

バウンドラインプロセス

光本浩士† 田村進一‡ 岡田広幸* 増山 博*

†大阪大学基礎工学部 ‡大阪大学医学部 *宮崎大学工学部

あらまし 視覚情報処理の研究が盛んになってきている。その中で、変分原理に基づく初期視覚問題の解法が提案され、さらに不連続処理（ラインプロセス）を導入した手法が提案されている。しかし、このラインプロセスには問題点がある。それは、なめらかさの評価が近傍画素において完全に不連続になっていない事である。従来のラインプロセスでは、ラインプロセスが立った境界においては、なめらかさの評価が無効になるように働くのみであった。それゆえ、境界ではデータ値になり、かつ、その両側では不連続部分を越えてなめらかさを計算する。完全には、不連続になっていないのである。この対策として、いくつか考えられる。本稿では、連続な領域内だけでなめらかさを計算することをバウンド機能と呼ぶ。そして、このバウンド機能をなめらかさ折り返しによって実現した。さらに、エネルギー関数の係数設定を学習により得ることも試みた。

Bound Line Process Model

Hiroshi Mitsumoto†, Shinichi Tamura‡
Hiroyuki Okada*, and Hiroshi Masuyama*

†Faculty of Engineering and Science, Osaka Univ.

‡Osaka Univ. Medical School

*Faculty of Engineering, Miyazaki Univ.

†, ‡2-2 Yamadaoka, Suita, Osaka, 565

*1-1 Gakuen-kihanadai, Miyazaki, 889-21

Abstract Line process model in surface reconstruction corresponds to discontinuities of a three dimensional scene. The conventional line process model does not completely discontinuity. That is, smoothness cost is calculated over the discontinuity, and state value is equal to just the data at the discontinuity point. In this paper, a new model for line processes is proposed. The proposed model which is called the bound line process model, calculates the smoothness cost separately only on each side of the discontinuity.

Further, a learning algorithm is proposed for setting up coefficients of energy terms, which utilizes discontinuity information given by a teacher. This new model can be applied to image reconstruction and also to early vision problems.

1. はじめに

近年の視覚情報処理の分野において、2次元の画像情報から3次元を推定する問題は ill-posed 問題であるとして、それを変分原理によって解を推定する手法が提案されている。すなわち、問題に有効な拘束条件を付加し、問題を解く手法である。拘束条件としては、なめらかさなどを使用している。これは、我々の世界がよくこの条件を満足しており、一般的であると考えられる為である。実際、なめらかさの条件は都合が良い場合が多く、この拘束条件を使用し問題を解く手法が多数提案されている [1]。しかし、この拘束に頼りすぎると得られる解がなめらかすぎて意味をなさない。問題は画像中に不連続が存在している場合である。不連続は、例えば、画像中において物体と背景の境界で発生する。物体の写っている部分に対してはなめらかさの拘束は当てはまるが背景と物体の境界では、濃淡値や、深さ、色などに関して不連続が発生する。この問題に対して、ラインプロセスという手法が使われている [2]。このモデルは不連続をラインという変数で表し、変化が大きいところではそのラインを1にし、なめらかさを評価しないようにエネルギー式を変化させている。乾らは、このラインプロセスをいれた過程が人の MACH 現象をよく説明できる事をシミュレーション実験によって示している [3]。また、Kochらは、この計算が抵抗回路によって並列的に計算できるため実際に VLSI による試作を行っている [2][4]。このように、ラインプロセスを用いた計算はニューラルネットワークの研究の1分野を形成している問題の一つである。我々もラインプロセスを利用した衛星画像の領域分割の研究を行っているが、そこでラインプロセスの一つの問題点が明らかになった。それは、なめらかさの評価が完全に不連続になっていない事である。従来のラインプロセスでは、ラインプロセスが立った境界においては、なめらかさの拘束が無効になるように働くのみであった。それゆえ、境界では処理結果はデータ値になり、かつ、その両側では不連続部分を越えてなめらかさを計算する。完全には、不連続になっていないのである。この対策として、いくつか考えられる。Terzopoulos は、[5] の中で不連続近傍におけるなめらかさの評価をその局所的な形状にあったオペレータによって評価している。変分計算中において不連続情報は静的な情報として扱っている。横矢ら [6] は、変分計算の途中に不連続の評価を行う手順を報告している。それによって、区分的なめらかさの評価を行っている点では、着眼点は同じであるが、本稿では、区分的なめらかさをエネルギー関数の中に埋め込むよりシンプルな定式化によって試みている点で異なる。本稿では、連続な領域内だけでなめらかさを計算することをバウンド機能と呼び、バウンド機能をなめらかさの評価内に入れるラインプロセス手法を提案する。このバウンド機能はなめらかさ折り返しによって実現した。それによって、不連続の決定となめらかさの評価を同時に行うことができる。さらに、従来、問題点の1つであったエネルギー関数の係数決定に対し、学習によって決定する手法を試みた。これは、不連続情報を教師として

用いた教師付き学習である。本稿では、2章において、従来のラインプロセスモデルの問題点を述べ、3章でその問題点を解消するバウンド機能を述べる。4章では、1次元データに対する実験結果によってその有効性を検証する。5章で考察を述べ、最後に、5章でむすびを述べる。

2. ラインプロセス

ノイズを含んだ画像からその元の画像を復元する画像再構成問題、ステレオ画像からの3次元復元問題などの、ill-posed 問題においては、変分原理に基づく解決法が提案されている。それは、拘束条件としてなめらかさを使い、ill-posed 問題を well-posed 問題にし、解を求める。例えば、画像再構成問題に適用した場合の式を式 (1) に示す。

$$E = \sum (\text{なめらかさ})^2 + \lambda \sum (\text{データ適合度})^2 \quad (1)$$

この場合、なめらかさを評価するモデルには、膜と板タイプがある。データにはノイズが含まれておりそのままでは原データは推定できない。そこで、データはなめらかさであるという拘束条件を入れることで、データから原データを推定できるのである。しかし、このままでは、画像内に濃淡の急激な変化などの不連続部分があった場合にもその部分をなめらかに補完してしまうという問題点がある。そこで、不連続を表現するラインプロセスを導入した手法が提案された。ラインプロセスモデルは、その実現方法によっていくつか存在しているが本稿においては [3] で用いられたモデルを従来モデルとし、式 (2) に示す。式 (3) はその状態遷移式である。

$$E = \frac{A}{2} \sum_i (1 - l_i) (\nabla^2 S_i)^2 + \frac{B}{2} \sum_i (S_i - d_i)^2 + \frac{C}{2} \sum_i l_i (1 - l_i) + C_1 \sum_i l_i \quad (2)$$

$$\frac{dS_i}{dt} = -\frac{\partial E}{\partial S} = -B(S_i - d_i) - A(1 - l_i)(\nabla^4 S_i) \quad (3)$$

$$\nabla^4 S_i = 6S_i - 4S_{i-1} - 4S_{i+1} + S_{i-2} + S_{i+2} \quad (4)$$

S_i は i 点における状態ニューロンであり、これは画像の画素に対応し、濃淡レベルは 0-1 の範囲に正規化してある。 l_i を、 S_i と S_{i+1} の間の不連続を表すラインニューロンとする。 A, B, C, C_1 は各エネルギーの係数であり、その値は事前に設定されている。エネルギー式の右辺第1項はなめらかさの評価を行っている。なめらかさの評価には膜モデルと薄板モデルがある。膜モデルとは、膜の面積を最小にするようになめらかに補完し、薄板モデルは、曲率が最も最小になるようになめらかな面を生成するように働くモデルである。本稿では、従来のラインプロセスモデルの

問題点を顕在化するために、薄板モデルを用いた。ラプラスアン の自乗によってなめらかさを評価している。その前に、 $(1 - l_i)$ が掛けられている。 $l_i = 1$ のとき、なめらかさを評価しないように働く。

右辺第 2 項は、データとの適合度に関するエネルギーである。データとの差が小さいほどエネルギーは小さい。右辺第 3 項は、ラインニューロンが 0 か 1 の値になったとき、0 になる。右辺第 4 項は、不連続を設定する際のペナルティーとして働く。このペナルティーの値を近傍のラインニューロンとの形状などの評価によって値を変化させる手法もある [7] [8]。そのようにすると、孤立点ノイズに対して頑強にでき、かつ、ラインニューロンの連結性も保持される。画像の安定した復元 [9] やラインプロセスによる画像の輪郭線抽出の報告もある [10]。本稿では、問題点を絞るためにラインニューロンの状態値に係数を掛けたものを用いた。次に、実験結果を用いてその問題点を考察する。

2.1. 問題点

式 (2) のモデルの実験結果を図 1 に示す。ここで、 \circ は与えられるデータ点を表している。値の低いレベルは 0.2、高いレベルは 0.8 にし、それぞれに ± 0.1 のランダム雑音を加えている。データ及びニューロン数 22 で、10 番目と 11 番目の間で不連続になるデータで実験を行った。実線は、ニューロンの状態値を直線で結んだものである。線の途切れは不連続が発生している事を表している。状態ニューロン、ラインニューロンともに、初期値は 0 から状態遷移を行った。この図において、以下の 3 つの問題点があげられる。

1. 不連続点において、状態ニューロンの状態値はデータと一致している。
2. 値の低い部分と高い部分へ 1 画素分使ってつながっている。
3. 不連続の発生する点が最適でない。

これらは、ラインプロセスモデルに起因している。1. の理由は、式 (2) において不連続が発生した点 (l_i が 1) においてなめらかさを評価しないためである。ニューロンの状態遷移は局所的計算によって行われるため、第 i 点においての状態遷移に関してはなめらかさの評価に関する項がなくなり、データとの適合度に関する項のみになる。したがって、ラインニューロンが 1 になった点の状態ニューロンの値は、データ値となるのである。

次に、2. についてであるが、この現象は薄板モデルを用いているため特に顕著になっている。それは、座標 i 点の近傍 $i \pm 1$ の点においてなめらかさを評価する場合、 i 点における不連続の情報は使用していない。すなわち、 $i \pm 1$ の点においては i 点の不連続を越えてなめらかさの評価をおこなっているのである。したがって、2. のような現象が現れるのである。




図 1: 従来のラインプロセスの実験結果

最後に、3. については、ラインニューロンの状態遷移式に関係しているということがいえる。ラインニューロンの状態遷移式は、状態ニューロンのラプラスアン の値の大きいところで成長するように働く。エネルギー関数が 2 次形でなくなり、非線形となっているため、ローカルミニマを多く持つ形となっていると予想できる。また、エネルギー関数の係数にも大きく影響される傾向がある。

3. バウンドラインプロセス

3.1. 折り返しによるバウンド機能の実現

本節では、本稿で提案するバウンドラインプロセスモデルについて説明する。基本的な考え方は、なめらかさをその連続領域内だけで評価する事である。さらに、不連続決定処理を同一の過程の中で評価する特徴を持つ。本稿では図 2 に示すように、ラインプロセスが立った時、折り返しによってバウンド機能を実現する。不連続を表すラインニューロンが、状態ニューロンの間に配置してある。 S_i の近傍で不連続がない場合、 l_i より右では図 2 内の細線で指示されているニューロンを用いてなめらかさの評価を行う。 l_i が立った場合、すなわち、 S_i と S_{i+1} の間に不連続が発生した場合、 S_{i+1} と接続されている線が不連続の壁に対して折り返され、 S_i を用いて計算を行う。したがって、 S_i のなめらかさの評価は l_i より左側のニューロンだけを使って評価されるのである。これが、バウンド機能を入れたラインプロセスの基本的アイデアである。なめらかさを S_i のラプラスアンで評価する薄板モデルの場合の評価式を式 (5) に示す。この式の中に折り返しによるバウンド機能を入れた場合、式 (6) になる。これをバウンドラプラスアンと名付けることにする。

$$\nabla^2 S_i = S_{i-1} + S_{i+1} - 2S_i \quad (5)$$

$$\diamond^2 S_i = \{(1 - l_{i-1})S_{i-1} + l_{i-1}S_i\} + \{(1 - l_i)S_{i+1} + l_iS_i\} - 2S_i \quad (6)$$

式 (6) の右辺第 1, 2 項はそれぞれラインニューロンがスイッチの働きをしている。右辺第 1 項においては、なめらかさの評価は S_{i-1} を用いて行われているが、ラインニュー




図2: 折り返しによるバウンド機能

ロン l_{i-1} が1になった場合（不連続が発生した場合）、完全に S_i に切り替わる。したがって、 l_{i-1} においてのみ不連続発生した場合、 S_i におけるなめらかさの評価は、実質的に式(7)で評価される。

$$\diamond^2 S_i = S_{i+1} - S_i \quad (7)$$

従来のラインプロセスで、ラインニューロンが1になったところではなめらかさの評価を行わないのと比較すると改善されていることがわかる。不連続がないところではまったくラプラスアンと等価である。

3.2. エネルギー関数

式(8)に本稿で提案するエネルギー関数を示す。 $\diamond^2 S_i$ は、式(6)に示してある。 A, B, C, C_1 は、各項の重み係数である。 d_i は、 i 番目の画像データ値を表している。

$$E = \frac{A}{2} \sum_i (\diamond^2 S_i)^2 + \frac{B}{2} \sum_i (S_i - d_i)^2 + \frac{C}{2} \sum_i l_i (1 - l_i) + C_1 \sum_i l_i \quad (8)$$

また、状態遷移は式(9),(10)によって行う。 x_i, u_i は、 i 番目のニューロン、ラインプロセスの内部状態である。

$$\frac{dx_i}{dt} = -\frac{\partial E}{\partial S_i} \quad (9)$$

$$\frac{du_i}{dt} = -\frac{\partial E}{\partial l_i} \quad (10)$$

次に、具体的に $\frac{\partial E}{\partial S_i}$ の導出を行う。

$$E_1 = \sum_i (\diamond^2 S_i)^2 \quad (11)$$

とする。

$$E_1 = \sum_i [(1 - l_{i-1})S_{i-1} + l_{i-1}S_i + (1 - l_i)S_{i+1} + l_i S_i - 2S_i]^2 = \sum_i [(l_{i-1} + l_i - 2)S_i + (1 - l_{i-1})S_{i-1} + (1 - l_i)S_{i+1}]^2 \quad (12)$$

E_1 中において、 S_i の現れる箇所は、 $i, i-1, i+1$ のみであるので、計算の方針は、 $i, i-1, i+1$ について独立に式を整理した後、和をとる。

i) i について計算する。

$$\frac{\partial E_1}{\partial S_i} = 2[(l_{i-1} + l_i - 2)S_i + (1 - l_{i-1})S_{i-1} + (1 - l_i)S_{i+1}][l_{i-1} + l_i - 2] \quad (13)$$

ii) $i-1$ について計算する。

$$\frac{\partial E_1}{\partial S_{i-1}} = 2[(l_{i-1} + l_i - 2)S_i + (1 - l_{i-1})S_{i-1} + (1 - l_i)S_{i+1}][1 - l_{i-1}] \quad (14)$$

これを+1だけシフトする。

$$\frac{\partial E_1}{\partial S_i} = 2[(l_i + l_{i+1} - 2)S_{i+1} + (1 - l_i)S_i + (1 - l_{i+1})S_{i+2}][1 - l_i] \quad (15)$$

iii) $i+1$ について計算する。

$$\frac{\partial E_1}{\partial S_{i+1}} = 2[(l_{i-1} + l_i - 2)S_i + (1 - l_{i-1})S_{i-1} + (1 - l_i)S_{i+1}][1 - l_i] \quad (16)$$

これを-1だけシフトする。

$$\frac{\partial E_1}{\partial S_i} = 2[(l_{i-2} + l_{i-1} - 2)S_{i-1} + (1 - l_{i-2})S_{i-2} + (1 - l_{i-1})S_i][1 - l_{i-1}] \quad (17)$$

(13)+(15)+(17)を計算すると、式(18)が得られる。

$$\begin{aligned} \frac{\partial E_1}{\partial S_i} = & 2\{[(l_{i-1} + l_i - 2)^2 + (1 - l_i)^2 + (1 - l_{i-1})^2]S_i \\ & - [(1 - l_i) + (1 - l_{i-2}) + 2(1 - l_{i-1})] \\ & (1 - l_{i-1})S_{i-1} \\ & - [(1 - l_{i-1}) + (1 - l_{i+1}) + 2(1 - l_i)] \\ & (1 - l_{i-1})S_{i+1} \\ & + (1 - l_{i+1})(1 - l_i)S_{i+2} \\ & + (1 - l_{i-1})(1 - l_{i-2})S_{i-2} \} \quad (18) \end{aligned}$$

次に、同様の手順によって $\frac{\partial E_1}{\partial l_i}$ を計算すると、式(19)が得られる。

$$\begin{aligned} \frac{\partial E_1}{\partial l_i} = & 2(S_{i+1} - S_i)[2(S_{i+1} - S_i)l_i \\ & - (S_i - S_{i-1})l_{i-1} + (S_{i+1} - S_{i+2})l_{i+1} \\ & - (S_{i-1} + S_{i+1} - 2S_i) \\ & + (S_i + S_{i+2} - 2S_{i+1})] \quad (19) \end{aligned}$$

したがって、状態遷移は以下の式に従う。

$$\frac{dx}{dt} = -\left\{ \frac{A}{2} \frac{\partial E_1}{\partial S_i} + B(S_i - d_i) \right\} \quad (20)$$

$$\frac{du}{dt} = -\left\{ \frac{A}{2} \frac{\partial E_1}{\partial l_i} + C\left(\frac{1}{2} - l_i\right) + C_1 \right\} \quad (21)$$

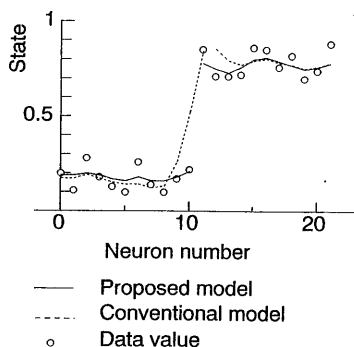


図 3: 提案モデルと従来モデルに対する実験結果

ここで、状態遷移式の中に 2 次項が入っている。ニューラルネットでは計算しようと考えた場合、この制約は重大な問題であるように思える。しかし、近年、バックプロパゲーションネットワーク (BPN) は任意連続写像関数を実現する能力を有するという報告がなされている [11][12]。また、正の部分のみ考えるならばシグモイド関数で近似できる。このように、2 次項の問題は HOP 型ネットワークと BPN を組み合わせた複合型ネットワークを用いる手法によって解決できる。本稿では、状態遷移計算をニューラルネットにまでは展開せず、状態遷移式の時間積分によって行った。

3.3. エネルギー関数の係数決定

実験を行う前に、エネルギー関数の各項の係数を決定しなければならない。この係数決定に関しては、通常実験的に設計者が決定している。我々は、不連続情報を教師とした教師付き学習によって係数の値を得た後、実際の実験にはその係数を目安にして決定した係数を使用した。教師付き学習式は付録に記載する。基本的に最急降下法に基づいている。しかし、この計算で得られる解は、解空間における境界地点に位置している解である。より適した解は、解空間の中心に位置しているはずである。したがって、実験に使用するエネルギー係数は計算で得られたものを参考とし、実験的に決定した。

4. 実験

ニューロン数 22, 1 次元データによって実験を行なった。データには、範囲 ± 0.1 の一様ランダム雑音を加えた。図 3 は、本稿で提案したモデルと従来モデルに対する実験結果を示している。丸はデータ値を表している。このデータは、図 1 と同じものである。エネルギーの各項の係数は、 $\{A, B, C, C_1\} = \{0.01, 0.01, 0.01, 0.0001\}$ である。

そこで、実験結果を比較した場合、提案モデルにおいては、不連続が発生した位置が真の不連続位置に一致していることがわかる。一方、従来法ではそれが一画素ずれて検出されている。次に、実際の状態値を比較する (表 1, 2)。

表 1: バウンダリプロセスの状態値

No.	データ値	状態ニューロン	ラインニューロン
9	0.17	0.18	0.0
10	0.22	0.21	1.0
11	0.85	0.78	0.0
12	0.71	0.75	0.0
13	0.80	0.80	

表 2: 従来のラインプロセスの状態値

No.	データ値	状態ニューロン	ラインニューロン
9	0.17	0.27	0.0
10	0.22	0.53	0.0
11	0.85	0.85	1.0
12	0.71	0.86	0.0
13	0.80	0.80	

表中、ラインニューロンの状態値が 1 になっているところは、その箇所で“不連続が発生している”。提案モデルではニューロン番号の 10 と 11 の間で不連続が発生しており、従来モデルではそれが 11 と 12 の間に発生している。従来モデルの結果である表 2 において、状態ニューロン値のみ見た場合には、10 と 11 の間に段差が見られない。すなわち、不連続が発生した位置において状態ニューロンの状態値に不連続があるとは考えにくい。

次に、のこぎり波に対して実験を行った。図 4 は、提案手法と従来手法の結果を重ねて表示している。エネルギー関数の係数は同じにしてある。図 3 の場合と同じく、不連続の発生する位置が異なっている。

実際の実験上、従来手法は係数の決定が難しく、真の位置に不連続を発生させるには至らなかった。しかしながら、不連続情報を画像のエッジなどから外部的に与えることで真の位置に不連続を発生させる事も考えられる。そこで、従来手法に対して不連続部分を強制的に設定した実験を行った (図 5)。しかし、それにも拘らず、状態ニュー

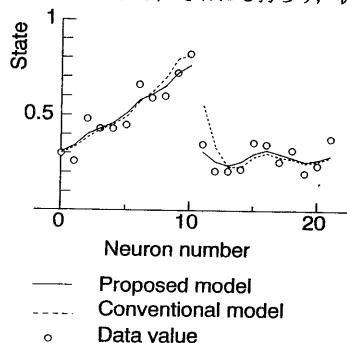


図 4: のこぎり波に対する実験結果

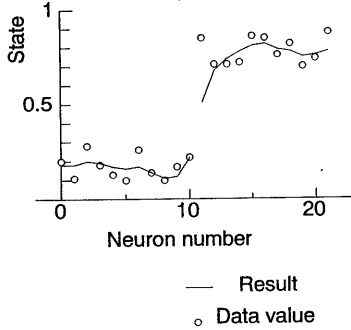


図5: 従来モデルに対し, 真の位置に不連続を強制的に設定した結果

ロンの状態値に不連続を表す段差が提案モデルに比べ顕著には見られない。画像から得られるエッジ情報には, 対象のテクスチャーなどから得られるエッジと物体の稜線としてのエッジが混在している。すなわち, ステレオ画像からの3次元復元を考えた場合には, このように, 不連続情報を画像エッジのみから得ると誤った結果を得る可能性が高い。さらに, 復元された3次元空間に対して, 従来のラインプロセスモデルを用いて処理を行ったとしても, 真の場所で不連続が発生しにくく, かつ, 得られる値が完全に不連続にならない。

次に, オプティカルフロー [13] と画像再構成を統合したモデルについて実験を行った。もし, 初期視覚を統合し, 初期視覚処理が互いに情報を補い合うことが出来ればよりロバストな画像認識が期待できる。全過程は3つの異なる過程に分けられる(式(22))。

E_s は, 画像の濃度値に基づく画像再構成の過程であり, E_l は, ラインニューロンのみに関する過程である。 E_o は, オプティカルフローの過程である。3つの式は, 独立しているように見えるが, なめらかさの評価内にラインニューロンの項が入っており, 組み合わせられている。

A, B, C, C_1, D, F は, 重み係数である。 $d_{i,j}$ は, (i, j) 番目の画像データ値を表している。

$$E = E_s + E_o + E_l \quad (22)$$

$$E_s = \frac{A}{2} \sum_{i,j} (\diamond^2 S_{i,j})^2 + \frac{B}{2} \sum_{i,j} (S_{i,j} - d_{i,j})^2 \quad (23)$$

$$E_l = \frac{C}{2} \sum_{i,j} \{I_{i,j}^h(1 - I_{i,j}^l) + I_{i,j}^l(1 - I_{i,j}^h)\}$$




図6: オプティカルフローと画像再構成モデルを統合した実験結果, 左:従来手法, 右:提案手法

$$+ C_1 \sum_{i,j} \{I_{i,j}^h + I_{i,j}^l\} \quad (24)$$

$$E_o = \frac{D}{2} \sum_{i,j} (I_x u_{i,j} + I_y v_{i,j} + I_t)^2 + \frac{F}{2} \sum_{i,j} (\diamond u_{i,j}^2 + \diamond v_{i,j}^2) \quad (25)$$

実験は, 画像サイズ 22×22 , これを1層とすると式(22)の過程全体を5層で実現している。画像には2つの四角形が, 一方は $(1,1)$, もう一方は $(1,0)$ へ移動したものをを用いた。 I は画像に対し 5×5 のサイズでぼかしをいれたぼかし画像である。これは, Hornによる手法が勾配法であり, 画像そのままを処理すると四角形と背景との境界の内外の両方で速度量が発生するためである。実験結果を図6に示す。画像再構成で得られた不連続情報が働き, 従来法に比べると移動部分がより鮮明に表れている。しかし, ラインニューロン層を見た場合, 移動方向が違う2つの四角形間の不連続は検出できていなかった。オプティカルフロー層内の不連続検出が働いていないためである。ニューロンの状態遷移は非同期で行なった。図形輪郭と一致している。

なお, 実験は, CPU に i486(25MHz) を使用している(株)松下製ワークステーション BE-B3800 上で行った。

5. 考察

本章においては, なぜ従来手法では不連続の発生する位置がずれる理由について考察する。エネルギー関数の係数学習において, ラインニューロンが0か1に分かれる条件式に対する重み係数(C)は, 比較的小さい値をとる場合が多かった。これは, C が大きいとノイズに対して過敏になり, 結果を誤る可能性が高くなるためだと考えられる。 C が小さい場合, 状態ニューロンはまずなめらかさの状態をとる。大きなフィッティングを行うと言える。状態ニューロンのみを状態遷移し, その時の $\frac{dI_i}{dt}$ をグラフ化したものを図7に示す。この図が示すように, 従来手法では, 真の不連続位置からずれた点で $\frac{dI_i}{dt}$ の量が大きくなっている。しか




図7: $\frac{dI_i}{dt}$ の表示

し、提案手法においては、真の位置で最大となっている。すなわち、係数 C が小さい時は、状態ニューロンが十分なめらかになるのが早く、真の不連続の位置での2次微分が微小となっている。そのため、従来手法では、不連続は真の位置で発生しにくく、発生したとしても微分がそれより大きい左右にずれた位置で発生すると考えられる。

6. むすび

不連続部分で、仮想的にニューロンを折り返した形で、なめらかさの拘束を適用するラインプロセスモデルを提案し、シミュレーション実験においてその有効性を示した。また、エネルギー関数の係数を学習によって得る方法を提案した。

完全な不連続を得る方法として、電気スイッチによって強制的に接続を切る方法も考えられる。実際、この方法によってラインプロセスモデルは抵抗回路網として実現されている。これを、生理学的に見た場合、接続を切るとはニューロン間のウェイトを急速に小さくすることに対応している。しかしながら、ラインプロセスが応用される初期視覚処理中にニューロン間のウェイトが短時間に大きく変化するとは考えにくい。提案モデルは、いわば不連続をラインニューロンからの抑制によって実現しており、ウェイトは変化しない。同様に、従来モデルも抑制を用いて実現できるが、それでは完全に不連続を実現できない。さらに、数学的には、特に薄板モデルを用いた場合、強制的に接続を切ることによる端効果についても無視できなくなると思われる。

残された問題点としては以下のようなものがある。エネルギー関数の係数を学習によって求める際、教師データがない場合にはこの手法は適用できない。また、データと推定値との差の項の係数に対しては学習がなされない。これら2点については今後の課題である。遺伝的アルゴリズム [14] を用いた手法によって係数を決定することも考えられる。

本手法を2次元に適用する場合、不連続の連続性が保持されないという問題点が起こると予想される。対策としては、連続性に関するエネルギー項の追加、ラインプロセス自体局所的なレベルでの議論であるため、より大きな特徴を抽出するため、多重解像度画像のラインプロセスが考え

られる [8]。

また、ニューロンの状態遷移式に忘却項を入れる事で、エネルギー関数の係数学習をエネルギー最小化過程と同時にこなう事を考えている。これが実現できれば、係数学習をシステム稼働中に持つため、環境変化に順応する適応的な動的システムが実現できる可能性がある。

謝辞

実験に関して援助していただいた松下電産(株)中島昌也氏(現松下技研(株))に深く感謝する。

参考文献

- [1] Poggio, T., Torre, V. and Koch, C., "Computational vision and regularization theory", *Nature*, 317, 6035, pp.314-319(1985.9).
- [2] Hutchubsin, J., Koch, C., Luo and J., Mead, C., "Computing motion using analog and binary resistive networks", *IEEE COMPUTER*, vol.21, no.3, pp.52-63(1988.3).
- [3] 乾敏郎, 川人光男, 本郷節之, "視覚再構成過程の計算理論とネットワークモデル", 信学技報, NC90-21, pp.61-68(1990).
- [4] Hutchubsin, J. and Koch, C., "Simple analog and hybrid networks for surface interpolatin", *Conference on neural networks for computing*, American Institute of Physics, pp.235-241(1986)
- [5] Pentland, A. P., "From pixels to predicates", pp.111-142, ABLEX PUBLISHING CORP. NORWOOD, NEW JERSEY(1986).
- [6] 横矢直和, 村木茂, "多重スケールでの正則化によるステレオ画像からの曲面再構成", 情報処理学会研究会資料, CV.70-3, pp.15-22, (1991.1).
- [7] Geman, D., "Stochastic model for boundary detection", *Image and vision computing*, 5, 2, pp.61-65(1987).
- [8] 本郷節之, 川戸光男, 乾敏郎, 三宅誠, "エネルギー学習機能をもつ局所並列確率アルゴリズムによる輪郭線抽出", 信学論, D-II, Vol.J74-D-II, No.3, pp.348-356(1991.3).
- [9] 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年電子情報通信春期全国大会, D-54, p.6-54(1991.3).

- [10] Geman , S. and Geman , D. ,“Stochastic relaxation ,Gibbs distributions , and the basian restoration of images”, IEEE Trans. PAMI , *PAMI-6*, pp.721-741(1984).
- [11] Irie , B. and Miyake , S. ,“Capabilities of three-layered perceptrons ”, IEEE , International conf. on Neural Networks , pp.641-648 (1988).
- [12] 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,MBE88-52 , pp.127-134(1988).
- [13] Horn , B. K. P. and Schunck, B. G. ,“Determining optical flow”, *Artificial Intelligence* , Vol.17 , pp.185-203(1981).
- [14] 宮沢丈夫 , “遺伝的アルゴリズムと最適化問題” , ASCII ,Vol.15 , #6 , pp.301-308(1991).

付 録

A エネルギー関数の係数学習

エネルギー関数の係数設定を教師付き学習によって行う。ここでは、ラインニューロンに関しての教師付き学習についてのみ考察する。ラインニューロンのみに限定した理由は、教師としてのパターンを実験者側で設定することが容易であるからである。望ましい状態を l_i とする。ラインニューロンを l_i とし、ラインニューロンの内部状態を u_i とする。 l_i には、1対1で l_{ii} が存在する。その時、誤差エネルギーを

$$E_t = \frac{1}{2} \sum_i (l_i - l_{ii})^2 \quad (\text{A.1})$$

とする。この誤差エネルギーを最小(極小)にするように係数を修正する。求める係数を P とする。修正式は、以下の通りである。

$$\frac{dP}{dt} \propto -\frac{\partial E_t}{\partial P} \quad (\text{A.2})$$

$$\begin{aligned} \frac{\partial E_t}{\partial P} &= \sum_i \left(\frac{\partial E_t}{\partial l_i} \cdot \frac{\partial l_i}{\partial u_i} \cdot \frac{\partial u_i}{\partial P} \right) \\ &= \sum_i \{ (l_i - l_{ii}) f'(u_i) \frac{\partial u_i}{\partial P} \} \end{aligned} \quad (\text{A.3})$$

ここで、BPN法の表記に従い、

$$\delta_i = (l_i - l_{ii}) f'(u_i)$$

とする。したがって、式(A.3)は、係数 η を使って以下のよう表される。

$$\frac{dP}{dt} = -\eta \sum_i (\delta_i \frac{\partial u_i}{\partial P}) \quad (\text{A.4})$$

また、 u_i は、

$$u_i = \sum_t \left(\frac{du_i}{dt} \right)$$

であるから、式(A.4)は、

$$\frac{\partial P}{\partial t} = -\eta \sum_i (\delta_i \frac{\partial}{\partial P} \sum_t \frac{du_i}{dt})$$

である。

実際のエネルギー式において係数は、 A, B, C, C_1 を使用しており、その修正式は、以下のようになる。

$$\frac{dA}{dt} = -\eta \sum_i (\delta_i \frac{\partial}{\partial A} \sum_t \frac{du_i}{dt}) \quad (\text{A.5})$$

ここで、

$$\frac{du_i}{dt} = -A \frac{\partial E_1}{\partial l_i}$$

なので、式(A.5)に代入すると、

$$\begin{aligned} \frac{dA}{dt} &= \eta \sum_i (\delta_i \sum_t \frac{\partial E_1}{\partial l_i}) \\ &= \eta \sum_i (\delta_i \sum_t \{ \\ &\quad [(l_{i-1} + l_i - 2)^2 + (1 - l_i)^2 + (1 - l_{i-1})^2] S_i \\ &\quad - [(1 - l_i) + (1 - l_{i-2}) + 2(1 - l_{i-1})] (1 - l_{i-1}) S_{i-1} \\ &\quad - [(1 - l_{i-1}) + (1 - l_{i+1}) + 2(1 - l_i)] (1 - l_{i-1}) S_{i+1} \\ &\quad + (1 - l_{i+1})(1 - l_i) S_{i+2} + (1 - l_{i-1})(1 - l_{i-2}) S_{i-2} \} \end{aligned}$$

同様に、 C, C_1 については以下のようになる。

$$\frac{dC}{dt} = \eta \sum_i \{ \delta_i \sum_t (\frac{1}{2} - l_i) \} \quad (\text{A.7})$$

$$\frac{dC_1}{dt} = \eta \sum_i (\delta_i \sum_t) \quad (\text{A.8})$$