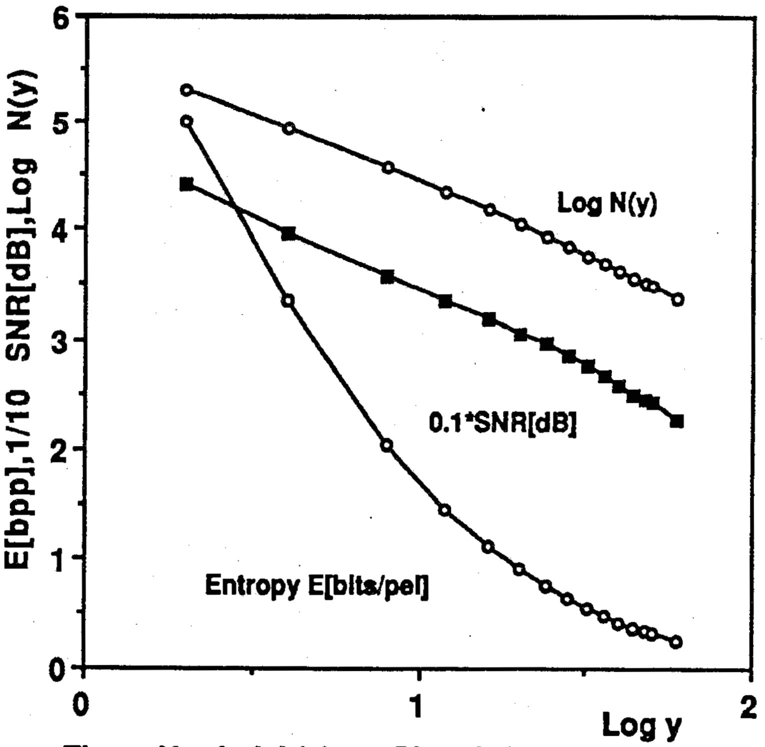


図5 ヤード長に対する復元画像品質、情報量、標本点数

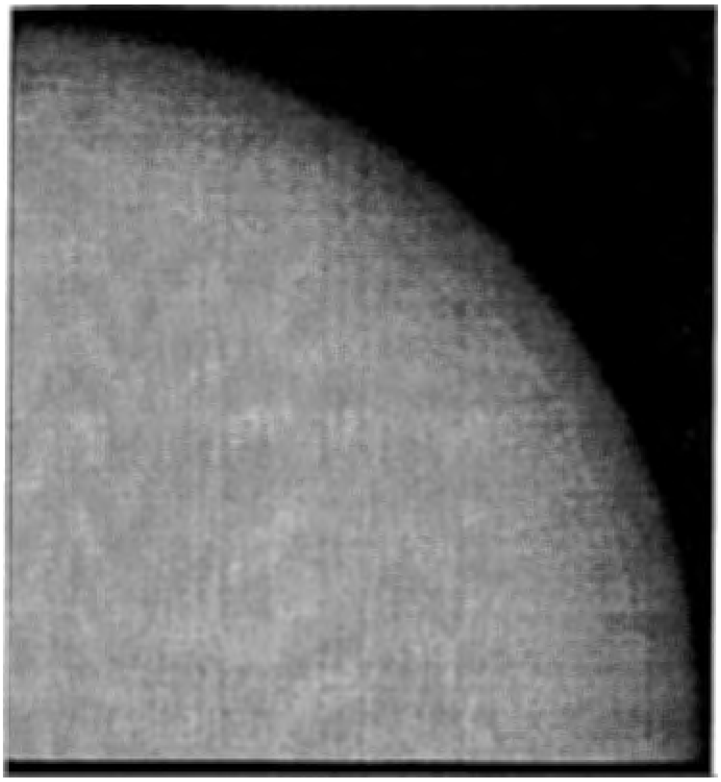

図6（a）原画（球面幾何図形）
256x256、レベル0～255、背景0

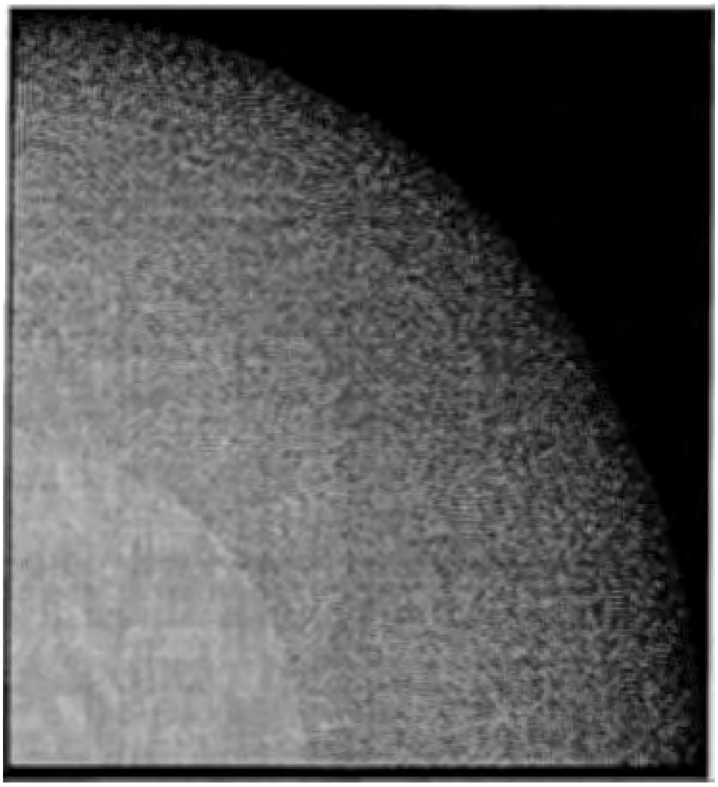

図6（b）緩和型神経回路モデルによる2値化

図7 (a) ベイヤー型の組織的ディザ法
マトリックスサイズ [4x4]

図7 (b) 緩和型神経回路モデルによる自然画像
の2値化

図８ 非線形圧縮画像

図９（a）組織的ディザ法による
文字と濃淡画像の混在する画像の
２値化

図９（b）緩和型神経回路モデル
による混合画像の２値化（CV ＝ 10）

図９（b）緩和型神経回路モデル
による混合画像の２値化
（CV ＝ 0.5）

図10（a）2値画像の濃淡復元

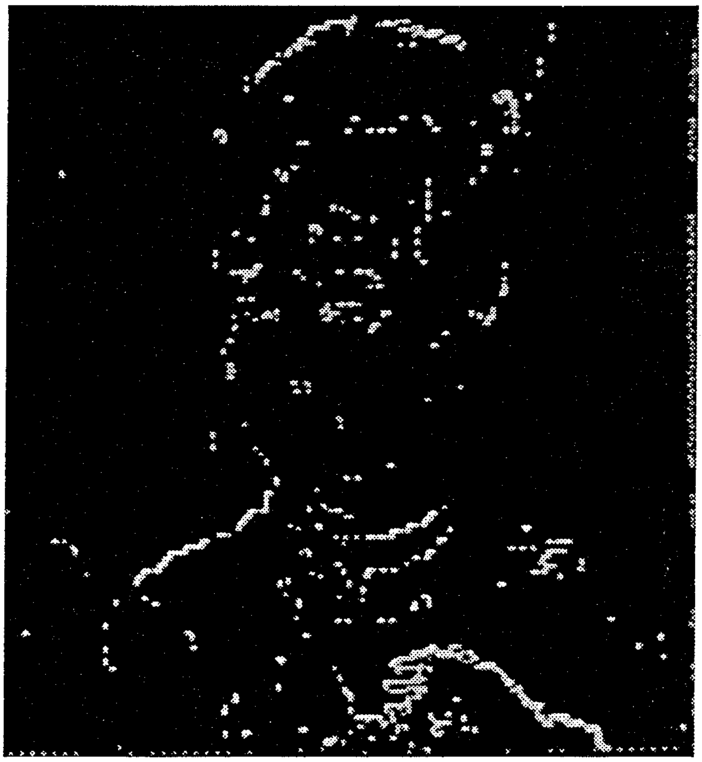

図10（b）2値画像より抽出された
濃淡画像のエッジ情報

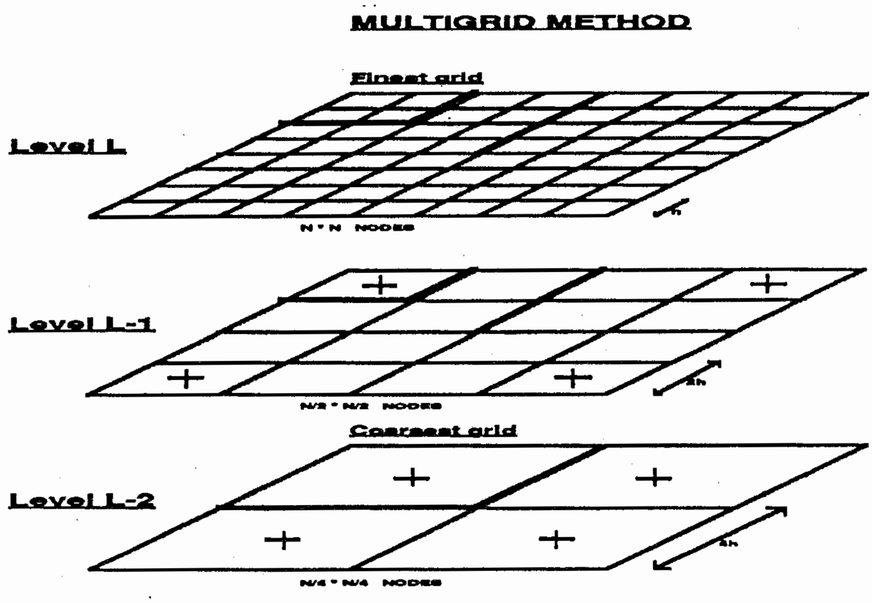


図11 画像の多重解像度表現

THE RELAXATION ALGORITHM

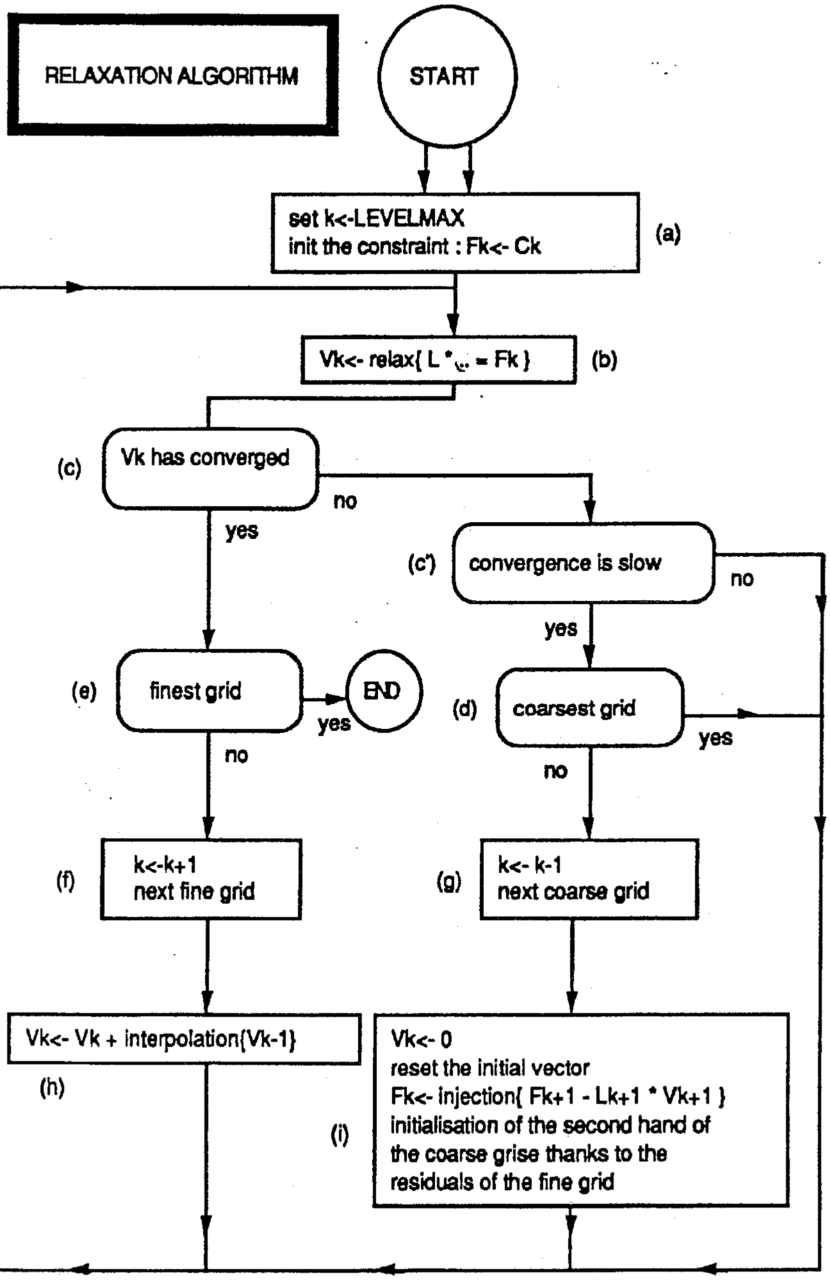


図12 多重解像度緩和アルゴリズム

（a）雑音に汚れた画像
SN 比＝17.24dB
標本化密度＝1／3

（b）多重解像度緩和法による
画像の復元
SNR = 20dB

図 13 多重解像度緩和法による雑音画像の復元

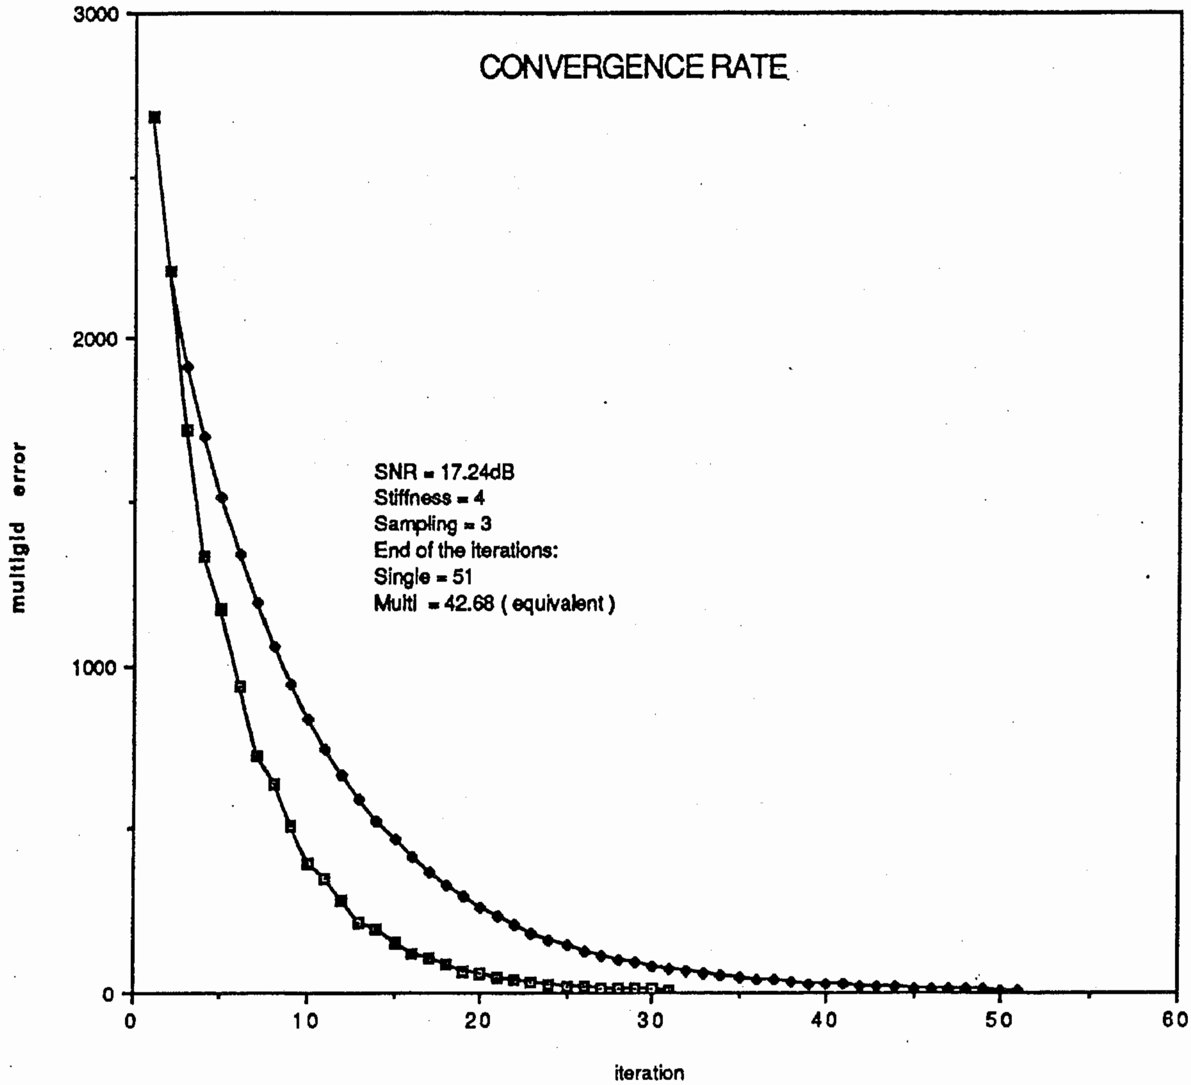


図14 雑音に埋もれた画像の復元問題に対する
多重解像度緩和法の収束特性

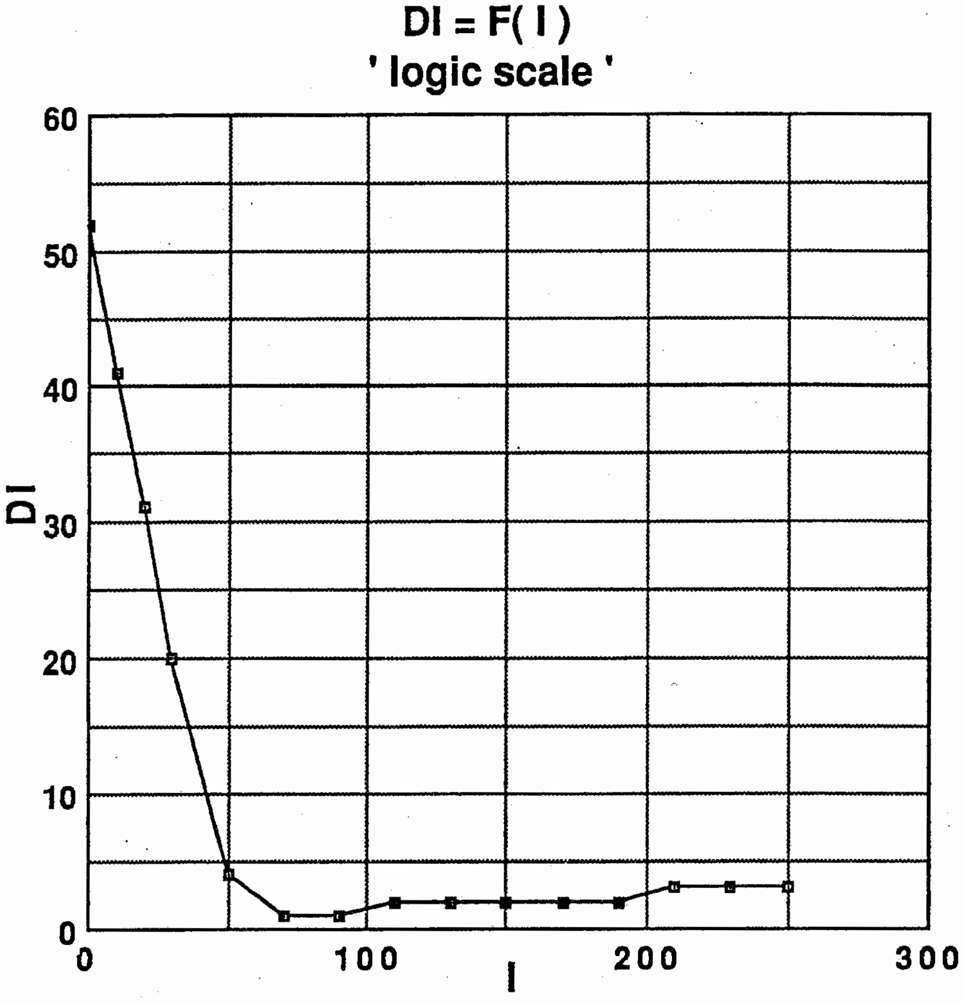


（測定条件）室内照度＝4.2LX
250 レベルの輝度＝34.5cd／㎡
30 レベルの輝度＝0.08cd／㎡
くけい領域のサイズ＝2°

図15　CRT画像の明るさに対する弁別しきい特性

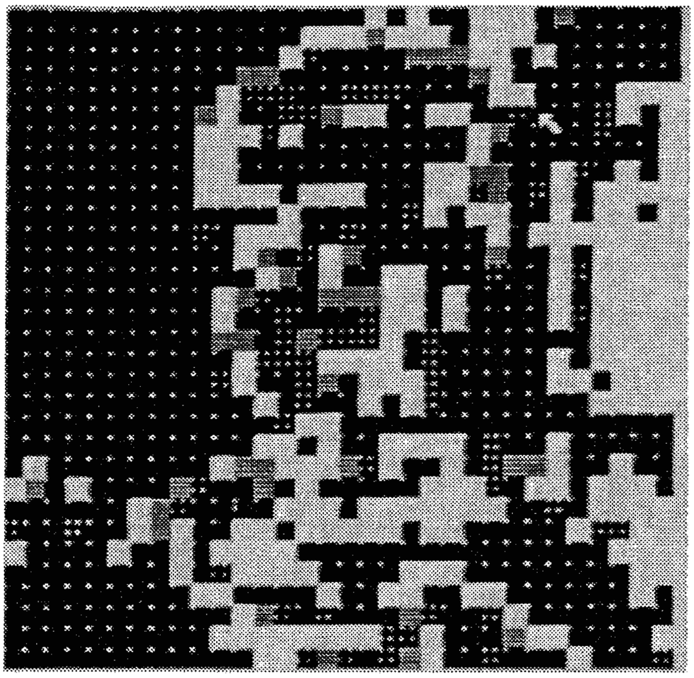

図16（a）２次元適応標本化

図16（b）シンプレート関数
による画像の復元

## 表1　神経回路モデルによる画像圧縮

| 従来の画像データ圧縮方式 | 神経回路モデルで実現すべき機能 |
|---|---|
| 変換符号化<br>・KL変換、DCT 変換<br>ー画像を他の配列に変換するエネルギー保存型<br>変換、 非因果系の符号化 | 非線形変換関数<br>ー符号器、復号器にそれぞれ3層必要、<br>入出力の2乗誤差最小化 |
| 予測符号化<br>・DPCM符号化、予測量子化<br>ー走査機構による因果系、冗長度の利用 | 非線形予測関数<br>ー予測器に3層必要、2乗予測誤差最小化 |
| ベクトル量子化<br>ー入力ベクトル$R^K$を有限の部分集合$R^K$に<br>マッピング | 非線形クラスタリング関数<br>ー入力ベクトルを代表する最良特徴写像 |
| モデル・ベースの符号化<br>ー画像の3Dモデルのパラメータ推定、<br>モデルの共有と差分の伝達 | 3Dの内部構造モデル |

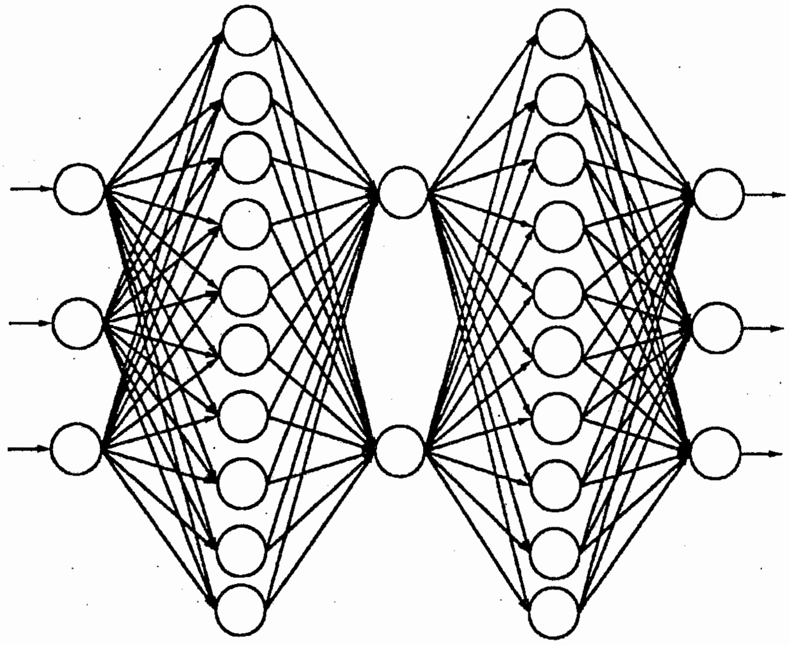

図17 次元圧縮のための5層
パーセプトロン

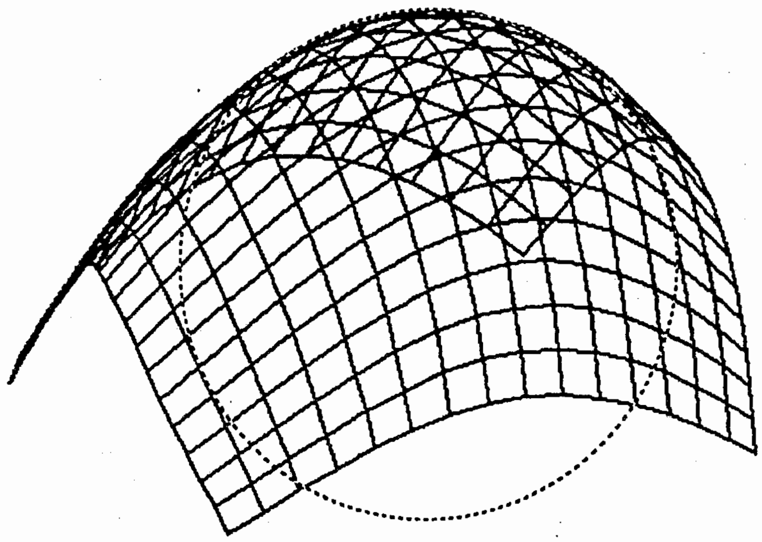

図18 中間層の2ユニットに形成
された曲線座標系

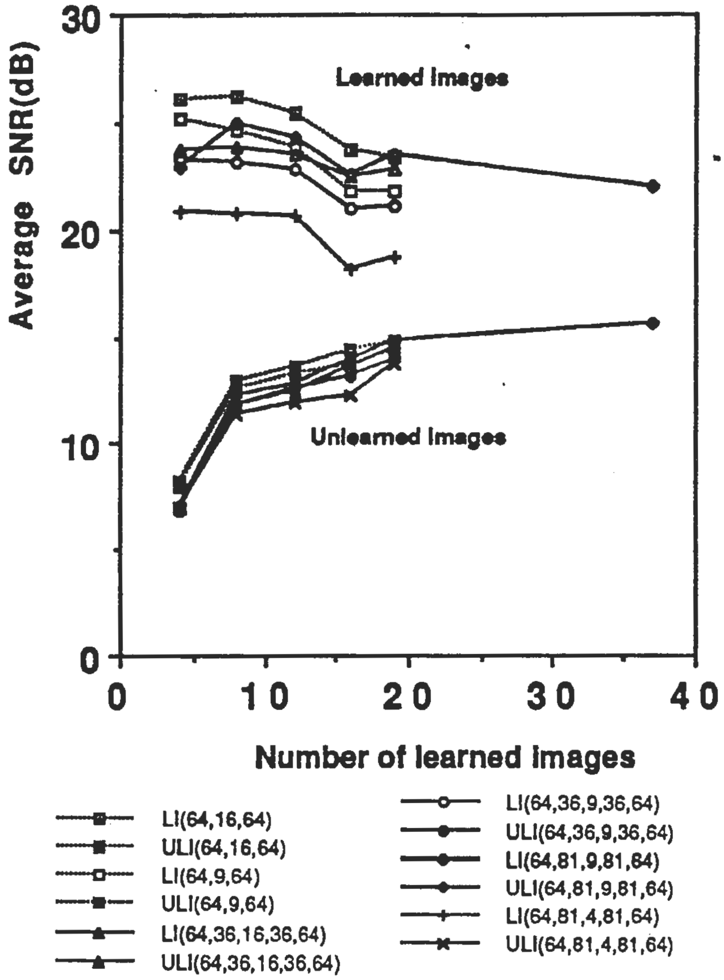


図19 多層パーセプトロンを用いた
変換符号化特性

原画像　　　　　　　　　復元画像

図９（a） 学習画像の復元画像例

原画像　　　　　　　　　復元画像

図９ （b） 未学習画像の復元画像例