

スネークスへのニューラルネットワークの 適用と学習用データ作成の手法

飯田 健太郎* 今井 正和† 烏野 武 ‡

ミノルタ (株)* 奈良先端科学技術大学院大学 情報科学研究科††

*大阪市中央区安土町二丁目3番13号大阪国際ビル

††奈良県生駒市高山町 8916-5

E-mail:imai@is.aist-nara.ac.jp†, uno@is.aist-nara.ac.jp‡

あらまし

画像中の輪郭抽出を行なう Snakes で望ましい収束結果を得るためには、Snakes 自身の内部エネルギーと画像から得られる外部エネルギーの最適な重み付けをする必要がある。これまでに Snakes を時空間に拡張した Active Tubes において Greedy Algorithm の移動先の決定に重み付けを学習したニューラルネットワークを用いる手法が提案されたが、収束動作の学習が十分ではなく、収束結果は満足できるものではなかった。

本研究では Greedy Algorithm にニューラルネットワークを適用した Snakes の収束能力の向上を目的とし、予め与えられた教師輪郭からより効果的な学習用データを作成する手法を提案する。

The Application of the Neural Network for Snakes and Generation of Learning Data

Kentarou Iida * Masakazu Imai † Takesi Uno ‡

Minolta corp.*

Graduate School of Information Science, Nara Institute of Science and Technology††

*Osaka International Building

3-13 nichome, Adzuchi, Chuo, Osaka 541, Japan

††8916-5, Takayama, Ikoma, Nara 630-01, Japan

E-mail:imai@is.aist-nara.ac.jp†, uno@is.aist-nara.ac.jp‡

Abstract

We have to set optimum coefficients of energy terms in Snakes to obtain desired contours in convergence of Snakes. There is a method to apply neural network that had learned the coefficients for the decision where the nodes of Active Tubes move to in Greedy Algorithm. Active Tubes is accumulation of Snakes along with time axis. As, the learning data were not enough, the convergence results of Snakes by the method is not satisfactory.

In this paper, we will propose an extended method to make learning data, for improvement in convergence performance of the Snakes that were applied neural networks. This method will give us more effective learning data from the given teacher contours.

1 はじめに

コンピュータビジョンにおいて、画像中の物体の正確な輪郭の抽出は、画像合成、医用画像解析、ロボットビジョン、画像入力を用いたヒューマンインターフェイスなど、多くの分野での応用が期待される。

Kassら [1] はエネルギー最小化原理に基づく動的輪郭モデル (Active-Contour model) である Snakes を提案した。Snakes とはスプライン曲線であり、その形状はエネルギー関数によって決まる。Snakes は自身の折れ曲がりにくさや局所的な伸び縮みを制御する内部エネルギーと画像中の濃度勾配の線 (エッジ) や端点等の特徴点への移動を制御する外部エネルギーを持ち、これらのエネルギー総和の最小化を行なうことにより目的の物体の輪郭上へ移動し収束する。

Snakes の収束アルゴリズムのひとつである Greedy Algorithm[3] は Snakes のノードの近傍に探索領域を設けこの領域内のエネルギー関数の総和が最小となる位置への移動を反復するアルゴリズムであり、計算量が少なく高速である。しかし、画像中のノイズに影響されやすく、この問題の解決のために古川ら [4] は Snakes を時空間に拡張した Active Tubes[5] において、局所的な極小値に捉えられてもシミュレートドアニーリングの導入により脱出が可能な Randomized Greedy Algorithm を提案した。

収束アルゴリズムと共に、Snakes の物体の輪郭への収束性能の向上のために新しいエネルギー項を付加した Snakes が提案されている [6][7][8][9]。エネルギー総和の最小状態への移動によって収束する Snakes にとって、これらのエネルギー関数の重み付けの設定がより重要な問題になってきている。しかし、これらエネルギー関数の適正な重みの設定には、従来、重みのパラメータの値を経験的に試行錯誤に決めていることが多かった。

エネルギー関数の重み付けが重要になってきた中で、加藤ら [10] は Active-Tubes において Greedy Algorithm にニューラルネットワークを適用し重み係数を学習により設定する手法を提案した。Greedy Algorithm において探索領域内の移動先はエネルギー関数の重み付けによって変化する。加藤らの研究は望ましい収束結果での収束

をニューラルネットワークに学習させ、この移動先の決定を行なわせるというものであった。この研究では対象となる物体の輪郭への収束がみられ、この手法による輪郭抽出の可能性が示された。しかし、収束過程に現われる無数の状態のうち教師とする収束結果の近傍でのごく一部の状態での収束動作しか学習していなかったため、得られた収束結果は満足のいくものではなかった。

本報告ではニューラルネットワークを適用した Snakes においてより収束能力を向上させる学習法を提案し、実際に物体の輪郭への収束を試みている。

2 Snakes へのニューラルネットワークの適用

2.1 Snakes

動的輪郭モデルのひとつである Snakes は、エネルギー関数を持ったスプライン曲線として定義される。Snakes は $v(s) = (x(s), y(s))$ なる位置ベクトルの集合で表される。Snakes の持つエネルギーは以下の式 (1) で表される。

$$E_{Snake} = \int_0^1 E_{int}(v(s)) + E_{ext}(v(s)) ds \quad (1)$$

E_{Snake} を最小にする曲線を求めることによって、画像中の物体の輪郭が得られる。適当な初期位置を与えると、Snakes は画像中に与えられた初期値から物体の輪郭上へ収束していく。

Snakes の滑らかさを表す内部エネルギー E_{int} は式 (2) で表される。 $\alpha(s)$, $\beta(s)$ は重みを表す分布定数である。

$$\begin{aligned} E_{int} &= \alpha(s) |v_s(s)|^2 + \beta(s) |v_{ss}(s)|^2 \quad (2) \\ v_s(s) &= \frac{dv(s)}{ds}, v_{ss}(s) = \frac{d^2v(s)}{ds^2} \end{aligned}$$

Snakes を画像中の濃度勾配の線や端点に引き寄せる外部エネルギー E_{ext} の基本形は以下の式 (3) となる。

$$E_{ext} = -w_{ext} |\nabla I(x, y)|^2 \quad (3)$$

外部エネルギーは画像上のポテンシャルエネルギーであり、エネルギーを最小化することによってSnakesはエッジに引き寄せられていく。

2.2 Greedy Algorithm

Snakesの収束状態であるエネルギー最小状態の解を求める方法として、変分法の利用[1]、動的計画法[2]など、幾つかの方法が提案されている。Williamsらは動的輪郭の高速アルゴリズムとして、Greedy Algorithm[3]を用いて収束を行なった。

Greedy Algorithmは反復法的一种である。Snakesの各ノードについて近傍探索領域を設け、その中のエネルギー関数が最小になる位置を探索し、ノードをその位置に順次移動していく。これをSnakesが収束して動かなくなるまで繰り返し実行する。図1にその様子を示す。




図 1: Greedy Algorithm

2.3 ニューラルネットワークによる収束

従来、Snakesの重み係数は、試行錯誤の結果、経験的に設定されていた。また、通常 $\alpha(s)$, $\beta(s)$ は正の定数 α , β としてSnakesの曲線全周で均一なものとして扱われることが多い。

そこで、加藤らは重みの働きを分布型として得るために、Active-Tubesにおいてこの重み付けの決定を行なうニューラルネットワークをGreedy Algorithmに適用した[10]。Active-TubesはSnakesを時空間に拡張したもので、この手法の適用をSnakesで論ずることは可能である。

Greedy Algorithmへのニューラルネットワークの適用の様子を図2に示す。近傍探索領域の各

エネルギーのパターンを入力層に入力し、出力層には移動先のパターンを出力させる。このとき、移動先の座標には1を、その他の座標には0を出力させるように学習させる。また、中間層の規模は任意である。

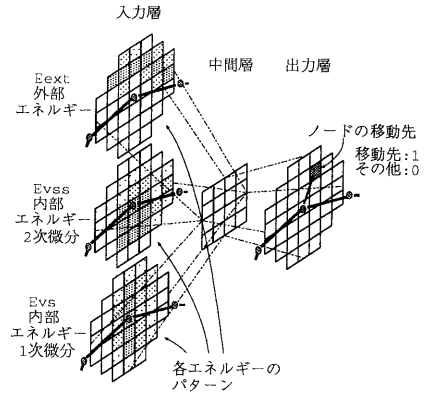


図 2: ニューラルネットワークの適用

ニューラルネットワークは学習用データの対(学習入力と教師出力)であるトレーニングセットを与えれば、誤差逆伝搬法により入力から出力への変換を学習できる。Greedy Algorithmにおける近傍探索領域の3種のエネルギーのパターンをニューラルネットワークに入力したときにこのニューラルネットワークに移動先を出力させるよう学習できれば、各エネルギー項の重み付けを行なったのと同じ効果が得られると考えられる。

2.4 従来の「単独移動」の学習方式とその問題点

Snakesの収束過程で近傍探索領域に現れるエネルギーパターンは無数にある。すべてのパターンをニューラルネットワークに学習させることは、計算量とニューラルネットワークの学習能力の2点より困難である。よって、収束を効率良く学習できるトレーニングセットを作成しなくてはならない。

加藤らは目標とする教師輪郭近傍でのノードの移動を学習させた。このトレーニングセットの作成の様子を図3に示す。

このトレーニングセットでは教師輪郭上のノ

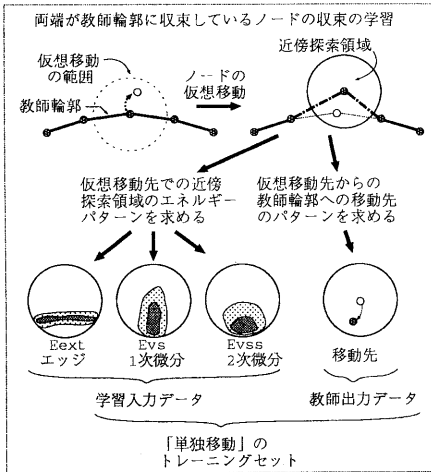


図 3: 「単独移動」のトレーニングセットの作成

ドが単独で仮想的に移動した位置から教師輪郭上の元の位置に復帰する移動を学習する。仮想移動先での近傍探索領域のエネルギーパターンを学習入力とし、復帰の移動パターンを教師出力とする。この時、教師輪郭上の全ノードについて仮想移動の範囲内の全ての位置からの復帰動作のトレーニングセットを用意する。本報告ではこのトレーニングセットを「単独移動」のトレーニングセットと呼ぶことにする。




図 4: 「単独移動」の学習の問題点

しかし、この「単独移動」のトレーニングセットを用いて誤差逆伝搬法で学習した Snakes の収束結果は良好といえるものではなかった。図 4 に示すように、1) の両隣のノードと共に並行移動したように対象物体の輪郭から離れたノードと 2) の隣の片方のノードを軸にしてもう一方の隣のノードと共に回転移動したように対象物体の輪郭から離れたノードにおいて収束がみられず、また、3) のように対象物体から遠く離れその近傍探索領域内に対象物体の輪郭の濃度勾配を捕らえることのできないノードにおいてはエッジから離れる方向に拡散したりなど挙動が不安定なものがあつた。

ドと共に回転移動したように対象物体の輪郭から離れたノードにおいて収束がみられず、また、3) のように対象物体から遠く離れその近傍探索領域内に対象物体の輪郭の濃度勾配を捕らえることのできないノードにおいてはエッジから離れる方向に拡散したりなど挙動が不安定なものがあつた。

3 学習用データ作成の手法

本章では従来の学習法の問題点を解決する学習法について提案する。

2.4節の 1) に対しては「並行移動」の、2) に対しては「回転移動」の、3) に対しては「無勾配移動」のトレーニングセットを、従来の「単独移動」のトレーニングセットと同じ教師輪郭を基に新たに作成し、これをニューラルネットに学習させる。

3.1 学習用データ作成の手法

提案するトレーニングセットの作成の様子を図 5 に示す。

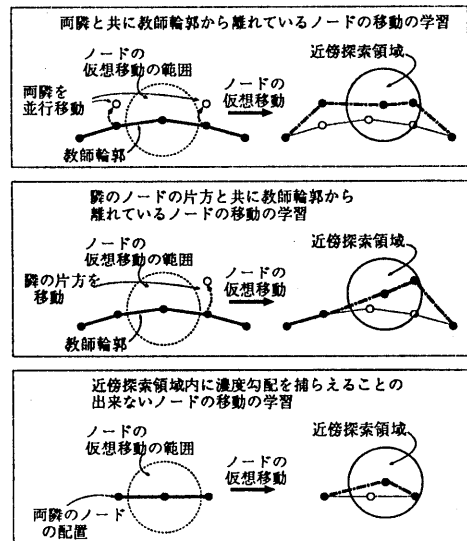


図 5: 提案するトレーニングセットの作成

「並行移動」の場合、教師輪郭上から両隣のノードを互いに並行になるように移動させる。このと

き教師輪郭の内側と外側の両方向に数段階の移動距離を設ける。

「回転移動」の場合、他方の隣のノードを軸にして教師輪郭上から片方のノードを回転移動させる動作を両隣のノードについて行なう。このとき教師輪郭の内側と外側の両方向に数段階の移動距離を設ける。

「無勾配移動」の場合、注目するノードの両側に、直線上に等間隔に並ぶように両隣のノードを配置する。このとき両隣のノードの組を、各々の組のノードを結ぶ直線の向き全方位分を用意する。

それぞれの状態で注目するノードの仮想移動先での近傍探索領域内の各エネルギーパターンを学習入力とし、この仮想移動先の位置から教師輪郭上の元の位置への移動のパターンを学習出力とする。但し、「無勾配移動」は濃度勾配が無いところでの移動を学習させるものなので、濃度勾配の無い外部エネルギー E_{ext} のパターンを用意する。

3.2 提案するトレーニングセットの特徴

「単独移動」のトレーニングセットの働きは、

- ・各ノードにおける教師輪郭の局所的な重み付けを記憶することによって Snakes 収束後の安定をもたらす。

ことである。

そして、提案するトレーニングセットの機能的な特徴については以下のように考えられる。

「並行移動」の働き

- ・教師輪郭から連続して離れている部分のノードの収束移動の重み付けを記憶する。

「回転移動」の働き

- ・教師輪郭上に収束している部分と収束していない部分との境界のノードの収束移動の重み付けを記憶する。

「無勾配移動」の働き

- ・その近傍探索領域内に濃度勾配を捕らえることのできないノードを、直線上に等間隔に並べるエネルギーの重み付けを記憶することによってその挙動を安定させる。

Snakes の収束過程での各トレーニングセットの効果を図 6 に示す。

II) では「回転移動」の効果により 2) のノードが輪郭に収束する。そして、III) では「無勾配移




図 6: 各トレーニングセットの効果

動」の効果により 3) の部分が等間隔になるように移動する。この 2 つの動作が繰り返されて収束が進み V) の状態になったときには、「並行移動」の効果によって 1) の部分が収束する。その後、VII) では「単独移動」の効果によって収束状態で安定する。

4 実験とその結果

実験サンプルには 2 値パターン画像と NMR 画像を用いる (図 7)。2 値画像の画像サイズは 349×296 画素で、NMR 画像の画像サイズは 361×308 画素である。




図 7: サンプル画像

どちらの画像に対しても、Snakes のノード数は 128 で、ノード間の平均距離は 4 画素程度にする。近傍探索領域は図 2 にあるように、7×7 画素で 4 隅をカットした領域とする。各トレーニングセッ

トの作成での仮想移動の範囲は、この近傍探索領域と同じ形の領域とする。

4.1 トレーニングセットの組合せとニューラルネットワークの規模

学習には、トレーニングセットを組み合わせたものを用いる。表 1 にトレーニングセットの組み合わせと学習の名称を示す。

今回、「並行移動」と「回転移動」のトレーニングセットの作成における隣のノードの移動は注目するノードの位置での教師輪郭の接線と垂直の方向に 3 段階で、「並行移動」では 8 近傍距離で 1, 2, 3 画素の移動とし「回転移動」では 2, 4, 6 画素の移動とした。「無勾配移動」では 360°を 32 段階に分け、各々の両隣と注目するノードとの距離を 8 近傍距離で 4 画素とした。

表 1: 学習の種類

名称	トレーニングセットの種類
学習 I	「単独移動」
学習 II	「単独移動」「並行移動」
学習 III	「単独移動」「回転移動」
学習 IV	「単独移動」「無勾配移動」
学習 V	「単独移動」「並行移動」 「回転移動」「無勾配移動」

ニューラルネットワークはその規模やトレーニングセットの種類と数によりその汎化能力が異なることが知られている。今回、学習を試みたネットワークの規模を表 2 に示す。なお、中間層の規模から各ネットワークに名称を付け、以降の説明ではこの名称を用いる。

学習回数は全ての学習とネットワークの組合せにおいて 300 回とした。以降、この 300 回学習を行なったネットワークを用いて輪郭の抽出を行なう。

4.2 輪郭抽出の結果

次に、これらのニューラルネットワークを用いて Snakes の収束を試みる。Greedy Algorithm による収束の反復回数は 100 回である。

表 2: ニューラルネットワークの規模

名称	総数	中間層のユニット数
37-37 型	4	in(111)-37-37-out(37)
37-5 型	4	in(111)-37-5-out(37)
21-5 型	4	in(111)-21-5-out(37)
14-5 型	4	in(111)-14-5-out(37)
7-5 型	4	in(111)-7-5-out(37)
37-5-5 型	5	in(111)-37-5-5-out(37)

まず、2 値パターン画像についての収束では、図 8 の輪郭の内側と外側からの 2 つの初期値から収束を行なった。このとき、教師輪郭は背景との境界線を用いた。

Snakes の収束率を図 9 に示す。この収束率は、近傍探索領域の範囲内まで教師輪郭へ収束したノードの割合である。



図 8: 初期値 -パターン画像-

初期値が内側のグラフをみると学習 II, III の収束率が高く、学習 V の収束率が最も高い。これより「並行移動」と「回転移動」のトレーニングセットが収束に効果があり、また全てのトレーニングセットの学習が最も効果があることがわかる。初期値が外側のグラフにおいても、ニューラルネットワークの型により違いはあるが同様の傾向がみられる。

2 つの初期値の両方で、21-5 型と 7-5 型の収束率が 100%であった。21-5 型の収束結果を図 10 に示す。「単独移動」のみの学習 I では図中の 1)~3) において収束していない部分がみられる (この 1)~3) は 2.4 節の図 4 に対応している)。学習 II では「並行移動」の効果によって 1) の部分において剥離していた部分が収束している。学習 III で




図 9: 収束率 -パターン画像-

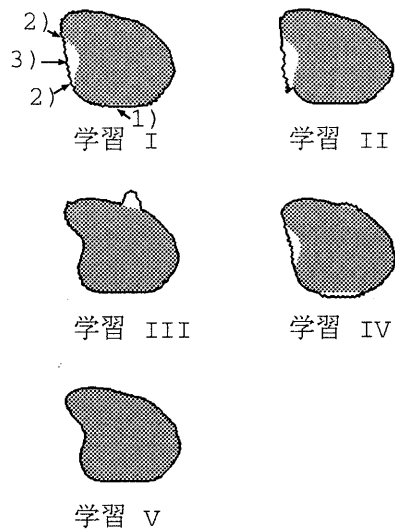



図 10: 収束結果 -パターン画像-

は「回転移動」の効果によって2)の部分の両方から内側の3)の部分へ向かって巻き取られるように収束している。また、挙動不安定なノードがエッジから離れて行こうとしているために上部に凸部ができてはいるが、その両側で収束を保っている。学習 IV では収束率は向上していないものの、「無勾配移動」の効果によって3)の部分が安定している。学習 V では全てのトレーニングセットの効果により、100%のノードが収束しその後安定している。

2 値のパターン画像において、21-5 型と 7-5 型が学習 V で 100%の収束を示した。そこで、21-5 型に学習 V を学習させて NMR 画像の輪郭の抽出を行なった。その収束結果を図 11 に示す。図 11 の結果 1 は脳の輪郭を手書きで抽出した教師輪郭で学習させたときの抽出結果で、結果 2 はこの手書き教師輪郭を従来の Snakes で収束させた教師輪郭で学習させたときの抽出結果である。

手書きの教師輪郭には初めから輪郭の抽出エラーがある。しかし、手書き教師輪郭への収束を学習させたものは Snakes の左部に収束していない部分があるものの、かなりの部分の収束が希望通りに行なわれている。一方、手書き教師輪郭を従

来の Snakes で収束させた教師輪郭で学習させたものではほとんどのノードが収束している。この場合の収束率は 93.75%であった。



結果 1 結果 2

図 11: 収束結果 -NMR 画像-

5 まとめ

本報告では、Snakes による輪郭抽出のアルゴリズムにニューラルネットワークを適用する手法において従来の学習用データの問題点を指摘し、これを解決する新しい学習用データの作成法を提案

し実験により以下の結果を得た。

- 輪郭の近傍で連続的に剥離している部分での移動のための学習用データと、収束している部分と収束していない部分の境界での移動のための学習用データが輪郭への収束度の向上に効果がある。
- 濃度勾配の無いところでの移動のための学習用データが濃度勾配の無いところでの Snakes の挙動の安定化に効果がある。
- 輪郭抽出能力が最も良かったのは、全ての学習用データを学習させた 2-1-5 型と 7-5 型のニューラルネットワークである。
- 手書き人力の教師輪郭には初めから輪郭抽出エラーが含まれているが、これを用いて作成した学習用データでも輪郭抽出の学習効果があり、手書き教師輪郭の重み付けを学習できる可能性を示している。

今回は、一つのニューラルネットワークで Snakes の全ノードの移動をおこなったため局所的な重み付けは明確ではない。

今後の課題として、重み係数の局所性を明確に学習することがあげられる。そのために、各ノードの Snakes 内での相対位置の情報をエネルギーパターンと同時にニューラルネットワークに入力する、あるいは Snakes の各ノードに専用のニューラルネットワークをひとつずつ設けるといった手法が考えられる。

参考文献

- [1] M.Kass, A.Witkin, and D.Terzopoulos: Snakes: Active Contour models. *International Journal of Computer Vision*, Vol. 1, No. 4, pp. 321-331, 1988.
- [2] Amini A. A., Weymouth T. E., and Jain R. C: Using Dynamic programming for solving variational problems in vision. *IEEE Trans. Pattern Anal. & Mach. Intell.*, Vol.PAMI-12, No.9, pp.855-867, 1988.
- [3] Donna J.Williams and Mubarak Shah: A Fast Algorithm for active contours. *Proc. of Third ICCV*, pp.592-595, 1990.
- [4] Ryo Furukawa, Masakazu Imai, Takeshi Uno: Robust Algorithm for Motion Analysis Based on Active Tubes. *Proc. of Motion of Non-Rigid and Articulate Objects*, November 11-12, pp.200-205, 1994.
- [5] Minoru Takahata, Masakazu Imai and Saburo Tsuji: Determining Motion of Non-Rigid Objects by Active Tubes. *Proc. of 11th ICPR*, Vol.1, pp.647-651, 1992.
- [6] 上田修功, 間瀬健二, 末永康仁: 弾性輪郭モデルとエネルギー最小化原理による非剛体物体の輪郭追跡手法. 電子情報通信学会論文誌, D-II Vol. J75-D-II, No.1, pp. 111-120, January 1992.
- [7] 光本浩士, 岡崎耕三, 梶見直樹, 田村進一, 河合秀夫, 福井裕: エネルギー関数とオプティカルフローを用いた1次元輪郭の抽出・補完と追跡. 情報処理学会論文誌, Vol.31, No.3, pp.444-452, March 1990.
- [8] 福井和広: 領域間の分離度に基づく物体輪郭抽出. 情報処理学会研究報告, 94-CV-88, pp.9-16, March 1994.
- [9] 柴藤稔, 白井良明, 浅田稔: クラスタリングから得られる領域の記述に基づく動的な輪郭抽出. 電子情報通信学会論文誌, D-II Vol. J75-D-II, No.7 pp. 1111-1119, July 1992.
- [10] 加藤浩巳, 今井 正和, 鳥野 武: Active Tubes による動作解析へのニューラルネットワークの適用. 電子情報通信学会技術研究報告, PRU95-44, pp.57-64, June 1995.