

Active Netの抽出性能改善に関する研究

A Study on Improvement of Active Net Extraction

難波 福弥 鷲見 育亮

植田 拓也* 藪木 登** 築谷 隆雄***

NAMBA Fukuya SUMI Yasuaki

UETA Takuya* YABUKI Noboru** TSUKUTANI Takao***

和文要旨：本論文では、これまで鷲見研究室で研究を行ってきたActive Netの性能向上に関する研究について述べる。Active Netはモデル内部の画像情報を取り込むことができる能力を持っているため、対象領域内部の情報を考慮した領域抽出を行うことができる。しかし、Active Netによる領域抽出において、対象領域が画像の端にあって、かつ初期ネットが対象領域を覆っていても、対象の捕捉ができていないという問題点があった。さらに、対象が1つにつき、ネットは1つしか利用できないので、対象が複数の場合には同じ動作を繰り返す必要があった。そのようなActive Netが持つ問題点の解決に向けて、我々は(1)ヒストグラムを用いた方式、(2)All-Image DCDAM、(3)All-Image BL-DCDAMを用いた方式の検討を行ってきた。それぞれの方式の研究成果について述べる。

【キーワード】Active Net、領域抽出、ヒストグラム、自己組織化マップ、DCDAM

Abstract: In this paper, we have explained the study on the performance improvement of Active Net that has been researching up to now in the Sumi Laboratory. As Active Net can take out the image-information from the image as the net model itself, it can extract the target from image that involves the information in the image. However, in case of extracting by Active Net the region from the image, the problem existed that it couldn't catch the target, though target area was in the image edge and covered with an initial net. In addition, as it was necessary for one net to one object, the same operation was needed to the plural objects. To the solution of such Active Net's problem, we have developed the methods to use the (1) histogram, (2) All-Image DCDAM, (3) All-Image BL-DCDAM. For each method we have described the fruits of study.

【Keyword】Active Net, Region extraction, Histogram, Self-Organizing Map, DCDAM

1. まえがき

画像認識・理解技術は、顔を用いた個人認証^[1]や、作業負担を減らし円滑な業務を遂行するための患者監視システム^[2]など福祉への貢献、さらには高度道路交通システムの実現へ向けた道路標識の認識^[3]というように、様々な分野で応用されようとしている。このような画像

認識・理解技術の実用化に向けては、得られる入力画像から対象物体候補が存在する領域の抽出処理が必須であり、これに関しては先に述べたような分野に限らず医学分野等幅広い分野にわたり様々な方法が検討されている^[4]。

領域抽出を行うには、領域を表す輪郭の検出が必要となる。輪郭検出には、動的輪郭モデル^[5]や、動的輪郭モデルを2次元の動的なネットのモデルへと拡張したActive Net^[6]など動的輪郭モデルに基づいた手法や、ニューラルネットワークを用いる手法^{[7]-[9]}と、さらに動的輪郭

*2007年3月修士課程修了

**津山工業高等専門学校

***松江工業高等専門学校

モデルとニューラルネットワークを組み合わせた手法^{[10],[11]}などがある。

このように、画像認識・理解のために画像中から対象となる物体を抽出することは必須の処理である。そのため、対象物体を表す領域を確定し、その領域抽出が必要となる。我々は道路情景画像から道路標識を表す領域のみを抽出してその道路標識を認識する^[12]ことを応用の1つとして、Active Netを用いた領域抽出を行っている。

Active Netはネットモデル内部にも画像情報を取り込むことができ、対象領域内部の情報を考慮した抽出が可能である。さらに、動的輪郭モデルをベースとした手法であるため、途切れてしまっている輪郭線の補完をすることができるため、雑音や遮蔽などが多い画像から輪郭抽出することに関して有用性が高いと言える。そして、我々が使用するActive Netでは、白黒2値画像だけでなく、カラー画像から特定の対象物体を抽出するためにカラー画像から必要となる特定色抽出を行った濃淡画像を入力画像として用いている。この特定色抽出を行うために、我々は色分布関数^[20]を用いている。色分布関数はあらかじめ抽出したい対象が持つ色を採取し、その標本色に対して共分散行列を求めることでXY色度座標の特定座標に対する「類似度」を256段階で出力することができる。この手法を用いることにより撮影状況による色の変動に対してロバストな特定色抽出を行うことができる特徴を持つ。

しかしながら、Active Netには基本的に2つの大きな問題がある。

課題1．Active Netによる領域抽出において、対象領域が画像の端にあって、かつ初期ネットが対象領域を覆っていても、対象の捕捉ができていないという問題点があった。

課題2．ネットは抽出対象が1つにつき、1つしか利用できないので、抽出対象が複数の場合には同じ動作を繰り返す必要があった。

この問題を解決するため、従来までに行われてきた改良として、Active Netのネット構造を変化させた手法^[13]や、マルチネット方式^{[15][16]}が取り組まれてきている。残されている問題として、いずれもネットの数だけ捕捉が可能であるが、初期配置を正しく行わなければ隣接した複数物体の抽出ができないという問題をいまだ抱えている。

さらに、道路情景画像中から道路標識を抽出するためには、次のような課題を解決しなければならない。

課題3．車載されたカメラの撮影範囲に写り込んだ道路標識を全て正しく抽出すること

課題4．移動体にカメラを搭載するため、高速な処理が可能であること

このような上記問題点の解決へ向けて、これまでActive Netは、エネルギー問題として対象物体の捕捉をしていた。そのとき、うまくいかない場合の補助手段（前処理）として、エネルギー問題をネット配置問題に置き換え、我々は次の3つの手法について検討した。本論文では主にこの3つの手法について述べる。

研究1．ヒストグラム方式

研究2．All-Image DCDAM

研究3．All-Image BL-DCDAM

研究1は課題1・2を解決するためになされたものである。従来研究であるマルチネット方式の問題点としては、ネットの数だけ捕捉が可能であるが、初期配置を正しく行わなければ隣接した複数物体の抽出ができない問題点を有していた。その問題を解決するために、Active Netの適切な初期位置を求める一手法としてヒストグラムを用いた手法を提案し、隣接した複数物体の抽出を正しく捕捉する方法を示す。

研究2は研究1のヒストグラム方式をベースに、さらに改良したものである。ヒストグラムの頻度分布を射影する角度によっては、誤検出をしてしまう場合があり、この問題を解決するために輪郭抽出手法DCDAM^[21]をActive Netの制御へ適用することでその性能改善を試みた。

研究3は課題3・4を解決するためになされたもので、DCDAMの改良版であるBL-DCDAM^[22]を新しく採用する手法を検討・開発した。これにより、DCDAMで発生する誤検出を削減することができた。本論文では、以下に示す順序で述べる。

2章でカラー画像から濃淡画像変換に用いる色分布関数

3章でActive Netの原理

4章でActive Netに関する従来研究

5章で研究1：ヒストグラム方式

6章で研究2：DCDAMを用いる方式

7章で研究3：BL-DCDAMを用いる方式

8章で3つの研究について総括

2．特定色抽出に用いる色分布関数について

本研究ではActive Netに入力する画像としては、デジタルカメラ等で撮影されたカラー画像を用いる。そこから対象物体を表す色（本研究では道路標識の赤・青・黄

の各色)を抽出するための手法として色分布関数^[20]を用いる。色分布関数は道路情景画像のように光源や天候に大きく左右される照明条件に対してロバストであり、さらに色の類似度を出力するため、その類似度を対象が持つ色のエネルギーとして見る事が可能であるためである。本章ではその色分布関数について述べる。

2.1. 色分布関数の概要

色分布関数とは、抽出対象にする物体の色をあらかじめ標本色として採取し、共分散行列を求める統計的処理を行い、入力画像の画素が抽出対象となる色に近いほど出力の濃淡値が大きくなるような色分布の関数として定義する手法である。

式(2.1)に示すように、色の分布は正規化分布と仮定する。さらに、広い範囲の撮影条件に対応できるように、式(2.2)に示すようなガウスフィルタを式(2.1)へ適用したものを式(2.3)に示す。このように色分布関数 $h(x, y)$ は、式(2.3)のように定義される。ガウスフィルタとはガウス関数を用いた平滑化フィルタの一種である。

$$S(\alpha) = 255 \cdot \exp\left\{-\frac{1}{2}(\alpha - \mu)^T K^{-1}(\alpha - \mu)\right\} \quad (2.1)$$

$$g(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (2.2)$$

$$h(x, y) = \sum_{x_i=x}^{x+l} \sum_{y_i=y}^{y+l} g(x - x_i, y - y_i) S(\alpha_i) \quad (2.3)$$

ここで、変数 μ, K は式(2.4)、(2.5)の通りである。

$$\mu = \frac{1}{N} \sum_{n=1}^N \alpha_n \quad (2.4)$$

$$K = \frac{1}{N} \sum_{n=1}^N (\alpha_n - \mu)(\alpha_n - \mu)^T \quad (2.5)$$

l はガウスフィルタにおけるオペレータ半径であり、 σ^2 はガウスフィルタにおける分散である。入力データの全画素数を N 、色標識画素ベクトルを $\alpha_n = [x_n, y_n]$ で表わしており、 x_n, y_n は n 番目の画素を xy 色度座標に変換した座標である。また、 $\alpha = [x, y]^T$ であり、分布関数作成のための標本画像の全画素平均ベクトルを μ 、共分散行列を K としている。

式(2.6) - (2.8)に、本研究で用いる各色標本データから求めた赤色、青色、黄色の各 μ, K を示す。また、 xy 色度座標平面における各色分布関数を図1に示す。図1において、 x 軸、 y 軸が xy 色度座標平面を表し、 z 軸が $h(x, y)$ を表している。

$$\text{赤色 } \mu = [109, 81]^T \quad K = \begin{bmatrix} 86 & -11 \\ -11 & 5 \end{bmatrix} \quad (2.6)$$

$$\text{青色 } \mu = [58, 62]^T \quad K = \begin{bmatrix} 47 & 38 \\ 38 & 42 \end{bmatrix} \quad (2.7)$$

$$\text{黄色 } \mu = [117, 117]^T \quad K = \begin{bmatrix} 8 & 10 \\ 10 & 14 \end{bmatrix} \quad (2.8)$$

これを求める事により、色を手がかりとして入力画像から、色分布関数上の特定色領域に類似している画素のみを直接的に取り出すことができる。

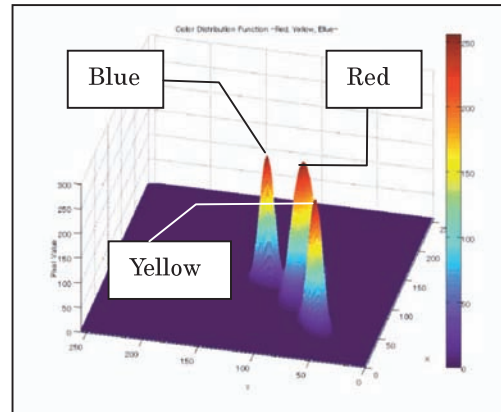


図1. 本研究で使用する色分布関数 (赤・青・黄)
Figure 1. Color Distribution Function for Our Study (Red, Blue, Yellow)

2.2. 色分布関数により得られる濃淡画像：類似度マップ

図2に示すカラー入力画像に対して図1に示した色分布関数のうち、赤色分布関数を適用して得られた出力を図3に示す。この濃淡画像が類似度マップと呼ばれるものである。類似度マップとはこのように、カラー入力画像である道路情景画像の各画素に対して色分布関数を適用し、標本色にどれだけ類似しているかを示す「対象物の色らしさ度」に置き換えた濃淡画像であると言える。つまり、カラー画像(原画像)からある物体の輪郭を抽出するために対象物体の持っている色にもっとも近いものを、色分布関数を適用することで得られる階調度256段階を持つ濃淡画像(2値画像ではなく)が類似度マップである。

図3において、黒に近い画素ほど所望の色である赤色標識色に近いことを示している。また、白色に近い画素ほど赤色標識色から遠いことを示している。入力画像の各画素 e_{ij} の色らしさ度は式(2.9)で表される。ここで、画素 e の添え字 i, j は入力画像における座標値を表している。

$$S_m(e_{ij}) = h[x_f(e_{ij}), y_f(e_{ij})] \quad (2.9)$$

なお、 $x_f(e_{ij}), y_f(e_{ij})$ は画素 e_{ij} を XY 色空間における xy 色度座標に変換したものである。



図2 . カラー入力画像
Figure 2. Color Input Image



図3 . 図17から得られた類似度マップ
Figure 3. Color Similarity Map by Figure 2

3 . Active Netの原理

本章では、Active Netの原理について説明を行う。

Active Netはエネルギー最小化原理に基づいた動的なネットモデルである。すなわち、ネットに対して定義されたエネルギーが極小状態になるように自ら変形を繰り返しながら領域を抽出する。ネットの全体像は図4に示すような形をしている。その構造は、格子点 $\mathbf{v}(p,q) = (x, y)$ 、 $0 \leq p \leq 1$ 、 $0 \leq q \leq 1$ の集まりからなり、図5に示すように各格子点は隣り合う4近傍の点 $\mathbf{v}(p,q-l)$ 、 $\mathbf{v}(p-k,q)$ 、 $\mathbf{v}(p+k,q)$ 、 $\mathbf{v}(p,q+l)$ と結合されてネットを形成している。ここで、 x 、 y はそれぞれ画像の水平、垂直方向の座標を表していとすると $k=1/(x$ 方向の格子点数)、 $l=1/(y$ 方向の格子点数)である。




図4 . 格子ネット
Figure 4. Structure of grid net




図5 . Active Netの格子点構造
Figure 5. Grid point structure of Active Net

このアルゴリズムでは、ネットモデルに対して、ネットの内部歪みエネルギー E_{int} およびネットと画像の適合性エネルギー E_{image} の2つのエネルギーが与えられており、ネットのエネルギー汎関数 E_{net} はこれらの和として式(3.1)のように定義される。




図6 同心四角ネット
(中心を持った四角形構造のActive Net)
Figure 6. Concentric square net
(Active Net of square structure with center)

$$E_{net} = \int_0^1 \int_0^1 \{E_{int}(\mathbf{v}(p,q)) + E_{image}(\mathbf{v}(p,q))\} dpdq \quad (3.1)$$

内部歪みエネルギー E_{int} はネットを収縮させかつその形状を滑らかに保とうとするエネルギーに対応しており、一般的に式(3.2)のように記述される。

$$E_{int} = \{ \alpha (|\mathbf{v}_p|^2 + |\mathbf{v}_q|^2) + \beta (|\mathbf{v}_{pp}|^2 + |\mathbf{v}_{qq}|^2 + |\mathbf{v}_{pq}|^2) \} / 2 \quad (3.2)$$

ここで、添字は偏微分を表し、 α と β は重み係数である。この式は2つの項から定義されており、第1項はネットを収縮する力、第2項はネットの滑らかさを保つ

力をそれぞれ表している。

画像の適合性エネルギー E_{image} は画像内の特徴的（濃淡レベル、画像の滑らかさなど）な領域へネットを導く力に対応している。すなわち、**Active Net**は対象物体の特徴（本研究では濃淡レベルを用いる）を表す E_{image} を定義すると、ネット自身をその対象に引き寄せる力が生じる。本研究で用いる E_{image} としては濃淡レベルを用い、式(3.3)のように定義する。

$$E_{image} = wI(x,y) \quad (3.3)$$

ここで、 $I(x,y)$ は格子点 $\mathbf{v}(p,q)=(x,y)$ での濃淡レベルを表している。 w は係数であり、 $w>0$ とした場合、ネットは濃淡レベルの低い方へと引きつけられるようになる。一般的に E_{image} は、**Active Net**の輪郭上の格子点が対象物の外側にあり内部の格子点が対象物領域内にある場合、小さな値をとるように定義する。

式(3.1)の最小化は汎関数における極値問題であり、変分法の枠組みであるオイラー・ラグランジュの方程式によって解くことができる。これにより以下に示す式(3.4)と式(3.5)の独立な2つの式を得る。

$$-\alpha(x_{pp} + x_{qq}) + \beta(x_{pppp} + 2x_{ppqq} + x_{qqqq}) + \frac{E_{image}}{x} = 0 \quad (3.4)$$

$$-\alpha(y_{pp} + y_{qq}) + \beta(y_{pppp} + 2y_{ppqq} + y_{qqqq}) + \frac{E_{image}}{y} = 0 \quad (3.5)$$

これら偏微分方程式の各項を差分近似式に置き換えることにより、格子点の x 座標および y 座標についての連立方程式ができる。それらの式は、初期ネットの位置を初期値としてヤコビ法に基づく並列型反復法を用いて解かれる。すなわち、**Active Net**の振舞いとは、反復演算中に逐次求まる近似解に対応しており、ネットはダイナミックに変形しながら最終解（エネルギー極小解）に落ち着く。本研究では、図4の格子ネットから同心型に変更した、図6に示すような中心を持った四角形構造の同心四角ネット^[18]を用いる。

4. Active Netに関する従来研究

本章では、従来まで**Active Net**に関する研究されてきた先行研究について述べる。

従来から用いられている**Active Net**のネット構造には、正方格子、同心四角ネット、同心円ネットなどがある^{[6],[18]}。そして、正方格子、同心四角ネットにおいては、初期のネットをほぼ画像全体を覆うように設定することができ、画像の端にある対象領域を捕捉することが

可能である。しかし、対象の大きさによっては、捕捉できない場合がある。また、一つのネットでは一つの画像全体に対して一対象しか捕捉することはできない。

そこで、多くの対象を捕捉できるよう、また、画像の端にある対象を捕捉できるよう、4.1で2段階**Active Net**方式^[14]と、4.2で画像を分割してネットを各分割領域に適用する方法としてマルチネット方式^{[15],[16]}についてそれぞれ述べる。さらに、4.3で**Active Net**のモデルに分割条件を加えた方式も提案されている^[24]。次よりそれぞれの詳細について述べる。

4.1. 2段階Active Net方式

2段階**Active Net**方式は、まず入力画像全体に対して同心四角ネットを配置する。次に、その**Active Net**を実行し、中心から伸びる各放射線の収縮速度を観測する。**Active Net**は濃淡値の高い画素付近での収縮は行わないため、収縮速度が遅い放射線を発見し、その付近に再び**Active Net**を配置することで画像の端にある対象が抽出できない問題、複数の対象の抽出についての問題を解決したものを試みた手法である。図7に、2段階**Active Net**方式による実験結果の一例を示す^[14]。

4.2. 多面分割（マルチネット）方式

次に、多面分割方式について説明を行う。他面分割方式は、画像を n 個の領域に分割し、それぞれの領域をカバーできるサイズのネットを n 個の各領域に適用する。分割数は増やすことも減らすことも可能な手法である。図8に多面分割方式の分割例を示す。

● 4面分割方式

4面分割方式を用いてシミュレーション実験を行った。まず入力画像を図9に示す。この入力画像は濃淡値128の人工画像である。このときのネットの形式は図8に示すとおりである^[15]。

対象物体は2つとし、この結果を図10-図11に示す^[15]。このうち左上に存在する対象は、良好に捕捉できていることが分かる。しかし、中央にある対象は捕捉できていない。これにより、既に述べたようにネットの初期形状において対象物体がそのネットに覆われている必要があることが分かる。



図7. 2段階Active Net方式の実行結果^[14]
Figure 7. Execution result of two-step Active Net^[14]




図8. 多面分割方式の初期形状の例(4面分割方式)
Figure 8. Example initial arrangement of multiple method (divide the net in quarters)



図9. 抽出対象が2個ある入力画像
Figure 9. Targets are two exist in input image

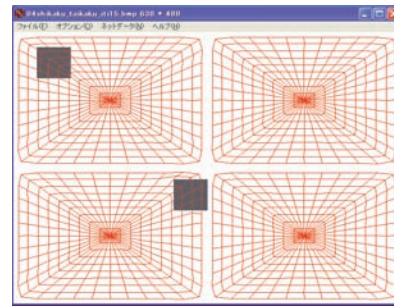


図10. 4面分割方式の実行 (iteration=1)
Figure 10. Execution of divide the Active Net in quarters (iteration=1)

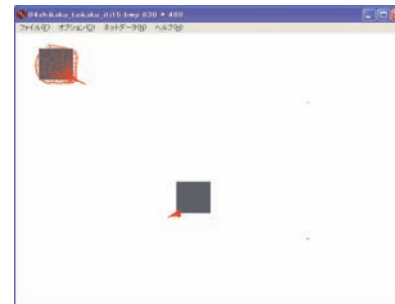


図11. 4面分割方式の実行結果 (iteration=10000)
Figure 11. Result of divide the Active Net in quarters (iteration=10000)

● 9面分割方式

次に、9面分割方式についても述べる。これは、対象が比較的大きく、または存在する座標が問題で、4面分割方式で捕らえられなくなった領域(ネット間の中心部分)を補うために、4つのネットの間を中心としたネットをさらに追加したものである。図12にネットの初期配置図を、図13にシミュレーション結果をそれぞれ示す。図13から、対象を捕捉していることが分かる。また、左端の対象は左上のネット、中央の対象は、左中、左下、中央、中央下の4つのネットにより捕捉されている。その他のネットについては、ネットの中心部へ収束している。




図12. 9面分割方式の実行 (iteration=1)
Figure 12. Result of divide the Active Net in nine (iteration=1)

4.3 . Active Netを分割する手法

4.1、4.2は前処理によりActive Netの初期位置と数を設定する手法である。このようなアプローチ以外にも、Active Netに動的に分割するための機能を組み込み、各格子点間の情報に基づき分割される手法についても検討されている [24]。




図13 . 9面分割方式の実行 (iteration=10000)
Figure 13. Result of divide the Active Net in nine (iteration=10000)

4.4 . Active Netに関する従来研究のまとめと残された課題

1章で述べた性能向上に関して、これまで取り組みが行われてきた手法をまとめると、次のように3つに分類することができる。

- 手法1 . Active Netのネット構造を変化させる手法
- 手法2 . 前処理によりActive Netの初期位置を設定する手法
- 手法3 . Active Netを分割する手法

本章では、Active Netの課題1・2を解決する従来研究について述べた。性能向上に関して述べた内容をまとめると、

手法1に関しては、正方格子、同心四角ネットが当てはまり、初期のネットをほぼ画像全体を覆うように設定することができ、画像の端にある対象領域を捕捉することが可能であるが、対象の大きさによっては、捕捉できない場合の例を示した。また、一つのネットの一つの画像全体に対して一対象しか捕捉することはできないことも併せて示した。

手法2に関しては、多くの対象を捕捉できるよう、また、画像の端にある対象を捕捉できるよう、2段階Active Net方式 [14]と、図8に示すように画像を分割してネットを各分割領域に適用する方法について検討を行ったものがマルチネット方式 [15]として提案されていることを述べた。

手法3に関しては、Active Netのモデルに分割条件を加えた方式も提案されている [25]。

しかし、いずれのアプローチにおいても、完全な解決ができておらず、残された課題としては

- 課題1 . 2段階Active Net方式においては1つの抽出対象領域に複数の放射線が重なった場合
- 課題2 . マルチネット方式で初期位置を固定して配置するために抽出対象領域の位置によっては失敗する場合がある

などという問題が残されている。その問題解決のために、ネットの分割などをActive Netへ組み込むのではなく、別処理による前処理として行うことでActive Netの基本性能へ影響を与えることなく抽出させることを目指して、我々は本論文で述べる3つの手法(研究1・2・3)でアプローチを行った。

5 . 研究1 : ヒストグラム方式を用いた手法

本章では、解決すべき問題点として前章で述べた課題1、2の解決について述べる。課題1、2として文献 [13]の手法では画像端の目標物を捕捉可能であるが画面全体から1つのみを抽出することしかできない。また、文献 [16]の手法ではネットの数だけ捕捉が可能であるが、初期配置を正しく行わなければ隣接した複数物体の抽出ができなかった。

そこで、我々は適切な初期位置をあらかじめ求める手法を用いるアプローチを取ることActive Netが持つ本来の機能を妨害しないように抽出ができる手法を目指した研究として、研究1ではヒストグラムを用いた手法とその詳細を述べる。

5.1 . ヒストグラム方式によるActive Netの初期配置

4章で述べたように従来手法では画像中で目標物が端にある場合や、複数物体が隣接した状態の抽出が困難だった。そのため、研究1ではまず、図14のような入力されたカラー画像中に色分布関数を適用することで、図15のように抽出対象である道路標識の付近は類似度が高く出力されていることに注目した。

図15に示した画像から、輪郭抽出を行うためにはあらかじめ何らかの前処理をして領域の絞り込みを行わせる。

領域の絞り込みが行われると、図16に示すように赤枠を得ることができる。その赤枠にActive Netが重なるように配置することで、従来研究で取り組まれた方式の間

題点を解決することができると思われる。そのような領域の絞り込みを実現するため、研究1ではヒストグラムを用いた方式で検討を行った。



図14．カラー入力画像
Figure 14. Color Input Image



図15．図17から得られた類似度マップ
Figure 15. Color Similarity Map by Figure 4




図16．領域特定を行った結果
Figure 16. Result of Area Squeeze

- ヒストグラムを得るための手法

本研究では、領域の絞り込みに関し、対象物体を抽出する前段として、対象物体が存在すると思われる所を特定しなければならない。その具体的な処理として、入力画像に対して色分布関数を適用して、得られた特定色抽出結果（類似度マップ）を2値化処理すると、対象物体の出現頻度を表すヒストグラムを得る（図17）。

- 抽出対象候補の位置推定

この結果より、特定色の画素がしきい値 t より多く出現している箇所に何らかの物体が存在すると仮定し、その中心にActive Netを配置する手法を開発した。

図14に示す入力カラー画像（640×480ピクセル）に対して色分布関数を適用し、得られた濃淡画像を2値化処理した画像と、それから得られた画素の出現頻度を表すヒストグラムを図17に示す。

図17に示したヒストグラムは、画像の縦方向と横方向の黒画素の出現頻度を調べたものである。ここから、出現頻度がある閾値 t を超えている領域で、かつ、ある程度の幅のある領域を抽出し、さらに、縦方向と横方向で重なる領域を何らかの物体が存在する領域と見なす。

本章の実験では、2値化のためのしきい値（濃淡値）を150とし、頻度のしきい値は25、出現頻度の幅は30としている。幅を求めるにあたり、何らかの理由により画素が著しく欠損している可能性がある。そのため、出現頻度の幅を求めるために本研究では移動平均により求め、移動平均のためのパラメータは4としている。

- Active Netの配置

次に、特定された領域の重心を求め、その重心をActive Netの中心位置として配置したものを図18に示す。今回はActive Netの大きさは手動で設定している。また、演算回数は50回に固定している。

- Active Netの実行

図18、図19に上記に基づきActive Netの配置と実行を行った結果を示す。図19より、隣り合う2つの対象物体を正しく抽出できていることが理解できる。




図17．色分布関数を適用して得られた画像に2値化処理を行った画像とヒストグラム
Figure 17. Binarized image of color similarity map with histogram




図18．画素の出現頻度を基にActive Netを配置した結果
Figure 18. Result of Active Net initial arrangement by histogram




図19．Active Netの実行結果
Figure 19. Execution result of Active Net

● 他の画像を用いた実験例

次に、図14とは異なる位置に対象が存在する図20に対して同様の手順でActive Netによる抽出を行った結果を図21-図24に示す。



図20．入力カラー画像
Figure 20. Input color image




図21．図22への色分布関数適用結果
Figure 21. Color Distribution Function (red) applied result

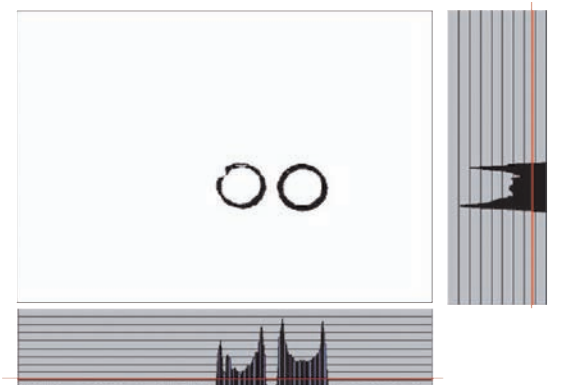


図22．色分布関数を適用して得られた画像に2値化処理を行った画像とヒストグラム
Figure 22. Binarized image of color similarity map with histogram

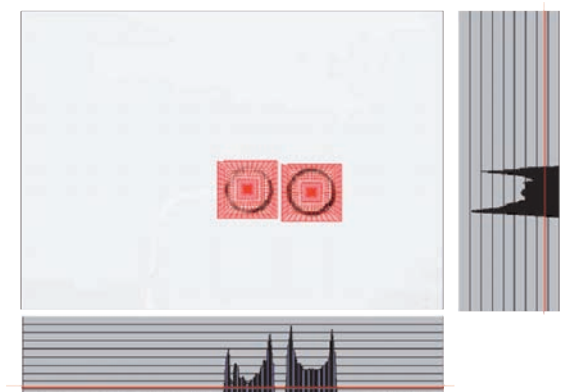


図23．画素の出現頻度を基にActive Netを配置した結果
Figure 23. Arranged Active Net by histogram

この結果より、抽出対象の出現する位置が一定でない場合においても正しく検出し、抽出できていることが理解できる。

● 従来手法との比較実験

次に、3で述べた従来手法との比較実験を行う。図25に図21に対して同心し各ネットを実行した結果と、図26

に図21に対してマルチネット（4分割）を実行した結果を示す。

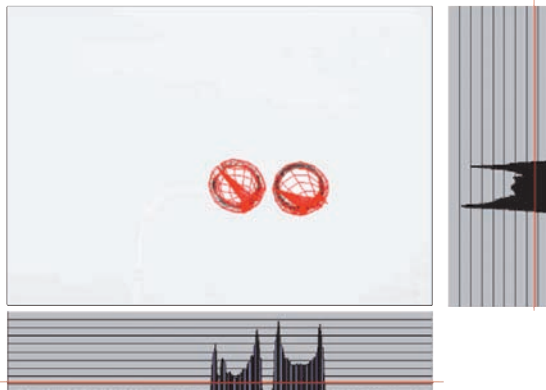


図24 . Active Netの実行結果
Figure 24. Execution result of Active Net

図25では1つのActive Netで2つの抽出対象を同時に抽出し、結果的に抽出に失敗している。図26においても同様に、4分割したActive Netのうち1つのActive Netに2つの抽出対象が含まれたため、抽出に失敗していることが理解できる。




図25 . 図21に対して同心四角ネットを実行した結果
Figure 25. Result of concentric square Active Net




図26 . 図21に対して4面分割方式を実行した結果
Figure 26. Result of four division Active Net

5.2 . 研究 1 : ヒストグラム方式のまとめと残された課題

4章で述べたように従来手法では画像中で目標物が端にある場合や、複数物体が隣接した状態の抽出が困難だった。

そこで、研究1では色分布関数により得られた類似度マップを2値化し、ヒストグラムを用いて物体が存在するのではないかと期待できる場所を特定しActive Netを配置することで、画面端かつ対象物体が隣接している場合でも正しく抽出することが実験から示せた。

研究1の課題としては、画像中にある目標物に対して垂直・水平方向で隣接していた場合だけではなく、斜め方向に隣接していた場合について失敗する場合があったことが挙げられる。

6 . 研究 2 : All-Image DCDAMを用いた手法

5.2のまとめで述べたように、Active Netの初期配置に関してヒストグラム方式を用いて目標物体候補の位置を推定する方式を開発した。この方式において対象物体の位置とヒストグラムを射影する角度の関係によっては複数の抽出対象を1つの抽出対象と見なす問題点が見つかった。

我々はニューラルネットワークの一種である自己組織化マップ^[19] (Self-Organizing Map: SOM) と、さらに色分布関数を統合することで実現した輪郭抽出に有効な手法である直接色分布適用手法 (Direct Color Distribution Applying Method: DCDAM)^[22]を開発している。

研究2では、本来輪郭抽出を行うために開発したDCDAMを、輪郭抽出用にはなく、入力画像の全画素を学習の対象にしてDCDAMを適用することで、ユニットは類似度の高い画素の周辺へ集まるようになると期待できる。この結果を利用してDCDAMの新しい役割として、対象物体候補の位置推定に利用できないかの検討を行った。

このようにして、DCDAMの機能に位置推定機能を追加して、All-Image DCDAMを提案する。このAll-Image DCDAMによる推定結果を利用してActive Netの捕捉性能を向上させる。

6.1 . DCDAM

この節では、All-Image DCDAMの解説の前に、

- ・自己組織化マップ
- ・逐次学習型 SOM アルゴリズム

について説明し、SOMと色分布関数とを統合して輪郭抽出手法として実現した

- ・DCDAM アルゴリズム

の概要を述べる。

6.1.1. 自己組織化マップ

まず、ニューラルネットワークの一種である自己組織化マップ (**Self-Organizing Map: SOM**)^[19]とは、**T. Kohonen**によって提案された教師信号なし近傍競争学習モデルである。広く一般的に用いられている構造は、図27に示すように入力層と競合層の2層から構成されている。




図27. 自己組織化マップの構造
Figure 27. Structure of Self-Organizing Map

競合層にはユニットと呼ばれるものが格子状に並んでいて、入力層はすべての競合層ユニットと結合している。ユニットとは、入力ベクトルと同じ次元数を持つ参照ベクトルを抽象化したものである。競合層ユニットは、通常1次元あるいは2次元の格子状に構成されているが、球面として構成されている場合もある。主な機能は教師信号を用いることなく、高次元入力ベクトルを高次元空間上での隣接関係を保持したまま、2次元マップなどの低次元空間に対して非線形写像が可能なことである。したがって、ある分布に従う高次元の入力ベクトル群に対して、その分布を保持したまま、マッピングすることができることが自己組織化マップの大きな特徴である。

6.1.2. 逐次学習型 SOM アルゴリズム

まず、マッピングの対象となる入力ベクトル群からランダムに取り出したベクトルを入力ベクトル $\mathbf{x}(t)$ とする。は離散時間座標で $t = 0, 1, 2, \dots, T$ の値をとる。この入力ベクトル $\mathbf{x}(t)$ とマップ上にある競合層ユニットに含まれる参照ベクトルとのユークリッド距離 $\|\mathbf{x} - \mathbf{m}_i\|$ が最小になるユニット i を探す。それに添え字 c をつけると、その値は式 (6.1) で定義される。

$$\|\mathbf{x} - \mathbf{m}_c\| = \min \|\mathbf{x} - \mathbf{m}_i\| \quad (6.1)$$

この式で求められた参照ベクトル $\mathbf{m}_c(t)$ を持つユニット

を勝者ユニットという。次に、この勝者ユニットを中心とする近傍範囲に存在するユニットに含まれる参照ベクトルを式6.2により学習させる。このことにより参照ベクトル群は学習が行われ、入力ベクトルに近づけられることになる。

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) + h_{ci}(t)[\mathbf{x}(t) - \mathbf{m}_i(t)] \quad (6.2)$$

ここで、関数 h_{ci} は近傍関数であり、学習の初期では近傍のサイズを大きくとり、学習が進むにしたがって単調減少させる。近傍の内側では $h_{ci} = \alpha(t)$ で、近傍の外側では $h_{ci} = 0$ である。この $\alpha(t)$ の値を学習率係数と呼び、学習が進むにしたがって単調減少させていく。学習率係数 $\alpha(t)$ は次の式 (6.3) のように表される。

$$\alpha(t) = \alpha_0 \left(1 - \frac{t}{T} \right) \quad (6.3)$$

勝者ユニットを中心とした近傍関数によって定義された近傍範囲内にあるユニットに対しては学習が行われ、近傍範囲外にあるユニットに対しては学習が行われない。競合層における自己組織化マップの参照ベクトル群は、この近傍学習によって入力ベクトル群の位相を保持していくようにマップが形成される。最終的に、競合層上のユニットが学習を経て、入力ベクトル群の位相を保持した自己組織化マップが形成される。

6.1.3. DCDAM アルゴリズム：色分布関数との統合

入力カラー画像から、あらかじめ作成した色分布関数によって得た濃淡画像の類似度マップを、その類似度に応じて6.1.2で述べた **SOM** の学習率係数を適応的に変化させるように統合を行い、目標物体の輪郭を抽出できるように実現したアルゴリズムが **DCDAM** である。

具体的には、**SOM** における学習率係数 $\alpha(t)$ に高い画素値を持つ画素に対しては積極的に反映させ、低い画素値を持つ画素に対しては消極的に反映を行わせる仕組みである。つまり、入力カラー画像に色分布関数を適用し得られる濃淡画像に含まれる画素の濃淡値に対して、式 (6.4) に示すように学習率係数 $\alpha(t)$ に画素値に応じた重みを出力する関数 $w(\mathbf{x})$ を導入し、適応的に学習率係数を変化させる方式を開発した。重み関数としては式 (6.5) に示すシグモイド関数を用いた ($\alpha = 20, \theta = 0.5$)。従来直接には適応できなかった濃淡画像に対して、このように **SOM** を直接適用して濃淡値に応じた学習をさせることで輪郭抽出を行う方式を我々は直接色分布適用方式 (**Direct Color Distribution Applying Method : DCDAM**) と呼んでいる。

$$\alpha(t) = w(x)\alpha_0 \left(1 - \frac{t}{T}\right) \quad 0 \leq w(t) \leq 1 \quad (6.4)$$

$$w(x) = \frac{1}{1 + \exp\{-\alpha(x - \theta)\}} \quad (6.5)$$

従来、**DCDAM** は対象物体が存在する領域を特定し、その領域に対して適用していた。このように領域限定された入力から、**DCDAM** を入力画像全体に適用することにより、**SOM** の競合層ユニットは類似度の高い画素が集まり、対象物体の輪郭周辺には競合層ユニットが密集することで、その密度を調べることでヒストグラム方式と同じように対象物体の位置推定ができるのではないかと期待できる。さらに、この集合は、ヒストグラム方式の問題で述べたように分布を射影する必要がないため、それにより発生した問題点を回避することができると考えられる。つまり、**DCDAM** を用いることで対象の位置に無関係な**Active Net**の初期配置を行うことができると思われる。

6.2. DCDAM によるActive Netの初期設定制御： DCDAM の新しい役割

Active Netを用いて特定の領域を抽出する場合、基本的な問題点として、画像中に複数の対象物体が存在した場合にそれぞれの対象物体を独立して抽出できない、画像端にある目標物は捕捉が難しいという2つの欠点を持つことを述べた。

そこで、ヒストグラム方式で問題となった対象物体の位置により**Active Net**の初期設定がうまくいかない問題を解決するために、我々は**DCDAM** アルゴリズムを用いて位置の影響を受けないように対象物体の位置推定を行うという新しい役割を**DCDAM** に与える。その推定結果を**Active Net**の初期設定へ適用して、入力画像中に存在する単数または複数の対象物体を**DCDAM** アルゴリズムの効果（輪郭抽出機能）により、複数の対象物体を明確に分離できる特徴を有することになり、**Active Net** は捕捉能力を向上することができる。

● DCDAM による輪郭抽出機能

DCDAM では、輪郭を抽出するために入力画像から何らかの手法を用いて領域の絞り込みを行う。さらに、その領域内には何らかの物体が存在すると仮定し、領域内の画素を学習対象の入力ベクトルとし、その限定された領域に対して**SOM** の各ユニットが学習する際に、事前に作成した色分布関数により対象となる画素の類似度に応じて**DCDAM SOM**アルゴリズムによって適応的に学習率係数を出力することで、**SOM** の競合層状に存在している各ユニットの学習の度合いが変化される。学習

の終了段階に向けて徐々に各ユニットの参照ベクトルが物体の輪郭を離散的に表すように収束していくことで抽出処理が行われていく。

すなわち、**DCDAM** は**Active Net**の持つ内部エネルギーのような自己で収縮していく機能は持たない。このような入力画像中の限定された領域を学習の対象とするのではなく、入力画像の全画素を学習の対象にして**DCDAM** を適用する。それにより、ユニットは類似度の高い画素の周辺へ集まるようになると期待できる。

● DCDAM の新しい役割への期待

（輪郭抽出から抽出候補領域の推定へ）

そこで、**DCDAM** アルゴリズムにおいては領域限定されたエリアの競合層状に存在するユニットは類似度の高い画素の周辺へ集まる性質を利用して、入力範囲を限定された領域から全画素を学習の対象として入力する。

学習を実行するとその実行結果からユニット密度を調べると密度が高い所は対象物体の周辺であるということが期待でき、対象物体の位置推定が可能となる方式を開発した。

この方式は、入力画像に対して領域絞り込みを行い、その絞り込まれた領域に対して**DCDAM** を実行して輪郭抽出とする処理のかわりに、入力画像に絞り込みを行わずに画像全体を入力画像として**DCDAM** アルゴリズムを実行する。その結果、入力画像中の濃淡値が高い場所に**SOM** のユニットが集まるため、それに基づき、密度の高い場所をターゲットが存在すると期待される特定の領域と見なして、**Active Net**を配置する位置・大きさについて初期設定が可能となる。この方式が**DCDAM** の新しい役割の特徴である。このことから、この方式を**All-Image DCDAM**と名付け、この特徴を使用して**Active Net**の捕捉性能向上を目指す手法について検討を行った。次で検討したアルゴリズムの詳細を述べる。

6.3. All-Image DCDAMアルゴリズム

本節では、提案手法である**All-Image DCDAM**アルゴリズムについて具体的に述べる。まず、図28に提案手法の処理手順を示す。この図に従い説明を行う。

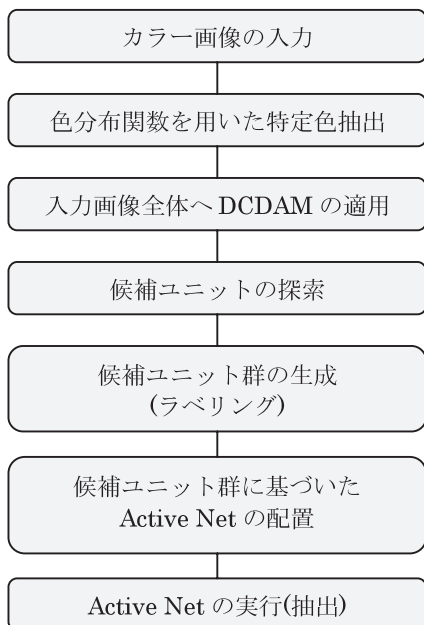


図28 . All-Image DCDAMアルゴリズム
Figure 28. All-Image DCDAM Algorithm

● カラー画像の入力と色分布関数による特定色抽出

図29 (a) に入力画像の例を示し、色分布関数を用いて図29 (a) から赤色を抽出した結果を図29 (b) に示す。

● 入力画像全体へのDCDAMの適用

次に、図29 (b) に対してDCDAMを画像全体に実行する。その結果を図30に示す。図30に示すように、DCDAMの実行結果において線が交わっている箇所がそれぞれのユニットを表す。このように画面全体にユニットが入力ベクトル群である画像中の各画素の順序を保ったまま配置され、類似度が高く出力されている画素周辺にユニットが集中していることを示している。



図29 . カラー入力画像 (a) と色分布関数による特定色抽出結果 (b)
Figure 29. (a) color input image (b) extraction result by color distribution function (red)




図30 . DCDAMの適用結果
Figure 30. Applied result of DCDAM

● 候補ユニットの探索

次に、これらの学習済ユニット u_n にそれぞれ半径 r ピクセルの円形状である探索領域を与える。図30の一部を拡大し、探索領域について図示したものを図31に示す。図31に示す探索領域内で、それぞれのユニットはあるしきい値 t を超えるユニットが存在しているかのチェックを行う。

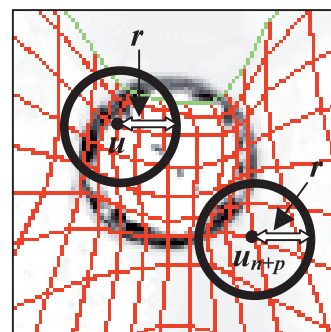


図31 . ユニットの探索領域を視覚化した図
Figure 31. Image of search region of each unit

● 候補ユニット群の生成 (ラベリング)

それらのユニットに対して候補ユニットのラベリングを行う。具体的には、探索領域としきい値の値と目標物体の大きさによっては1つの目標物体付近で複数の候補ユニットが選出される可能性が考えられる。この場合、あるユニット u_n が条件を満たしているユニットとすると、その最隣接近傍であるユニットが同様に条件を満たしている場合、 u_n とそのユニットとを1つの候補集合として取り扱う。同じ手順で条件を満たしている最隣接のユニット同士を結合していくことによって、文献 [14] の手法で発生しうる問題を回避することができる。ラベリング結果を図32に示す。




図32 . All-Image DCDAM実行結果
Figure 32. Execution result of All-Image DCDAM

図32に示した格子点間に描かれたユニットのうち、大きく描写されているものが1つの候補ユニット集合としてラベリングされた候補ユニットを結合する線である。

● Active Netの配置

そして、生成された候補ユニット群の情報を利用して**Active Net**の配置を行う。**Active Net**の大きさは最低でもラベリングされたユニットの集合全体が持つ探索領域を全て覆うように配置される。本研究ではさらに上下左右ともに10ピクセルずつの余裕を持たせている。これは、前述したように自己組織化マップの近傍学習によって、類似度の高い画素周辺に存在するユニットがある程度集まり、条件を満たすユニットが対象物体の外側に発生するため、候補ユニット集合の探索領域を全て覆うように**Active Net**が配置されることで目標物体を**Active Net**の中に取り込んでいると考えられるためである。

図33に図32で示した候補ユニット群の情報に基づいて**Active Net**の配置を行った結果を示す。

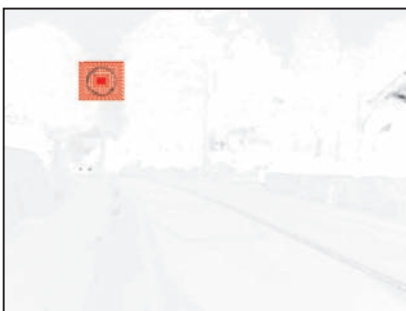


図33 . 候補ユニット群に基づいて配置されたActive Net
Figure 33. Arranged Active Net by candidate unit group

● Active Netの実行

提案手法**All-Image DCDAM**により生成された候補ユニット群の数だけ**Active Net**は前項で述べたルールに基づき配置される。そして、配置された全ての**Active Net**

の実行を行う。反復回数は、予備実験より50回と固定して実行している。図34に、図33にて示した配置済**Active Net**を実行した結果を示す。

6.4 . 実環境の情景画像を用いた実験

本実験では、入力画像は640×480ピクセルの道路標識を含む実環境にて撮影した情景画像を用いて行った。また、予備実験の結果より $r=15, t=7$ とした。また、使用する**SOM**のユニット数は25×20とし、学習回数は55,000回とし、初期近傍範囲は7、学習率係数は1とした。



図34 . 配置されたActive Netを実行した結果
Figure 34. Execution result of arranged Active Net

次に、色分布関数を用いて特定色抽出を行った。その結果得られた画像に対して**All-Image DCDAM**を実行し、その結果に対して、上述したように位置・大きさを提案手法によって設定した**Active Net**を配置して推定された領域の詳細な輪郭抽出を行った結果を図35に示す。図35において、それぞれ入力画像を**A,B,C**とし、

a. 色分布関数により特定色抽出を行った結果

b. 提案手法**All-Image DCDAM**の実行結果

c. **All-Image DCDAM**の実行結果を**Active Net**の初期設定とし、抽出を行った結果

をそれぞれ示している。なお、入力画像**A,B**に対しては赤色色分布関数を適用し、入力画像**C**に対しては黄色色分布関数を適用している。

実験結果から、対象の数が1つまたは2つある場合、対象物体の形状が異なる入力画像に適用しても提案手法によって正しい推定結果を得ることができ、その結果を基に**Active Net**の位置・形状を設定し、それぞれ目標物体を正しく抽出することができていることが分かる。

次に、研究1で検討したヒストグラム方式により失敗する例に対して研究2で検討した手法を適用した結果を図36に示す。なお、ヒストグラム方式の各パラメータは5章で述べたものと同一である。

図36 (a) から理解できるように、ヒストグラム方式は

2つの対象に対して1つのみの推定結果を出力している。すなわち、1つのみの**Active Net**を用いる場合、マルチネット方式で発生した問題と同様の1つのネット内に複数の抽出対象が存在するという問題が発生している。しかし、研究2で提案した手法で目標物体の位置推定を行い、その結果を用いて**Active Net**による目標物体の抽出においては正しく2つの対象それぞれを独立に正しく抽出できていることが理解できる。

さらに、文献^[14]の手法においても、図35に示すような入力画像においては複数の放射線が1つの目標物体にかかると考えられる。この状態では複数の放射線に存在する格子点の速度が低下することが予想でき、1つの目標物体に対して複数の推定結果を出してしまう可能性があり、従来手法は有効的とは言いがたい。また、マルチネット方式においても図35 (B-a) のような抽出対象同士が近く隣り合う入力画像の場合、抽出が難しい。これは、図26に示した通りである。

実験の平均時間は2.8 GHzのCPU, 2 GBのRAMを実装した計算機において、画像入力から**Active Net**の演算終了までを1つの処理単位とし、およそ50秒前後と

なった。

6.5. 研究2：DCDAMを用いた手法のまとめと残された課題

研究2では**Active Net**を用いる抽出手法において画像中の端に対象物体が存在していた場合、さらに複数物体の抽出において対象物体の位置・数を定義することが難しい場合も対処できる手法**All-Image DCDAM**を提案した。**Active Net**で従来問題となるような適当な位置・大きさの物体に対して、**DCDAM**を適用して対象物体の抽出を試みた。

実画像を用いたシミュレーション実験を行い、従来手法では抽出が困難な場合においても提案手法では正しく抽出を行うことができることを示した。実験結果より、提案手法を用いて**Active Net**の初期設定制御を行うことで、従来指摘されていた問題点を解決できるものである。

課題としては、抽出対象同士がごく狭い間隔で隣接していた場合、ラベリング処理により複数の抽出対象が1つとしてまとめられていた場合が見受けられた。

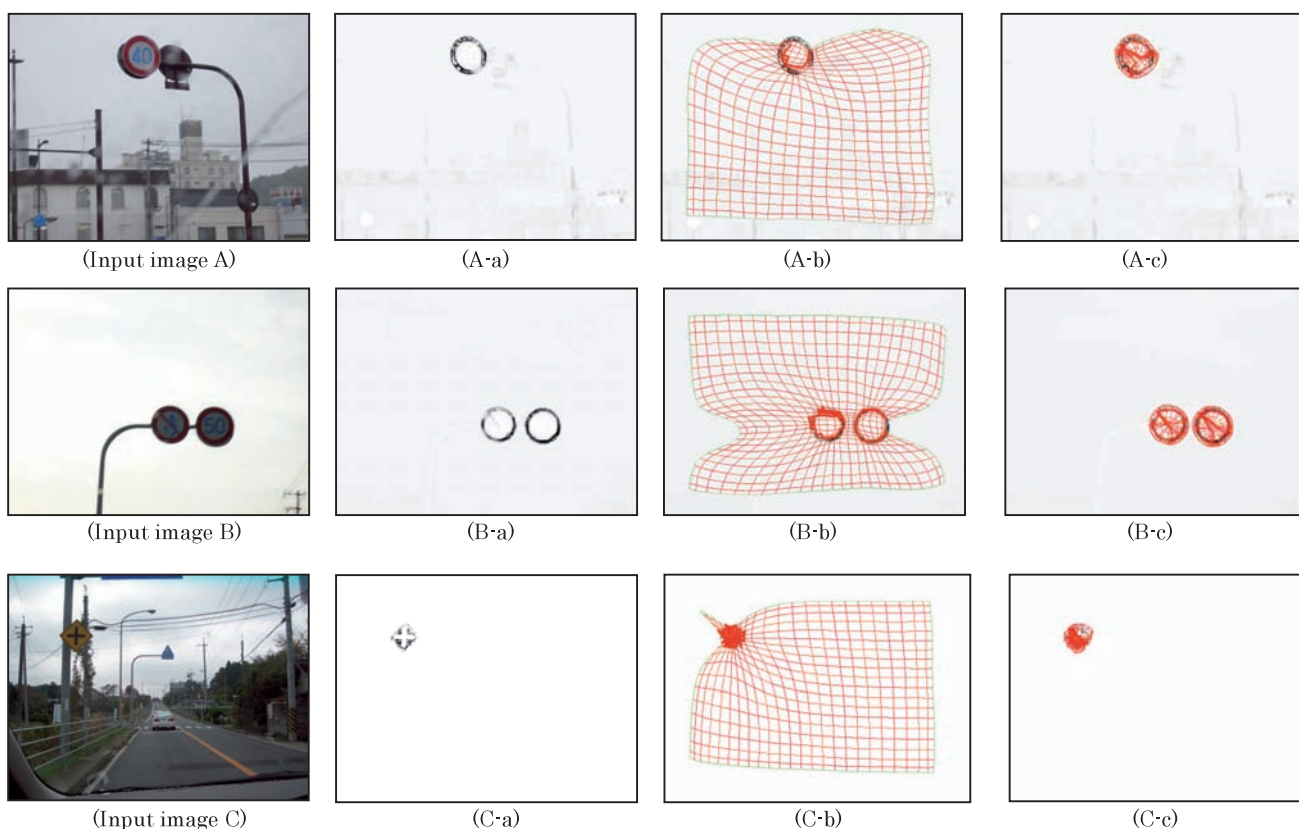
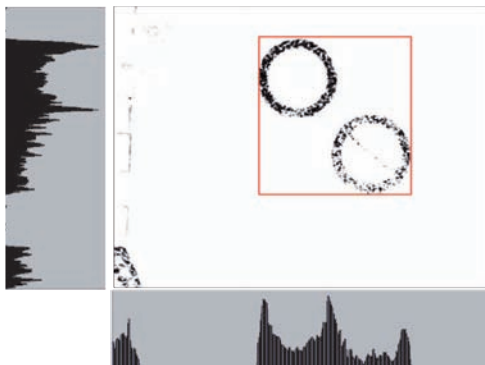



図35. 提案手法による位置推定結果とその結果により設定されたActive Netによる抽出結果
Figure 35. Results of All-Image DCDAM and Active Net execution results



(a) ヒストグラム方式による推定結果



(b) 研究2の手法による推定結果と抽出結果

図36. ヒストグラム方式の特定結果 (a) と研究2の手法による実行結果 (b)
Figure 36. Estimation by Histogram (a) and execution result of study No.2 (b)

7. 研究3 : All-Image BL-DCDAMを用いた方式

研究2のまとめで述べたように、**Active Net**の初期配置に関して **DCDAM** を用いて目標物体候補の位置を推定する方式を開発した。この方式において対象物体同士がごく狭い間隔で隣接していた場合、ラベリング処理により複数の抽出対象が1つとしてまとめられていた場合が見受けられた。

研究3では、**All-Image DCDAM**において用いた **DCDAM** の学習アルゴリズムを改良して提案された **BL-DCDAM** を用いる手法を検討した。

これにより、各ユニットは1つの対象付近に存在する座標値の平均を学習するため、隣接している他の対象を表す座標に影響を受けずに学習できるのではないかと思われる。

7.1. DCDAM の問題点

研究3では、さらに **DCDAM** へバッチ学習型 **SOM** アルゴリズムを用いた **BL-DCDAM**^[21]を導入して実験を

行った結果^[28]について述べる。

この研究3の目的は、**DCDAM** において学習アルゴリズムは逐次学習型 **SOM** アルゴリズムを採用していたため、学習結果が入力ベクトルの提示順序に依存する問題点を有していた。また、逐次学習型 **SOM** アルゴリズムに存在する学習率係数も提示順序により学習結果が変化することに影響を与えている。学習率係数は学習初期段階において大きくとり、学習終期段階に近づくにつれ小さくなる。つまり学習率係数も、入力ベクトルの提示順序による学習結果の変化に影響を与えてしまっている。

この問題を解決するために提案されている学習アルゴリズムがバッチ学習型 **SOM** アルゴリズムであり、その学習アルゴリズムを採用した手法が **BL-DCDAM** である。バッチ学習型 **SOM** アルゴリズムは、参照ベクトルの学習(更新)を一括して行うことで入力ベクトルの提示順序に対する依存性を排除している。また、学習率係数も存在していない。そこで、本研究においても **BL-DCDAM** を用いることでさらなる対象候補推定率の改善が狙えると考え、研究2で用いた **DCDAM** を **BL-DCDAM** に置換して実験を行った。

7.2. BL-DCDAM とは

DCDAM は、**SOM** を用いて、輪郭抽出手法を濃淡画像に適用できるように、具体的には、**SOM** アルゴリズムにおける学習率係数に着目して適応的に変化させる方式を検討した方式である。しかし、バッチ学習型 **SOM** アルゴリズムにおいては既に説明したように学習率係数が存在しないため、そのまま座標値を入力したのでは **SOM** が輪郭線を表すような学習結果となることがない。そのため、我々はバッチ学習型 **SOM** アルゴリズムによって輪郭抽出を実現するために開発した手法が **BL-DCDAM** である。

DCDAM で輪郭を抽出する場合に、**SOM** の学習率係数について、学習率係数は最初に大きく値を取り、次第に小さくしているものを持っている。このような入力ベクトルの提示順序に依存しないということで、**DCDAM** にバッチ学習型 **SOM** アルゴリズムを導入する。これにより、入力ベクトルの提示順序に依存することがなく入力ベクトルごとに学習の度合いを変化させることが可能となる。次よりその方式について具体的に説明を行う。

- バッチ学習型 **SOM** アルゴリズムでの濃淡値反映型重み関数の導入
BL-DCDAM 実現の最も重要なポイントとしてバッチ

学習型 **SOM** 型アルゴリズムには学習率係数が存在しないという特徴がある。そこで、バッチ学習型での参照ベクトルを更新する場合に平均ベクトルと呼ばれるある入力ベクトルと類似した入力ベクトル群の平均値をユニットが学習する段階で、その平均ベクトル値が表す座標が持つ濃淡値に応じた重み関数を導入するような式 (8.1) を導入することで我々は **BL-DCDAM** アルゴリズムを実現している。

$$m_c(t+1) = \frac{1}{\sum_{x_i \in N_c(t)} w(x_i)} \sum_{x_i \in N_c(t)} w(x_i)(i, j) \quad (8.1)$$

また、重み関数 $w(x)$ には本論文では式 (8.2) に示すシグモイド関数 ($\alpha=20, \theta=0.25$) を用いて実験を行った。

$$w(x) = \frac{1}{1 + \exp\{-\alpha(x - \theta)\}} \quad (8.2)$$

7.3 . All-Image BL-DCDAM

本研究においても、**DCDAM** の問題点として挙げたようなことが懸念点となる可能性がある。

つまり、**DCDAM** で発生した提示順序に関する問題が同様に発生する可能性があるため、**BL-DCDAM** の導入は本研究においても効果的であると考えられる。

効果としては、**BL-DCDAM** を用いたとき、各ユニットは1つの対象付近に存在する座標値の平均を学習するため、隣接している他の対象を表す座標に影響を受けずに学習できるので、**DCDAM** で問題点であった対象同士が非常に近く隣接した場合にそれを1つの候補ユニット群として生成していたような場合を回避することができると思われる。

まず、カラー画像から特定色抽出を行った濃淡画像に対して **BL-DCDAM** を用いて学習を行う。その後、6.3で述べたように候補領域を推定していく手法は6.3で述べたアルゴリズムと同一であるため、6.3を参照されたい。

7.4 . 実環境の情景画像を用いた実験

本実験では、入力画像は640×480ピクセルの道路標識を含む実環境にて撮影した情景画像を用いて行った。また、予備実験の結果より $r=15, t$ は画像ごとに探索領域内に存在するユニット数の最大値から上位5位までを含むしきい値とした。また、使用する **SOM** のユニット数は25×20とし、学習回数は75回とし、初期近傍範囲は7、学習率係数は1とした。

● All-Image BL-DCDAMの実験結果

次に、色分布関数を用いて特定色抽出を行った。その結果得られた画像に対して **All-Image BL-DCDAM** を実

行し、その結果に対して、上述したように位置・大きさを提案手法によって設定した **Active Net** を配置して推定された領域の詳細な輪郭抽出を行った結果を図37に示す。図37において、それぞれ入力画像を **A, B** として、提案手法を適用した結果を基に **Active Net** を配置し、抽出した結果をそれぞれ示している。なお、入力画像 **A, B** に対しては赤色色分布関数を適用したものである。

実験結果から、入力画像 (a), (b) において目標となる道路標識を正しく独立して抽出することができていることが理解できる。また、一部道路標識以外の物体を抽出しているが、これは認識処理において容易に除外することが可能である。

● All-Image DCDAMとAll-Image BL-DCDAMの比較評価

All-Image DCDAM と **All-Image BL-DCDAM** の比較を行う。図38に図37入力画像 (b) に対して **All-Image DCDAM** を実行し、その結果に基づいて **Active Net** による抽出処理を行った結果を示す。図38から分かるように、2つある対称物体のうち緑色の円で囲んだ対称物体について候補ユニットの選定が失敗し、**Active Net** の配置が正しく行われなかったため抽出に失敗していることが理解できる。

しかし、既に図37に示したように入力画像 (b) に対して **All-Image BL-DCDAM** を適用した場合においては正しく抽出することが示していることから、本研究においての **All-Image BL-DCDAM** の効果は **All-Image DCDAM** と比較して良好な結果を得ることができた。

7.5 . 研究3のまとめ

実験結果より、研究2で用いた **All-Image DCDAM** を **All-Image BL-DCDAM** とすることで本研究においても候補領域の推定率が上がることを確認できた。また、**BL-DCDAM** はバッチ学習型 **SOM** アルゴリズムに基づいているため、1で述べた課題2について実現するため、バッチ学習型 **SOM** アルゴリズムを学習アルゴリズムとした **SOM** をハードウェアで構築することで大幅な高速化を実現している文献^[24]の導入が可能となり、実時間処理の達成を行うことができる。

8 . おわりに

本論文では **Active Net** の抽出成功率改善に関する研究について、従来までに行われた研究についてを概観し、その問題点と解決へ向けて検討した手法について述べた。具体的には、(1)ヒストグラムを用いた方式 (2) **All-Image DCDAM** (3) **All-Image BL-DCDAM** を用いた方

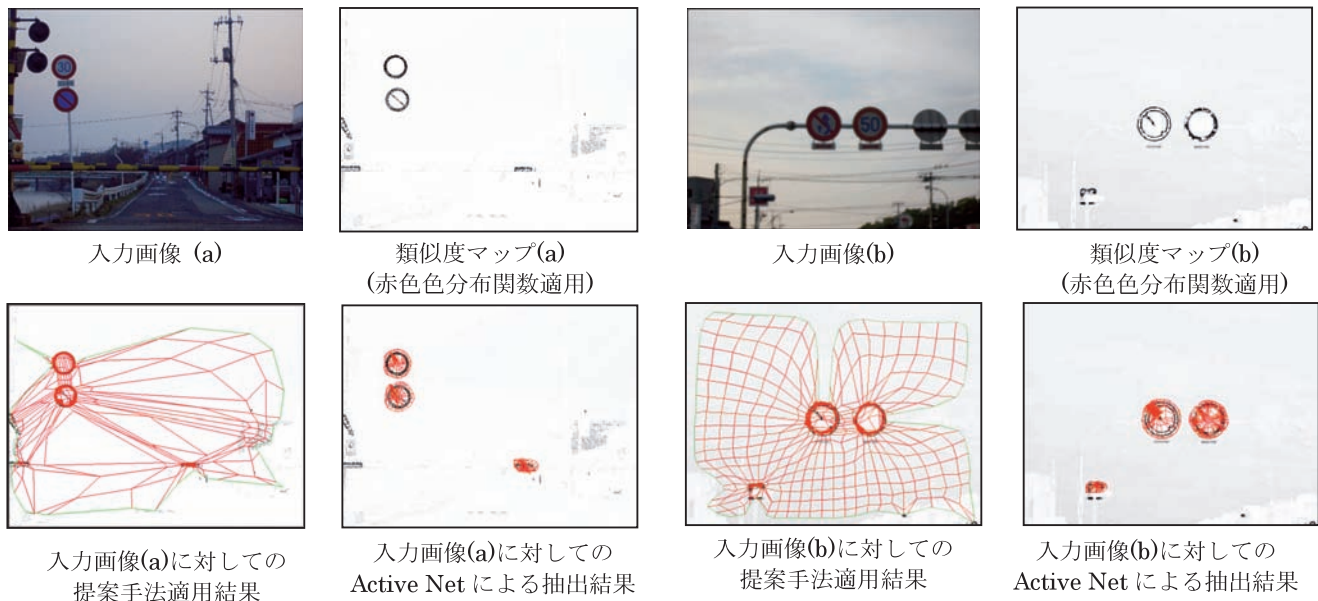


図37 . 実験結果

Figure 37. Results of All-Image BL-DCDAM and Active Net execution results

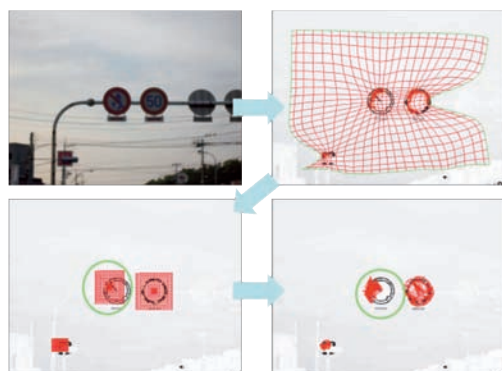


図38 . All-Image DCDAMによる実験結果

Figure 38. Experimental result by All-Image DCDAM

式の検討を行った。さらに(3)の方式においては道路標識認識への応用など高速処理が要求される場合でもSOMハードウェアを用いることで実現可能であることを述べた。

実験の結果から、これまで検討してきた3つの手法を用いて確実にActive Netの抽出成功率が向上することを確認した。

今後の課題として、この3種類の手法をそれぞれの特徴を活かして、どのように選択して使用していくと効率が良くなるかを検討していく予定である。

参考文献

[1] 赤松茂, “コンピュータによる顔認識 - サーベイ”, 信学論, Vol. J-80-D-II, No.8, pp.2031-2046, 1997.

[2] 佐藤和人, 石井雅樹, 間所洋和, “院内巡回ロボットの開発と評価実験”, 信学論, Vol.84-D-I, No.6, pp. 855-866, 2001.

[3] 山内仁, 小島篤博, 宮本貴朗, 高橋浩光, 福永邦雄, “連続フレームからの抽出画像の重ね合わせによるロバストな道路標識認識手法”, 信学論, Vol. 90-D, No.2, pp.494-502, 2007.

[4] 村木茂, 喜多泰代, “3次元画像解析とグラフィックス技術の医学応用に関するサーベイ”, 信学論, Vol.J87-D-II, No.10, pp.1887-1920, 2004.

[5] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes: active contour models," IJCV, Vol.1, No.4, pp.321-331, 1988.

[6] 坂上勝彦, 山本和彦, “動的な網のモデルActive Netとその領域抽出への応用”, テレビジョン学会誌, vol. 45, No.10, pp.1155-1163, 1991.

[7] 大橋剛介, 大矢晃久, 名取道也, 中島真人, “超音波エコー画像の3次元表示のためのニューラルネットワークを用いた輪郭抽出法”, 信学論, Vol.J76-D-II, No.2, pp.368-373, 1993.

[8] 鈴木賢治, 堀場勇夫, 杉江昇, 南木道生, “ニューラルエッジ検出器を利用したDSAにおける左心室の輪郭抽出”, 信学論, Vol.J83-D-II, No.10, pp.2017-2029, 2000.

[9] P.Doucette, P.Agouris, A.Stefanidis, and M. Musavi, "Self-organized clustering for road extraction in classified imagery", ISPRS Journal of Photogrammetry & Remote Sensing 55 pp.347-358, 2001.

- [10] Y. V. Venkatesh, S. Kumar Raja, N. Ramya, "Multiple Contour Extraction From Graylevel Images Using an Artificial Neural Network," IEEE Trans. on Image Processing, Vol. 15, No. 4, 2006.
- [11] H. Shah-Hosseini, R. Safabakhsh, "A TASOM-based algorithm for active contour modeling," Pattern Recognition, Vol. 33, pp. 1239-1250, 2000.
- [12] Fukuya Namba, Yasuaki Sumi, Takuya Ueta, Noboru Yabuki, Takao Tsukutani, "A Study on Road Sign Recognition Using Active Net," The 22nd ITC-CSCC2007 Proceedings, Vol.1, pp. 267-268, 2007.
- [13] 松田喜貴、藪木登、片岡大、鷺見育亮、副井裕、三木成彦、“従来の動的なネットモデルを改良した新しいネットモデルの提案”、信学技報 PRMU99-212, pp.61-68, 2000.
- [14] Y. Matsuda, Y. Sumi, D. Kataoka, M. Ota, N. Yabuki, Y. Fukui, S. Miki, "Proposal for a Convergence Criterion to the Active Net in Two Steps," ISCAS2000, pp.V313-V316, Geneva, Switzerland, 2000.
- [15] 野田尚志、藪木登、鷺見育亮、松前進、福本善洋、植田拓也、副井裕、“動的なネットモデルのマルチ方式化に関する検討”、第17回 回路とシステム軽井沢ワークショップ論文集、pp.171-175, 2004.
- [16] 藪木登、鷺見育亮、難波福弥、築谷隆雄、“動的なネットモデルのマルチネット方式化”、電気学会論文誌C、掲載決定。
- [17] 船山竜士、横矢直和、岩佐英彦、竹村治雄：“複数の動的な網のモデルの協調とその顔部品抽出への応用”、電子情報通信学会技術研究報告、PRU95-179, 1995.
- [18] S. Osher and J. A. Sethian, "Fronts propagating with curvature dependent speed: Algorithm based on Hamilton-Jacobi formation," Journal of Comp. Physics, vol.79, pp.12-49, 1988.
- [19] T.Kohonen, “自己組織化マップ”, Springer, 2005.
- [20] 藪木登、三木成彦、鷺見育亮、副井裕、“道路情景画像における交通標識の認識に関する検討”、信学技報 CAS2002-129, pp.27-32, 2003.
- [21] 植田拓也、鷺見育亮、難波福弥、藪木登、松前進、福本善洋、築谷隆雄、“SOMによる濃淡画像に対応した輪郭線抽出処理の検討”、第20回 回路とシステム軽井沢ワークショップ論文集 pp.247-252, 2007.
- [22] 植田拓也、鷺見育亮、難波福弥、藪木登、築谷隆雄、“自己組織化マップを用いた輪郭抽出手法 BL-DCDAM の提案”、第20回 回路とシステム軽井沢ワークショップ論文集 pp.247-252, 2008.
- [23] F. Namba, Y. Sumi, T. Ueta, N. Yabuki, T. Tsukutani, "A Study on Improvement Extraction Stability of Active net Using All-Image BL-DCDAM Introduced BL-DCDAM," The 23rd ITC-CSCC2008, pp.477-480, Yamaguchi, Japan, 2008.
- [24] 金子宗司、田向権、田中利康、徳永憲洋、古川徹生、“自己組織化マップをもとにした新しい脳型ハードウェアの開発：SOM2のFPGA化”、第20回 回路とシステム軽井沢ワークショップ論文集 pp.517-522, 2007.
- [25] 吉野和芳、真木みお、川嶋稔夫、“分裂アクティブネットを用いた色情報による領域抽出”、北海道大学工学部研究報告、No.167, pp.87-96, 1994.

(2009年1月8日受理)