5. 神経回路の学習と視覚情報処理

川 人 光 男[†], 池 田 孝 利^{††},
正会員 三 宅 誠[†]

1. ま え が き

最近, 神経回路網モデルを現実的な情報処理問題に
応用する試みが注目されている. このきっかけとなっ
たのは, Hopfield & Tank¹⁾ の巡回セールスマン問題
の研究であった. この論文で示されたように, 複雑な
非線形拘束条件の下で, ある評価関数(エネルギー)を
最小(大)化する最適化問題は, 問題のサイズが大きくな
ったとき, 神経回路モデルの並列構造に問題の巨大
なサイズをうまくマッピングできれば, 神経回路が得意
とする情報処理課題のひとつとなる. 画像処理や視
覚情報処理の分野でも, いくつかの問題が, 大規模な
最適化問題とみなせることが指摘され, 視覚情報の局
所並列性を生かした並列アルゴリズムや神経回路モデル
が提案されてきた. しかし, これらの具体的問題に
おいて, 評価関数(エネルギー)やそれに対応する神経
回路モデルの構造とシナプス結合荷重は, 天下り的に
実験者によって与えられてきた. これは脳のモデルと
しても不自然であるし, 工学的な応用においても大きな
障害となる.

Uno, Kawato, Suzuki²⁾ は, ヒトの上肢多関節運
動における軌道生成の問題が, ある評価関数を最小化
する問題であることを示した. さらに我々^{3,4)} は, この
評価関数を運動の例から学習によって獲得し, しか
も, 回路の並列演算によってこの評価関数を最小化で
きる 4 層神経回路網モデルを提案した.

本稿では, 画像復元や初期視覚の問題について, 軌
道生成の神経回路モデルと同様に, 最小化すべきエネ
ルギーを画像の例から学習によって獲得し, さらに,
回路の並列演算でそのエネルギーを最小化する, 神経

回路モデルについて述べる.

2. 初期視覚・画像復元と神経回路モデル

2.1 初期視覚

ヒトの視覚情報処理の第 1 段階は, 初期視覚と呼ば
れており, その目的は, 網膜像(2 次元画像)から実世
界(3 次元)の様子を推測することである. 初期感覚と
は, 2 次元の原画像の強度を決定している 4 つの要
因, (1)可視表面の幾何学的構造, (2)可視表面の反
射率, (3)光景に対する照明, (4)観察点を, 2 次元
画像情報をもとに分離表現することである⁵⁾. また,
Poggio ら⁶⁾ は, この過程が, 3 次元物体から 2 次元
の濃淡画像への写像である光学のちょうど逆になっ
ているので, 初期視覚を逆光学と呼び, それが, 数学的
には不良設定問題であることを示している. したがっ
て, 画像データ以外にも何らかの拘束条件がなければ,
(i)解が存在しない, (ii)解が一意に定まらない,
(iii)解がデータに対して連続とならない, のうち
いずれかが生じてしまう.

Poggio & Koch⁷⁾ は, 適当な拘束条件を与えて, 結
果として得られる最適化問題を標準正則化理論を用い
て解くとともに, 並列神経回路モデルも提案した. さ
て, 標準正則化理論では, 評価関数は 2 次形式として
与えられる. したがって, 標準正則化理論によって提
供される作用素は線形であり, 並列神経回路モデルも
線形のものに限られる. このような理論でも, 心理物
理学のいくつかの現象を再現したり, コンピュータビ
ジョンのために有効なアルゴリズムを与えることはで
きるが, 画像に不連続性を含む本質的に非線形の問題
を取扱うことはできない.

2.2 マルコフ確率場とライン過程

Geman & Geman⁸⁾ は, 1984 年に少なくとも 4 つの
点で画期的な進歩をもたらした論文を発表した. 彼ら
は, 初期視覚の問題ではなく, ノイズに汚されたデー
タから原画像を推定し復元する, 画像復元の問題を取

[†] ATR 視聴覚機構研究所

^{††} 大阪大学 基礎工学部 生物工学科

"Learning in Neural Networks for Visual Information Processing"
by Mitsuo Kawato, Takatoshi Ikeda (Department of Biophysical
Engineering, Faculty of Engineering Science, Osaka University,
Osaka) and Sei Miyake(ATR Auditory and Visual Perception
Research Laboratories, Osaka)

扱ったが、その基本的なアイデアが初期視覚の問題にも適用できることは、この論文の後を追う MIT や Brown 大学グループの数々の論文^{6)9)~11)}からも明らかであろう。彼らは第一に、画像のマルコフ確率場モデルが、Gibbs 分布のエネルギーを定義することと等価であることを示した。第二に、ライン過程と呼ばれる画像の不連続性を表現する、隠れた(仮想の)確率変数を導入した。第三に、画像復元の問題を最大事後確率を与える原画像を推定することととらえて、対応するエネルギー最小化が、局所並列演算(確率緩和)によって実行可能であることを示した。第四に、この確率緩和に温度のゆっくりとした低下(シミュレートされた焼きなまし)を導入することにより、エネルギー最小化が厳密に達成できることを示した。

2.3 神経回路モデルによる奥行き面の再構成

Koch ら⁹⁾は、Geman & Geman⁸⁾のライン過程とマルコフ確率場の概念を応用して、Hopfield 型の神経回路で、不連続性を本質的に含む初期視覚の問題を解いた。この神経回路は、両眼視によって、雑音を伴う

奥行きデータが格子状の計測点上にまばらに与えられているとき、滑らかな曲面を再構成する。物体の端に相当する部分では、奥行きデータが不連続になる。この不連続を誤って曲面化してしまわないように、ライン過程と呼ばれる隠れた確率変数を格子点の間に配置する。図 1(a)の正方形が各画素でのデータ、その間にある線がライン過程を示す。

Geman & Geman は、「焼きなまし」による確率緩和でエネルギー最小化を達成したが、Koch らは、神経回路の並列演算でエネルギーの最小値を達成した。これは計算時間の点で確率緩和よりはるかに優れている。

図 1 に示す神経回路モデルを簡単に説明しよう。格子点上での奥行きデータの推定値を f 、観測により得られた奥行きデータを d 、格子点の間に配置するライン過程で、水平に並んだ奥行きデータの不連続を示すものを v 、垂直に並んだデータの不連続を示すものを h とする。 f は実数、 h, v は、0 と 1 の間の数とし、1 のとき完全な不連続を、0 のときには完全な連続を表している。変数の定義(1)式、エネルギーの各項の定義(2)~(5)式、および変数の時間変化則(6)式を以下に示す。

(a)

(b)

図 1 初期視覚の問題を解決する神経回路モデルの構造
(a) 格子状に配列している奥行きデータと不連続を表すためのライン過程、(b) 奥行き(白四角)とライン過程(黒四角)を表すニューロン間の相互作用

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

$$E_I + E_D = \sum_{ij} (f_{i+1,j} - f_{i,j})^2 (1 - h_{ij}) + C_D \sum_{ij} (f_{ij} - d_{ij})^2 \quad (2)$$

$$E_L = C_v \sum_{ij} h_{ij} (1 - h_{ij}) + C_p \sum_{ij} h_{ij} h_{i+1,j} + C_c \sum_{ij} h_{ij} + C_L \sum_{ij} h_{ij} [(1 - h_{i+1,j} - v_{i,j} - v_{i+1,j})^2 + (1 - h_{i-1,j} - v_{i-1,j} - v_{i,j+1})^2] \quad (3)$$

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

$$g(U_i) = \frac{1}{1 + e^{-2\lambda U_i}} \quad (4)$$

$$E = E_I + E_D + E_L + E_G \quad (5)$$

$$\begin{cases} \frac{df_{ij}}{dt} = -\frac{\partial E}{\partial f_{ij}} \\ \frac{dm_{ij}}{dt} = -\frac{\partial E}{\partial h_{ij}} \end{cases} \quad (6)$$

ここで、 i, j は格子点の位置を表す。簡単のために水平なライン過程に関する式のみを示す。 m_{ij} は、 g というシグモイド関数を通して h_{ij} を決める。これはニューロンの膜電位に対応する。

エネルギーの各項の意味は次の通りである。 E_I は奥行きデータの連続性、 E_D は計測されたデータの信頼性、 E_L は不連続(ライン過程)の生じ方、 E_G は m が発散しないことをそれぞれ要求する。これらのエネ

ルギー関数の各項にある係数 C_D , C_V , C_P , C_C , C_L , C_G は、それぞれの項の重みを決定する係数である。3節で説明する NCUBE 上の実験では、Koch らの用いたパラメータとほぼ同じ値を用いた。これらの係数を決定するのは困難である。

この神経回路モデルのシミュレーションには、 N 個の格子点に対して、 $3N$ 個のニューロンの状態変化を表す複雑な非線形常微分方程式を解く必要がある。図 1 (b) に奥行きを表す格子点(白ヌキ四角)と、ライン過程を表す格子点(黒四角)がどのように相互作用するかを示してある。これからわかるように、1つのライン過程に対応する1個のニューロンは、周囲の10個のニューロンと相互作用する必要がある、格子状に配列された画像処理専用の並列計算機では結合が足りなくなることがわかる。

3. NCUBE 上での神経回路モデルによる画像復元

本節では、256 個のノードを持つハイパーキューブ構造の強並列計算機 NCUBE/10⁽¹²⁾⁽¹³⁾ に前節の神経回路モデルをインプリメントし、画像復元の問題を解く。NCUBE 上のプログラミングの詳細は、池田ら⁽¹⁴⁾を参照されたい。

まず、2次元に配列している1画素(m, h, v に対応する3個のニューロン)の処理を、おのおの1ノードに処理させるべくプログラムを行ったが(図2b)、この方法では、NCUBE の能力がうまく引き出せなかった(表1参照)。原因は、2次元格子状に配列している画素の処理を、神経回路モデルのニューロンの昇順そのままにノードに割り付けたことにある。それぞれのノードは、受け持ちの画素と隣接する8つの画素を受け持つ8つのノードと密接に情報交換する必要があるが、この通信が、ハイパーキューブ上で直接隣接しない2ノード間で頻繁に行われるため、ノードは、処理の大半の時間を他のノード間の通信の中継処理や、通信に必要なルートの空き時間待ちに費やしてしまい、計算速度が全く上がらないことがわかった。

そこで、ハイパーキューブのリンクにうまく適合す

(a) 分割なし

(b) 2次元分割

(c) 1次元分割

図2 神経回路モデルのニューロンの NCUBE のノードへの割り付けの様子

(a) すべての画素に対応するニューロンをホストで処理、(b) 近傍の画素に対応するニューロンをまとめて1つのノードで処理(2次元分割)、(c) 横1列の画素に対応するニューロンを1つのノードで処理(1次元分割)

るように神経回路モデルを移植するために、問題の並列化から再検討した。2次元に配列した画素の横方向の列をひとまとめにしてノードを割り当てた(図2c)。このように分割すれば、隣接している画素の左右2つの画素は同一のノードに含まれ、左上、真上、右上の画素は上隣のノードに、左下、真下、右下の画素は下隣のノードに含まれる。そのため、密に通信するのは上下のノードであることがわかる。つまり、ノードを1次元にリンクすれば、特定のノード間で行われる通信が他の通信の終了を待つことはない。このリンクは、いわばハイパーキューブに沿った一筆書きであり、それはまた双方向にデータが流れるパイプラインを形成している。このリンクの構造は幾何学的で、ハイパーキューブの次元が大きくなると複雑化する。

表1 NCUBE 上の神経回路モデルによる画像の復元実験のパフォーマンスの比較

分割方法	データ	実行時間	試行回数	相対速度
分割なし	32 * 32	12 秒	100	1.0
2次元	32 * 32	19 秒	100	0.63
1次元	256 * 256	91 秒	600	506

図3 NCUBE上の神経回路モデルによる雑音をと
もなう画像データからの不連続を考慮にいた
た画像の復元実験
上：ライン過程の状態変化，左：(6)式に従
う1回の更新の後，右：200回の更新後の
ライン過程の状態。下：濃淡値の状態変化，
左：ノイズに汚されたデータ，右：(6)式
に従って200回の更新の後の状態。た
だし，全画像の中心部分についてのみ結
果を示す。

今回は、プログラムでリンクを決定し、それを利用した。これらのノードの割り付けの様子は図2(c)に示した。

今回採用した1次元鎖の拡張として、その両端が互いに接続している1次環、1次鎖を平行に配置して鎖のなかの相対するノードをさらに鎖状に接続してできるメッシュ状のもの(2次鎖)、1次の場合と同様にし得られる2次環、ひいては、これらを n 次にまで拡張した形態も、ハイパーキューブ構造の内部にノードを無駄にすることなくリンクできる。特に、2次鎖構造は、現在研究している神経回路のシナプス結合荷重の学習や、ライン過程を介して異種視覚情報を統合する場合に適している。

図3に示すように、6つの濃淡値をとる幾何学的な人工画像(256 * 256)を考える。画像の最大濃淡差は150であった。わずか50ステップ程度(8秒の実行時間)で、輪郭線を含めて原画像を再現できた(図3上、下)。

計算時間については、表1に示すようにホスト単独の約500倍の計算能力が発揮された。ホストの能力が0.5 MIPSと低めに見積もっても、これは250 MIPSに相当し、ほぼNCUBEの最大能力が引き出せるように、神経回路モデルをハイパーキューブ上で処理する

ことができた。神経回路モデルと、並列計算機でのシミュレーションとの両面から、満足できる結果が得られたといえよう。

4. エネルギー最小化とエネルギー学習を 同時に行う神経回路モデル

前節の実験で、原画像に加える正規乱数の分散を増やしていくと、本来画像の輪郭のない場所にライン過程が立つ($h_{ij}, v_{ij}=1$)ようになる(図3上右のノイズのように見える過剰なライン過程に注意)。計測データの信頼性が下がれば当然(2)式の C_D を減らさねばならないし、不連続の少ない画像データに対しては(3)式の E_L を増やさねばならない。しかし、これを実験者がいちいち決めていたのでは何のための画像復元かということになってしまう。(2)~(4)式に現れるパラメータあるいはエネルギーの形は、画像のモデルあるいは物理世界の拘束条件として導入されたものなのだから、ある決められた画像のセットに対して一意に決まるはずである。エネルギーを学習によって神経回路内に獲得できないだろうか。

f がニューロンの状態、 d が画像復元の計測データを、 C がエネルギーを特徴づけるパラメータを表すベクトルとする。また $\hat{f}$ は、画像の真の状態を示すとする。(1)~(6)式で与えられる神経回路モデルは、エネルギーを $E(f, d, C)$ と表せば、ほぼ E の最急降下方法に状態変化を起こし、画像の推定値 f^* として、

$$\frac{\partial E(f^*, d, C)}{\partial f} = 0 \quad (7)$$

を満たすものを与える。いま画像の推定値と真の値の2乗誤差 $(f^* - \hat{f})^2$ を最小にするように、エネルギーを定義するパラメータ C を変化させることを考える。

$$\frac{\partial C}{\partial t} = -\epsilon \frac{\partial (f^* - \hat{f})^2}{\partial C} \quad (8)$$

まず、陰関数の定理を用いて(7)式から $\partial f^* / \partial C$ を計算する。 f^* で E が極小であることと、 E の主要項が E_D, E_G であるという仮定から、 $(\partial^2 E(f^*, d, C) / \partial f^2)^{-1}$ を正定数で置き換える。さらに、神経回路の状態 f が、パラメータ C の学習時間のスケールではほとんど安定平衡状態 f^* の近くににいるという準静近似の仮定をすれば、結局パラメータ C の変化則として次式が得られる。

$$\frac{\partial C}{\partial t} = \epsilon \frac{\partial^2 E}{\partial f \partial C} (f - \hat{f}) \quad (9)$$

各ニューロンの状態遷移が、次の方程式に従うことに

留意すれば、

$$\frac{df}{dt} = -a(f) \frac{\partial E}{\partial f}, \quad 0 < a(f) \ll \infty \quad (10)$$

結局、

$$\frac{dC}{dt} = -\varepsilon \frac{\partial}{\partial C} \left(\frac{df}{dt} \right) (f - \hat{f}) \quad (11)$$

が得られる。さらに(6)式を計算すればわかるが、一般的に、(11)式の df/dt は次のようにパラメータ c をシナプス荷重とした、シナプス後電位の線形和となることがわかる。

$$\frac{df_{ij}}{dt} = \sum_k C_{ij}^k g_k(f_{lm}, h_{lm}, d_{ij}) \quad (12)$$

$$\frac{dm_{ij}}{dt} = \sum_k C_{ij}^k r_k(f_{lm}, h_{lm}, m_{ij}) \quad (13)$$

ここで、 g_k , r_k は非線形関数、添字 lm はエネルギー(あるいは神経回路の相互作用)が局所的であることから、格子点 ij の近傍の値のみをとる。したがって最終的に、エネルギーを定めるパラメータ、つまり、シナプス結合荷重の学習則は次式のように与えられる。

$$\frac{dC_{ij}^k}{dt} = \varepsilon g_k(f_{lm}, h_{lm}, d_{ij})(\hat{f}_{ij} - f_{ij}) \quad (14)$$

$$\frac{dC_{ij}^k}{dt} = \varepsilon r_k(f_{lm}, h_{lm}, m_{ij})(\hat{h}_{ij} - h_{ij}) \quad (15)$$

(12), (13)式のニューロンの状態の時間変化に比べて、(14), (15)式で与えられるシナプス結合荷重の変化が充分遅くなければいけないことを、もう一度注意しておく。

さて、(12)~(15)式をもう一度検討すると、これはよく知られた異シナプス可塑性学習則となっている。つまり図4に示すように、1個のニューロンは、通常のシナプス入力 $g_1, \dots, g_N$ をシナプス荷重 $C_1, \dots, C_N$ で重み付けて、その状態を(12), (13)式に従って変化させている。

図4 エネルギー学習のためのニューロンの異シナプス可塑性(ニューロンの状態が時間と共に連続的に変化する点が普通の学習則と異なる)

このニューロンは、誤差信号 $\hat{f} - f$ を第2の種類のシナプス入力として受け取っており、2種類のシナプス入力と同時に活動したときのみ、第1種のシナプス荷重だけが変化する。(14), (15)式では、画像の各点で、エネルギーを定義するパラメータ値が異っていてもよいようになっている。画像が等方的であれば、(14), (15)式を ij について平均すればよい。結局、エネルギーの最小化を行いながら((12), (13)), そのエネルギーをより画像のモデルとして適当なように学習変更する((14), (15))ことが、ひとつの神経回路で達成できるのである。

我々は、この学習則を、 8×8 の格子点上に与えられた簡単な幾何学図形(5×5 の正方形: 図5(a)である2次元画像(最大濃淡差200)のエネルギーを特徴づけるパラメータの学習に応用した。まず、標準偏差12のホワイトな正規乱数を各格子点に加える(図5(a)左)。神経回路の濃淡データ f の初期値として

図5 簡単な2次元画像に対するエネルギー学習の実験 (a)濃淡データの初期値(左、生データ)とライン過程の初期値(右)、(b)学習前の神経回路モデルによる画像復元の結果、(c)エネルギーのパラメータを学習した後の神経回路モデルによる画像復元の結果。

図 6(a) エネルギーの学習中における、神経回路モデルが推定したライン過程自乗誤差、濃淡値の自乗誤差、エネルギーを特徴付ける 6 つのパラメータの学習回数に伴う時間変化

は、ノイズに汚されたデータをそのまま用いる。一方、ライン過程の初期値は、すべて 0.5 とする (図 5 (a) 右)。エネルギーの形としては、(2) 式から (5) 式のように選び、エネルギーを特徴付けるパラメータは、NCUBE 上のシュミレーションと同じとした。図 5 (b) に示すように、エネルギーの学習前には、原画像で不連続のない場所にまでライン過程が立ってしまい、エネルギーのパラメータの値が不適当であることがわかる。これに対して、約 80 個の同じ統計的性

図 6(b) 画像に加えるノイズの標準偏差によるパラメータ C_D の収束先の違い

質をもつ画像のパターンを用いて学習を行った後では、図 5 (c) に示すように、本来不連続のある場所にもライン過程が立ち、濃淡データも滑らかに再構成されていることがわかる。

図 6(a) に、標準偏差 10 のノイズを加えたときの、30 個のパターンを用いた学習中のライン過程の誤差、濃淡値の誤差、エネルギーを特徴づける 6 個のパラメータの変化を示す。図 6(b) は、ノイズの標準偏差が小さいとき ($\sigma=8$) と大きいとき ($\sigma=10$) とを比較すると、真の画像に加えるノイズの標準偏差が大きいとき、 C_D は小さな値に収束することを示していて、エネルギー学習がうまく進んでいることがわかる。

ここで提案した学習則は、エネルギーを特徴づけるパラメータの変化則として導出したが、図 4 を見れば、これはエネルギー

の形そのものの学習に拡張できることがわかる。つまり図 7 に示すように、入力層と出力層の 2 層からなる神経回路モデルが、エネルギーの形そのものを学習し、さらに、回路のダイナミクスにしたがって、獲得したエネルギーを最小化するモデルとして考えられる。

5. む す び

本稿では、初期視覚・画像復元問題で近来大きな進

図7 エネルギーの形そのものを学習する2層神経回路モデル

2層とも、2次元画像の格子点に対応して、ニューロンは、どの画像に対応するかが決まっている。入力層から出力層への結合も、出力層から入力層への結合も、画像モデル(エネルギー)の局所性から、その範囲は、相互作用近傍に限られている。この神経回路モデルは、その状態をフィードバック結合によって連続的に変化させながら、シナプスの結合加重を学習によって変えていく。

歩の見られた局所並列アルゴリズム、ライン過程を含むマルコフ確率場、神経回路モデルによるエネルギー最小化について紹介した。神経回路モデルを強並列計算機 NCUBE 上にインプリメントし、画像の不連続性を含めた画像復元に成功した。また、エネルギーの学習と最小化を同時に行える神経回路モデルを提案し、簡単な例について、パラメータ学習がうまく行えることを確認した。

初期視覚に現れる線形のアルゴリズム(フィルタ)、つまり、2次形式のエネルギーを表現する行列を、画像データから推定する試みが、MIT¹⁰⁾とブラウン大学¹¹⁾で行われている。本稿で述べた神経回路は、非線形のアルゴリズム、一般的なエネルギーを学習できるという点で、これらの研究より進んでいることを最後に強調しておく。

(昭和63年5月2日受付)

(参考文献)

- 1) J. J. Hopfield and D. W. Tank: "Neural' Computation of Decisions in Optimization Problems", Biol. Cybern., **52**, pp.141-152(1985)
- 2) Y. Uno, M. Kawato and R. Suzuki: "Formation and Control of Optimal Trajectory in Human Multi-joint Arm Movement—Minimum Torque-Change Model", Biol. Cybern., submitted(1988)
- 3) M. Kawato, Y. Uno, M. Isobe and R. Suzuki: "A Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics", IEEE Control Systems Magazine, **8**, 2, pp. 8-16(1988)
- 4) 前田, 川人, 宇野, 鈴木: "ヒト上肢多関節運動軌道を学習、生成する多層神経回路モデル", 信学技報, MBE-87-133, pp. 233-240 (1988)
- 5) D. Marr: "Vision", Freeman (1982), 乾, 安藤訳「ビジョン—視覚の計算理論と脳内表現—」, 産業図書(1987)
- 6) T. Poggio, V. Torre and C. Koch: "Computational Vision and Regularization Theory", Nature, **317**, pp. 314-319 (1985)
- 7) T. Poggio and C. Koch: "Ill-posed Problems in Early Vision: from Computational Theory to Analogue Networks", Proc. R. Soc. London, Ser. B **266**, pp.303-323(1985)
- 8) S. Geman and D. Geman: "Stochastic Relaxation, Gibbs Distributions and the Bayesian Restoration of Images", IEEE Trans., PAMI-6, pp. 721-741 (1984)
- 9) C. Koch, J. Marroquin and A. Yuille: "Analog "Neumal" Networks in Early Vision", Proc. Natl. Acad. Sci. USA, **83**, pp. 4263-4267 (1986)
- 10) A. Hurlbert and T. Poggio: "Synthesizing a Color Algorithm from Examples", Science, **239**, pp. 482-485 (1988)
- 11) D. Kersten, A. O'Toole, E. Sereno, D. Knill, J. Anderson: "Associative Learning of Scene Parameters from Images", Applied Optics, **26**, pp. 4999-5006 (1987)
- 12) 三宅: "ニューラルコンピューテーション", 信学誌, **70**, pp. 1255-1262 (1987)
- 13) NCUBE: NCUBE HANDBOOK v1.1(1986)
- 14) 池田, 三宅, 川人, 乾, 淀川, 鈴木: "初期視覚の計算理論と神経回路による解法", 第2回生体・生理工学シンポジウム論文集, pp. 137-140 (1987)

かわと みつお
川人 光男 昭和51年、東京大学理学部物理学卒業、56年、大阪大学基礎工学部生物工学科博士課程修了。同年、大阪大学助手、62年、同講師を経て、63年、ATR視聴覚機構研究所に移る。脳機構の理論的研究に従事。

いけだ たかし
池田 孝利 昭和55年、福岡県立門司高等学校卒業。現在、大阪大学生物工学科4年在学中。神経回路モデルによる画像情報処理、パラメータの学習および強並列計算機上での高速処理の研究に従事。

みやけ せい
三宅 誠 昭和45年、早稲田大学理工学部電気通信学科卒業。同年、NHKに入局。49年、同放送科学基礎研究所、59年、同放送技術研究所。62年より、ATR視聴覚機構研究所に勤務。現在、同所視覚研究室主幹研究員。神経回路モデルによるパターン情報処理機構、学習機構の研究に従事。工学博士。正会員。