

反応・拡散モデルによる群化過程の実現

野村 厚志[†] 一川 誠^{††} 三池 秀敏^{††}

視覚システムにおいて、特徴量の類似した近接領域が結合してより大きな領域として知覚されることが知られている。これを群化と呼び、領域が結合していく過程を群化過程と呼ぶ。群化過程は他の様々な視覚機能の基となる機能であり、視覚システムのモデル化の研究において群化過程のモデルの実現は意義深い。本研究では、反応・拡散モデルを用いた群化過程のモデルを提案する。基礎となるモデルは、生理学実験から導かれた神経軸索における信号伝播の様子を記述するミクロなモデルである FitzHugh-Nagumo 型の 2 変数反応・拡散モデルである。それら 2 変数はそれぞれ活性化因子・抑制性因子と呼ばれる。また、特徴量として微小線分の方向を扱い、1 組の反応・拡散モデルを 1 つの特徴量 (1 方向) に対応付ける。複数の特徴量を扱うために複数組の反応・拡散モデルを導入する。提案モデルには、特徴量の類似した近接領域を結合しようとするメカニズムと、異なる特徴量を持つ領域間 (すなわち複数組の反応・拡散モデル間) で相互に領域の結合を抑制しあう相互抑制のメカニズムが組み込まれている。さらに、反応・拡散モデルの抑制性因子の拡散係数を活性化因子のそれよりも大きくすることで、自己抑制のメカニズムも導入されている。提案モデルをテスト画像に対して適用し、有効性を定量的に確認した。また、モデルパラメータの設定値が群化過程に及ぼす影響についても検討した。

Realizing the Grouping Process with the Reaction-diffusion Model

ATSUSHI NOMURA,[†] MAKOTO ICHIKAWA^{††} and HIDETOSHI MIIKE^{††}

The human visual system has the function which groups the regions that are filled with similar features. The function is the underlying mechanism in the human visual system. The present paper proposes a computational model realizing the grouping process of the visual system. The proposed model utilizes a reaction-diffusion model consisting of activator and inhibitor variables. The reaction-diffusion model utilized here is a modified version of the FitzHugh-Nagumo model, which was derived from physiological experiments. A set of the reaction-diffusion model governs one feature. Thus, multi sets of reaction-diffusion models are utilized. A particular reaction-diffusion model has two mechanisms, one of which merges neighbouring regions having similar features and the other of which inhibits other regions having different features from growing. In addition, the model also has the mechanism inhibiting self-growing process. This mechanism is caused by the condition that the diffusion coefficient on the inhibitor variable is larger than that on the activator variable. The performance of the proposed model is confirmed through analysis of several test images. The proposed model has several parameters. Thus, the influence of the model parameters on results of the grouping process is also confirmed.

1. はじめに

異なる特徴量を持つ小パターンで埋められた複数の領域からなる画像を人間の視覚システムに提示したとき、類似パターンの領域は結合され、異なるパターンの領域は分離して知覚される。類似の特徴量を持つ近接領域がより大きな領域として結合されて知覚されることを群化と呼び、その過程を群化過程と呼ぶ¹⁾。例

として、微小線分パターンで埋められた画像を考える。ここで、線分の方向を特徴とし、その方向の具体的な値を特徴量とする。複数の領域においてその線分の方向が異なっている。このとき、線分の方向が同じで、なおかつ隣接領域のものはより大きな領域として結合して知覚される。このような群化は、方向だけでなく、明るさや色など、様々な特徴に対して観測されることが知られている²⁾。また、人間の視覚システムは、様々な機能の視覚モジュールから構成されていると考えられている。したがって、この例に対しては、最初に方向検出モジュールにおいて微小線分の方向が特徴量として検出され、その結果が、群化過程のモジュール

[†] 山口大学教育学部

Faculty of Education, Yamaguchi University

^{††} 山口大学工学部

Faculty of Engineering, Yamaguchi University

ルに送られ、群化が引き起こされると考えることができる。また、他の特徴に対しても、それぞれの特徴検出モジュールからの出力が群化過程のモジュールに送られ、そこで群化されるものと考えられる。群化は視覚システムの様々な機能：ステレオ視・オプティカルフロー検出、テクスチャ分離・領域分割、視覚探索・ポップアウトに関与し、重要な役割を果たしているとも考えられている。

著者らは、生物のミクロな仕組みを用いて、視覚機能やシステムを実現することを目指している。Hodgkinらは生理学実験により生物の神経軸索における信号伝播の様子を記述するミクロなモデルを導いた³⁾。このモデルの定性的な性質を模倣するモデルとして、FitzHughやNagumoらは2変数の反応・拡散モデルを提案した^{4),5)}。このモデルはFitzHugh-Nagumo (FHN) モデルと呼ばれている。著者らは、FHNモデルを用いて、2値画像を対象としたエッジ検出と領域分割を行うモデルを提案した⁶⁾。また、ランダムドットステレオグラムを0と1のドットからなる2値画像と考えたとき、論理演算を用いることでステレオ対応問題が領域分割問題となる⁷⁾。これに対して、FHNモデルによる領域分割モデルを適用することで、ランダムドットステレオグラムにおける視差検出のモデルを提案した⁸⁾。それぞれの視覚モジュールを反応・拡散モデルを用いて実現し、最終的にはモジュールを結合させることによって、視覚システムを構築する試みを進めている。反応・拡散モデルのみを用いることによって、様々な視覚機能を実現することが可能となれば、視覚工学における画像処理チップなどのハードウェア化においても意義あるものと考えられる^{9),10)}。

本研究では、視覚システムの基礎をなす群化過程のモジュールを、生物学的な動機付けから、反応・拡散モデルを用いて実現することを目的とする。ここでは、いくつかの異なる方向を持つ微小線分で埋めつくされた画像を対象とする。これに対して、微小線分の方角を検出するモジュールを適用し、その結果に対して、領域が分離して検出されるような群化のモデルを提案する。この問題に対して、すでに著者らが提案している2値画像を対象とした反応・拡散モデルに基づく領域分割モデルでは⁶⁾、2つの特徴量しか扱うことができず不十分であった。ここでは、新たに複数組の反応・拡散モデルを準備し、それぞれの反応・拡散モデルで1つの特徴量に対応させる。そのとき、複数組の反応・拡散モデルの間で、相互に抑制しあうメカニズムを新たに導入する。この相互抑制のメカニズムと、元々の反応・拡散モデルが持つ自己抑制のメカニズムによっ

て、群化過程のモデルを実現する。提案モデルをテスト画像に対して適用し、その有効性を確認する。

2. 反応・拡散モデル

2変数 (u, v) 反応・拡散モデルの一般形は次式で表される。

$$\begin{aligned}\frac{\partial u}{\partial t} &= D_u \Delta u + \frac{1}{\varepsilon} f(u, v) \\ \frac{\partial v}{\partial t} &= D_v \Delta v + g(u, v)\end{aligned}\quad (1)$$

ここで、右辺第1項が拡散を表し、 D_u 、 D_v はその拡散係数である。 u 、 v は時間・空間に関する関数であり、特に2次元空間と時間の関数： $u = u(x, y, t)$ 、 $v = v(x, y, t)$ であるとき、空間 (x, y) に関する演算子 Δ は $\Delta = \partial^2/\partial x^2 + \partial^2/\partial y^2$ を表す。また、右辺第2項の $f(u, v)$ 、 $g(u, v)$ は反応項と呼ばれ、 ε は定数 ($0 < \varepsilon \ll 1$)である。反応・拡散モデルの一種として、生物の神経軸索における信号の伝播の様子を記述するFitzHugh-Nagumo (FHN) モデルが知られている^{4),5)}。FHNモデルにおいて、反応項は次式で記述される。

$$\begin{aligned}f(u, v) &= u(1-u)(u-a) - v \\ g(u, v) &= u - bv\end{aligned}\quad (2)$$

ここで a 、 b は定数である ($0 < a < 0.5$ 、 $b > 0$)。反応・拡散システムは、式(2)のような反応現象が拡散過程に従って空間的に伝播するシステムである。これは、 u 、 v の2層からなるネットワークモデルと考えることもできる。

ここで拡散項を無視し ($D_u = D_v = 0$)、反応項のみを考慮したより単純な常微分方程式からなるシステムを考え、そのときの解 (u, v) の振舞いについて考察する。変数 (u, v) の振舞いの概略は、図1のような相図によって知ることができる。図1において、点A、B、Cの3点は $f(u, v) = 0$ かつ $g(u, v) = 0$ の条件を満たす平衡解である。そのうちの2点A、Cが安定な平衡解である(双安定システム)。双安定システムにおいて初期解を $(u, v) = (u_0, 0)$ とし、 u_0 を変化させたとき、 $u_0 < a$ において解は安定点Aに収束し、 $u_0 > a$ においては安定点Cに収束する。したがって、パラメータ a は初期解 $(u_0, 0)$ をA、Cのどちらか一方の状態に分ける閾値の役割を持つ。また、変数 u が増加し $u > a$ となると、システムの状態は急激に興奮状態 ($u \simeq 1$)へと変化するので、 u は活性化因子と呼ばれる。一方、 v の値が大きくなるとシステムの興奮が妨げられる、あるいは、興奮状態から休止状態(安定平衡解Aに収束している状態)への変化が促されるので、 v は抑制性因子と呼ばれる。以

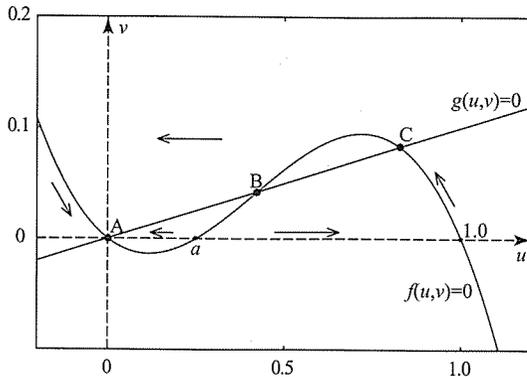


図1 FitzHugh-Nagumo モデルの常微分方程式系 $du/dt = f(u,v)/\epsilon$, $dv/dt = g(u,v)$ における解の振舞いを説明する相図 [関数 $f(u,v)$, $g(u,v)$ については式 (2) を参照]. 横軸が u , 縦軸が v を表す. パラメータは $a = 0.25$, $b = 10$ とした. $f(u,v) = 0$, $g(u,v) = 0$ となる平衡点 A, B, C のうち, 点 A, C は安定である (双安定システム). 解 (u,v) は時間とともに矢印に沿って変化する

Fig. 1 Phase plot illustrating the solution behaviour of the FitzHugh-Nagumo type ordinary differential equations $du/dt = f(u,v)/\epsilon$ and $dv/dt = g(u,v)$ [see Eq. (2) for the functions $f(u,v)$ and $g(u,v)$]. The horizontal coordinate system refers to u ; the vertical one does to v . Parameters are set to $a = 0.25$ and $b = 10$. The points A and C are stable steady states and the point B is an un-stable one. The system illustrated in this figure is bi-stable. A set of solutions (u,v) moves along the arrows as time proceeds.

上の考察は, 拡散過程を無視したモデルに対するものである.

拡散も考慮した反応・拡散モデルでは, 時空間パターンが形成されることが知られている. 神経軸索におけるパルスの伝播の様子は単安定システムにおいて形成される時空間パターンの一種である. また, システムを双安定に設定したとき, 興奮状態と休止状態の2種類の領域への分割の機能を実現することができる. ただし, 一般に分割領域の境界は静止せず, ある速度で移動する. 1次元の場合の境界の移動速度は, モデルのパラメータに依存する. たとえば, $D_u > D_v$, $0 < a < 0.5$ の条件の下で, 安定点 A を持つ領域と安定点 C を持つ領域が境界で接する場合を考えよう. これらの2つの領域は, 安定点 A の領域が安定点 C の領域となるようにそれらの境界が時間とともに移動する. このとき, 活性化因子の拡散係数 D_u が大きいほど境界の移動速度は大きくなる. また, 抑制性因子の拡散係数 D_v や定数 a を大きくすることによって, 活性化因子 u が増大するのが妨げられ, 境界の移動速度は小さくなる.

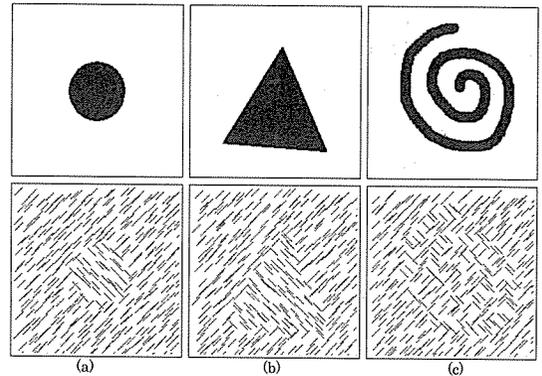


図2 群化を引き起こす画像の例. (a) 円形, (b) 三角形, (c) 渦巻きパターンの領域とその背景が分離して知覚される. それぞれ上段が設定領域, 下段が微小線分の特徴とする群化を引き起こす画像. 微小線分は, 領域ごとに異なる方向を向いている (右水平方向から反時計回りに $\pi/4$, $3\pi/4$). 画像サイズはすべて 200×200 (pixel)

Fig. 2 Test images causing the perceptual grouping. The upper row shows original group maps and the lower one does images having groups filled with short lines. Particular images have (a) circular, (b) triangular and (c) spiral patterns. Short lines locating within each pattern and those on the background are directed to different orientation directions of $\pi/4$ and $3\pi/4$ from the horizontal rightward direction in the inverse clockwise direction. The image size is 200×200 (pixel).

3. 提案モデル

3.1 群化過程

視覚システムにおいて, 異なる特徴量を持つ領域が分離して知覚される. この現象は, 特徴量が類似の領域を1つの領域として知覚する群化と呼ばれる機能によるものと考えられる²⁾. 図2に群化を引き起こす画像の例を示す. 特徴量として微小線分の方向を考えたとき, これら3種類の例では, 方向の異なる2種類の微小線分で埋めつくされている. すなわち, ある方向を持つ領域と別の方向を持つ領域とがそれぞれ群化過程によって分離して知覚される. ここでは, 特徴として線分の方向のみを考え, 反応・拡散モデルを用いた群化過程のモデルを提案する.

3.2 モデルの概略

本論文で提案する方向を特徴としたときの群化過程の概略を図3に示す. まず, 入力画像は異なる方向を検出する方向検出モジュールに送られる. 方向検出モジュールとしてはいくつか提案されているが, ここでは入力画像を2値画像と仮定して論理演算による次のような検出方法を用いる. あらかじめ方向の異なるいくつかの線分のパターンを方向検出モジュール内に保

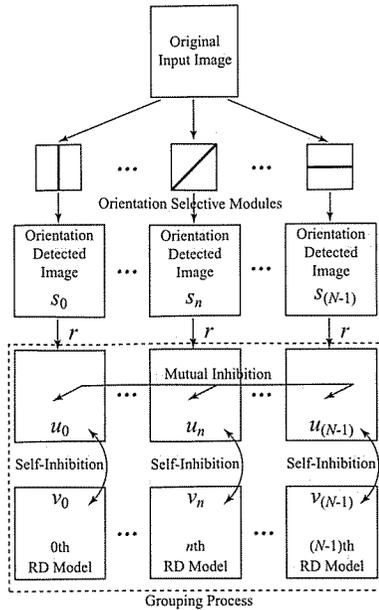


図 3 群化過程のための提案モデルのモジュール構造。まず最初に、入力画像は N 方向からなる方向検出モジュールに送られる。第 n 番目のモジュールの検出結果 s_n は、さらに r で重み付けされて、群化過程のモジュールに送られる。群化過程のモジュールは、 N 個の反応・拡散モデルから構成されており、さらにそれぞれの反応・拡散モデルは、2 変数からなる [第 n 番目のモデルは (u_n, v_n) の変数を持つ]。群化過程のモジュールは、複数の反応・拡散モデル (RD Model) 間で相互に抑制しあうメカニズムが考慮されている。また、それぞれの反応・拡散モデル内においても、自己抑制のメカニズムが組み込まれている

Fig. 3 Proposed model for the perceptual grouping. Orientation selective modules detect orientation of short lines contained in an original input image. The output s_n of the n th orientation selective module is provided to the n th reaction-diffusion (RD) model for the perceptual grouping. When the number of orientation selective modules is N , the same number of sets of the reaction-diffusion models are prepared; the particular models consist of two equations having activator and inhibitor variables u_n and v_n [$n = 0, 1, \dots, (N-1)$]. The proposed model takes account of not only a mutual inhibition mechanism among the reaction-diffusion models, but also a self-inhibition mechanism between the two equations of the particular reaction-diffusion models. [See Eq. (3), Eq. (4) and Eq. (5).]

持しておく。その線分パターンと入力画像との間で、各点において XOR 論理演算を適用する。その論理演算結果において 1 の数を数え、結果がゼロとなったとき、その画素はその方向の線分を持つものとする。また、論理演算結果において 1 の数がゼロより大の場合、その方向の線分はないものとする。入力画像が濃淡画像の場合、他の研究者や著者らによって提案されている方向検出モジュールに代えることができる^{11),12)}。

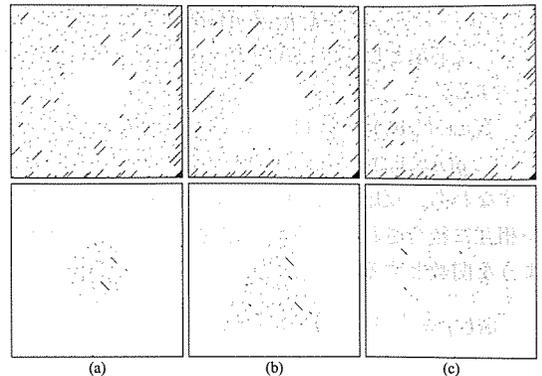


図 4 線分方向検出結果。図 2 (a), (b), (c) の方向検出結果をそれぞれ (a), (b), (c) に示している。上段は $\pi/4$ 方向の検出結果を、下段は $3\pi/4$ の方向の検出結果を表す (ただし、方向は水平右方向から反時計回り)。黒色領域・ドットがその位置にその方向の線分が存在することを表している

Fig. 4 Outputs of the orientation selective modules. The outputs (a), (b) and (c) were respectively obtained from Fig. 2 (a), (b) and (c). The upper row and the lower one are outputs of different two orientation selective modules for the orientation directions of $\pi/4$ and $3\pi/4$ from the horizontal rightward direction in the inverse clockwise direction. Black regions and dots in each output share the same orientation.

いま、 N 方向の方向検出モジュールを仮定すると、それぞれのモジュールにおいて、検出結果として 0 (その方向の線分がない)、1 (その方向の線分がある) の値からなる 2 値画像を出力する。この画像を $s_n(x, y)$ とする。たとえば、図 2 のような画像が与えられたとき ($N = 2$)、方向検出結果の 2 値画像は図 4 となる。各モジュールでそれぞれ検出結果が得られるので、2 枚の 2 値画像を得る。これらの画像が、次に提案する N 組の反応・拡散モデルからなる群化過程を実現するモジュールに送られる。

3.3 群化過程のモデル

FHN 型の反応・拡散モデルを基本とした群化過程のモデルを提案する。2 変数からなる式 (1) を 1 組のモデル式と考え、特徴量として異なる N 方向を扱う場合、 N 組の反応・拡散モデルを用いる。後の実験で示すが、2 変数の反応・拡散モデルを用いる理由は、抑制因子 v の拡散の効果が重要となるからである。いま、 N 組のモデルに番号 n ($n = 0, 1, \dots, N-1$) を付ける。このとき、第 n 番目のモデルの変数を (u_n, v_n) とし、これらを用いて次のような群化過程のモデル式を提案する。

$$\begin{aligned} \frac{\partial u_n}{\partial t} &= D_u \Delta u_n + \frac{1}{\varepsilon} f(u_n, U, v_n) + r s_n \\ \frac{\partial v_n}{\partial t} &= D_v \Delta v_n + g(u_n, v_n) \end{aligned} \quad (3)$$

ここで、 U は u_n を除いた他の組の u_m ($m = 0, 1, \dots,$

$n-1, n+1, \dots, N-1; m \neq n$ の中の最大値とする。また、反応項として、次式のような関数 $f(\cdot)$, $g(\cdot)$ を提案する。

$$\begin{aligned} f(u_n, U, v_n) &= u_n(1-u_n)(u_n-a(U)) - v_n \\ g(u_n, v_n) &= u_n - bv_n \end{aligned} \quad (4)$$

すなわち、反応項 $f(\cdot)$ の $a(U)$ を通じて、モデルが相互に結合されている。具体的には、 $a(U)$ を次のような関数とする。

$$a(U) = \frac{1}{4} \{1 + \tanh(U + a_0)\} \quad (5)$$

ここで、 a_0 は定数。また、 $U \rightarrow +\infty$ のとき $a(U) \rightarrow 0.5$, $U \rightarrow -\infty$ のとき $a(U) \rightarrow 0$ となり、式 (2) におけるパラメータ a の条件 ($0 < a < 0.5$) を満足している。

従来の FHN 型の反応項の式 (2) の定数パラメータ a に代えて、提案モデルでは関数 (5) を導入した理由を述べる。先に述べたように、パラメータ a は閾値の役割を果たし、その増大はモデルが興奮することを妨げるように働く。例として、2種類の異なる特徴量を持つ領域が接するか重なり合うような境界を考える。このとき、番号 n の組と番号 m の組のモデルに対する入力 s_n, s_m が境界付近で 1 となっているものとする。たとえば番号 m の組がその周辺において先に興奮状態 ($u_m \simeq 1$) となると、番号 n の組においては式 (5) より $a(U) \simeq 0.5$ となり、興奮状態となることが抑制される。このメカニズムによって、境界においてそれぞれの領域が広がることを相互に抑制しあっている。パラメータ a を定数とした場合 (すなわち一般的な反応・拡散モデル式 (2) を用いた場合)、モデル間での相互抑制のメカニズムが考慮されず不十分である。

最後に、時刻 t における群化過程の領域分布 $M(x, y, t)$ を求める。すなわち、各画素において、 N 個のモデルの中から、最も大きな活性化因子 u_n の値を持つモデルの番号 n を、その画素の領域の番号とする。

3.4 提案モデルの離散化と計算条件

提案したモデル式 (3) を計算機で実行するため、時空間微分を差分 $\delta x, \delta y, \delta t$ を用いて離散化する。このとき、拡散項は 5 点近似を用い、計算の安定性を考慮して Crank-Nicolson 法を用いて差分化する (文献 13) の pp.181-186 を参照)。たとえば、時刻 t , 空間 (x, y) における Δu_n の計算は、離散点 $x = i\delta x, y = j\delta y, t = k\delta t$ (i, j, k は整数) を用いて次式によって近似的に求める。

$$\Delta u_n(x, y, t) \simeq c\Delta u_n(i, j, k+1)$$

$$+(1-c)\Delta u_n(i, j, k) \quad (6)$$

ここで $c = 0.5$ 一定である。また $\Delta u_n(i, j, k)$ は次式による。

$$\begin{aligned} \Delta u_n(i, j, k) &= \frac{u_n(i+1, j, k) - 2u_n(i, j, k) + u_n(i-1, j, k)}{\delta x^2} \\ &+ \frac{u_n(i, j+1, k) - 2u_n(i, j, k) + u_n(i, j-1, k)}{\delta y^2} \end{aligned} \quad (7)$$

境界条件としては空間勾配をゼロとする Neuman 条件を課す。また、 (u_n, v_n) の初期値はゼロとする。得られた線型代数方程式に対して Gauss-Seidel 法を適用し解を推定する。この計算を繰り返すことによって提案モデルの解 (u_n, v_n) の時間発展を得ることができる。特に断らない限り、後の実験ではモデルのパラメータを $D_u = 1.0, \varepsilon = 1/100, a_0 = 0.25, b = 10, \delta x = \delta y = 0.1, \delta t = 10^{-3}$ とした。なお、パラメータ $a_0 = 0.25, b = 10$ のとき、提案モデルの反応項の式 (4) および式 (5) は、 $U = 0$ において双安定となり、 U の増大とともに単安定へと変化する。単安定モデルでは、解がすべて安定点 A に収束することとなり、よって、ある組の解が最大値となって $U \simeq 1$ となったとき、それ以外の組のモデルは単安定となり、仮に興奮状態となっても速やかに休止状態の安定点 A へと移行する。この考察は、拡散を無視した場合についてであるが、ここでも相互抑制の効果がモデルに組み込まれている。

4. 実験結果

4.1 2 領域からなるテスト画像の解析

最初に、提案モデルの基本的な妥当性を確認するため、最も簡単な 2 領域 ($N = 2$) からなる図 2 の 3 画像を解析した。群化結果を図 5 に示す。図 2 の設定領域と比較しても良好な結果を得ている。特に人間の目で確認しても分かりにくい渦巻きパターンに対する解析結果も、幅の狭い領域までほぼ良好に群化されていることが確認される。

4.2 3 領域からなるテスト画像の解析

より複雑な 3 領域 ($N = 3$) からなる画像の解析結果を示す。解析対象の画像を図 6 に示す。ここで、ローマ字の 'YU' が 5 角形パターンの上に描かれている。鋭角のパターン (ローマ字 'Y' の二股に分かれた部分) や狭い領域 (ローマ字 'U' と 5 角形パターンに囲まれた領域) の部分において群化が困難となることが予想される。テスト画像に対して、まず方向検出モジュールを適用した。結果を図 7 に示す。この方向

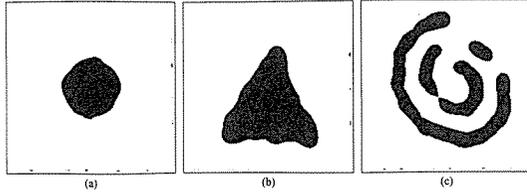


図5 2領域からなるテスト画像(図2)に対する群化モデルの適用結果。(a),(b),(c)は、それぞれテスト画像の図2(a),(b),(c)から得られた。濃淡値の違いが群化された異なる領域を表す。モデルパラメータは $D_v = 4.0$, $\alpha_0 = 0.25$, $r = 100$ に設定した。また、すべての結果は $t = 10$ において得られた

Fig. 5 Results of the perceptual grouping from the test images having two groups. Results (a), (b) and (c) were obtained respectively from Figs. 2 (a), (b) and (c). Different grey levels refer to different groups of orientation. Model parameters were set as $D_v = 4.0$, $\alpha_0 = 0.25$, $r = 100$. All of the maps were obtained at $t = 10$.

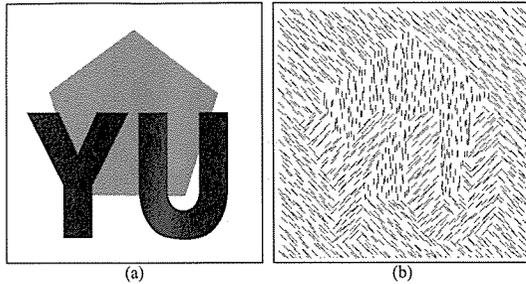


図6 3領域 ($N = 3$) からなるテスト画像。(a) 設定領域の分布、(b) 設定領域を元に生成された群化を引き起こす画像。各領域は異なる方向(水平右方向から反時計回りに $\pi/4$, $2\pi/4$, $3\pi/4$ の方向)を持つ微小線分で埋めつくされている。それぞれの領域内では線分は同じ方向を向いている。画像の大きさは 400×400 (pixel)

Fig. 6 Test images having 3 groups ($N = 3$). Particular groups of the image (a) are filled with short lines. In each group, lines share the same orientation. Short lines belonging to different groups are directed at the different orientation directions of $\pi/4$, $2\pi/4$, $3\pi/4$ from the horizontal rightward direction in the inverse clockwise direction. The image size is 400×400 (pixel).

検出結果に対して、比較のため4種類の手法:(1)提案モデル ($D_v = 4.0$), (2)提案モデル ($D_v = 0.0$), (3)拡散モデル [提案モデルにおいて反応項をゼロ: $f(\cdot) = 0$, $g(\cdot) = 0$ とおいたもの], および(4)川崎らの手法¹⁴⁾(付録A.1を参照)を適用した。群化結果を図8に示す。

まず図8(a), (b), (c)を比較すると、提案モデルにおいて $D_v = 4.0$ とした場合の結果は、 $D_v = 0.0$ とした場合のそれに対して、困難が予想されたローマ字‘Y’における鋭角の部分、および、ローマ字‘U’と5角形パターンとが囲む領域において良好な結果を示

している。また、 $D_v = 4.0$ とした提案モデルの結果と拡散モデルのそれとを比較すると、やはりローマ字‘Y’の鋭角部分について特に違いが見られる。図8(a), (d)の比較においても同様に鋭角部分については提案法の特徴がよく現れている。

提案モデルおよび拡散モデルの計算量(計算時間)の実際について述べる。反応・拡散モデルは式(3)のように連立の偏微分方程式で記述されており、 u_n , v_n の時間発展を数値計算の差分法によって計算している。このための計算量は膨大であり、提案手法を実際に工業用画像処理などのリアルタイム性を要する分野へ応用しようとするならば問題となる。反応・拡散モデルを実現する集積回路の実用化が進められており^{9),10)}, 将来的にはそのようなデバイス化によって計算時間の問題を解決できる可能性がある。しかしながら、現時点で一般的な計算機を用いたときにどの程度の計算時間を要するか示しておくことは必要である。著者らの計算機環境(中央処理装置: Intel Xeon 1.7 GHz, 主記憶装置: 512 MByte からなる一般的なパーソナルコンピュータ)を用いて3領域からなるテスト画像の解析結果を得るまでの実計算時間を測定した。その結果、提案法 ($D_v = 4.0$) を用いて図8(a)の結果を得るまでに要した計算時間は48分40秒であった。同様に、提案法 ($D_v = 0.0$) を用いて図8(b)の結果を得るまでに要した計算時間は47分17秒、拡散モデルによって図8(c)の結果を得るまでに要した計算時間は2分28秒であった。したがって、計算量については拡散モデルが提案モデルに対してきわめて少ない。このような計算量の違いはあるものの、著者らは視覚情報処理の様々な分野において、反応・拡散モデルが単なる拡散モデルにはない優れた特徴を有していると期待しており、これを追求していく意義はあると考えている。なお、本提案手法では、線型代数方程式の数値解法として Gauss-Seidel 法を利用している。より高速計算可能な SOR 法や CG 法などの計算手法¹⁵⁾を利用することにより、計算時間の短縮は可能であると期待される。

群化過程を定量的に評価するため、図6(a)の設定領域の画像 $M_0(x, y)$ とそれぞれの手法によって得られた群化過程 $M(x, y, t)$ を用いて次式を定義する。

$$d(x, y, t) = \begin{cases} 0 & \text{if } M(x, y, t) = M_0(x, y) \\ 1 & \text{if } M(x, y, t) \neq M_0(x, y) \end{cases} \quad (8)$$

式(8)の画面全体に対する平均値 $\bar{d}(\%)$ を群化過程の評価に用いる。評価値が小さいほど設定領域と時刻 t における群化過程が合致していることを表し、群化過

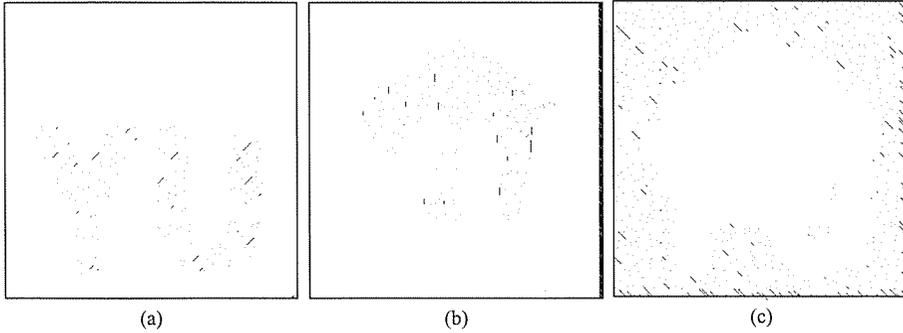


図 7 3 領域からなるテスト画像 (図 6) からの方向検出結果. (a) $\pi/4$, (b) $2\pi/4$, (c) $3\pi/4$ の方向 (水平右方向から反時計回り) を検出するモジュールの出力図. 黒色領域・ドットがその位置にその方向の線分が存在することを表している

Fig. 7 Outputs of the orientation selective modules from Fig. 6. Orientation is (a) $\pi/4$, (b) $2\pi/4$ and (c) $3\pi/4$ from the horizontal rightward direction in the inverse clockwise direction. Black regions and dots in each output share the same orientation.

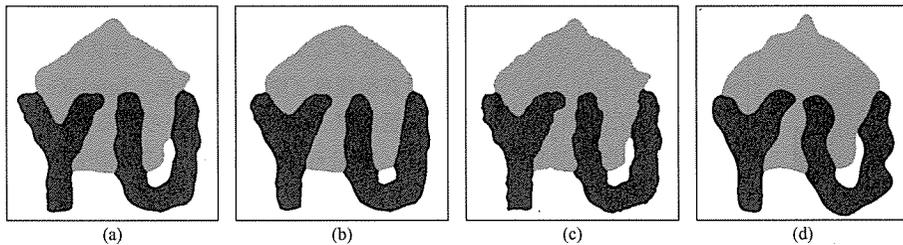


図 8 3 領域からなるテスト画像 (図 6) に対する群化の結果. ただし, 画像の境界の問題を取り除くため, テスト画像の周囲 20 (pixel) ずつを切り取った 360×360 (pixel) の画像を解析した. (a) 提案モデル ($D_v = 4.0$), (b) 提案モデル ($D_v = 0.0$), (c) 拡散モデル (提案モデルにおいて反応項をゼロ), (d) 川崎らの手法¹⁴) (手法の詳細および解析に用いたパラメータ値については付録 A.1 を参照) によって得られた結果. (a), (b) は $t = 10$ において, (c) は $t = 1.0$ において得られた結果

Fig. 8 Results of the grouping process for the test image of Fig. 6. The results (a) and (b) were obtained by the proposed model with the diffusion coefficients $D_v = 4.0$ and $D_v = 0.0$, respectively. The result (c) was obtained by an ordinary diffusion model, that is, the model of Eq. (3) without reaction-terms. The result (d) was obtained by the method proposed by Kawasaki and Iijima¹⁴). See the appendix A.1 for more information on the method of Kawasaki and Iijima and its parameter values utilized here. Different grey levels refer to different groups on orientation. The maps (a) and (b) were obtained at $t = 10$; the map (c) was done at $t = 1.0$.

程に対する定量的な評価の目安となる. 図 8 に対して定量評価の式 (8) を適用して得られた値の各時刻における平均値の時間変化を図 9 に示す. $D_v = 4.0$ と設定した提案手法は, 群化過程の初期において, いったん, 評価値が大きくなるように変化するが, その後急激に小さくなり, $t = 10$ では定常状態となっている. それに対して, $D_v = 0.0$ と設定した提案手法は, およそ $t < 1.0$ の範囲では $D_v = 4.0$ の場合と同様にいったん評価値が大きくなる傾向を示すが, その後ほぼ定常状態となる. 最終的には $D_v = 4.0$ の場合よりも評価値が大きくなっている. 定常状態となるまでの時間は $D_v = 4.0$ の場合とほぼ同様である. そ

れに対して, 拡散モデルの場合, $t < 1.0$ の範囲においてはほぼ一定値を保つが, その後, 評価値は時間とともに増加傾向を示す. 提案モデル ($D_v = 4.0$) の最終的な評価値に対して, 拡散モデルはいずれの時間においても評価値が大きくなっている. 以上の結果から, 群化結果の画像 (図 8) に対する観察結果においても, 定量的な評価 (図 9) においても, 提案モデルの $D_v = 4.0$ の場合が最も良好な結果を与えていることが確認された.

図 9 は, 拡散モデルによる結果の評価値 [図 9(c)] が時間とともにほぼ増加傾向にあることを示している. このような増加傾向は, 以下に説明するような理由で

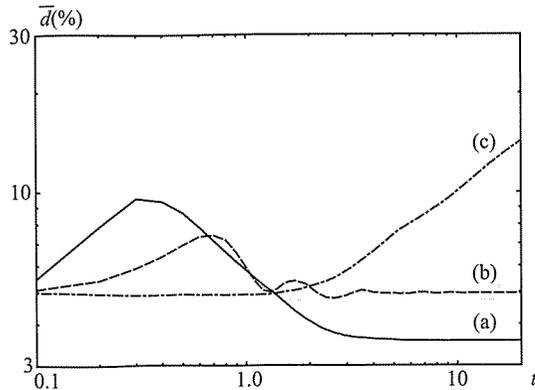


図9 群化過程の解に対する定量評価。横軸が t 、縦軸が評価値 \bar{d} (%) を表す。(a) 提案モデル ($D_v = 4.0$)、(b) 提案モデル ($D_v = 0.0$)、(c) 拡散モデル (提案モデルにおいて反応項をゼロとして実現) によって得られた群化過程に対して評価式 (8) を適用し、領域分布図全体の評価値の平均の時間変化を計算した。なお、川崎らの手法¹⁴⁾ (付録 A.1 参照) による結果: 図 8 (d) の評価値は $\bar{d} = 6.58$ (%) であった

Fig.9 Quantitative evaluations for the grouping process. The horizontal coordinate system refers to time t ; the vertical one does to the value \bar{d} (%) of a quantitative evaluation for a particular grouping process. [see Eq. (8) for the quantitative evaluation]. Results evaluated for the grouping process by the proposed model with $D_v = 4.0$ (a) and $D_v = 0.0$ (b); that by an ordinary diffusion model (c), that is, the model of Eq. (3) without reaction-terms. A quantitative measure \bar{d} evaluated for the result of Fig. 8 (d) obtained by the method of Kawasaki and Iijima (see the appendix A.1) was $\bar{d} = 6.58$ (%).

一般的な画像に対してもおよそ予想される。式 (3) から反応項 $f(\cdot)$ 、 $g(\cdot)$ を除いた式は u_n のみの拡散方程式となる (反応項がないため u_n と v_n の方程式が独立となり、ソース項 s_n は u_n の方程式のみに考慮されているので、 v_n の方程式は考えなくてよい。また、異なる組間の結合も考えなくてよい)。したがって、フィルタ出力: s_n が u_n の拡散方程式にそれぞれソース項として加えられ、それが時間とともに拡散するのみである。それぞれの拡散モデルにおいて u_n は拡散、すなわち一様化していくが、ある時刻における u_n の空間に関する総和は、その時刻までの時間・空間に関する s_n の総和となる。したがって、十分時間が経過すると、 s_n の空間に関する総和が最大のグループの u_n が、空間のいたるところで他のグループの u_n よりも大きくなる。群化過程の領域分布図 $M(x, y, t)$ を構成する際に、各点において $u_n(x, y, t)$ の中から最大値を持つものを、その点におけるグループとしている。結局、十分時間が経過した後は、 $M(x, y, t)$ は s_n の空間総和が最大のグループによって埋めつくされる。したがって、長い時間スケールで見れば、元

画像の設定領域分布と得られる領域分布との違いを表す評価値 \bar{d} は増加し続け、最終的に 1 つの領域のみが残ったときに \bar{d} は一定値となる。なお、それまでの過程でどのような領域分けとなるかは、 s_n の分布に依存するので一般的な説明は困難であり、また一時的に \bar{d} の値が減少することもありうる [図 9 (c) では $t = 0.8$ のとき最小値となった]。

さてこれより、先の $D_v = 4.0$ と設定した場合の提案モデルに対して、他のモデルパラメータを変化させたときに群化過程がどのように変化するか示す。解析対象の画像を図 6 とする (画像の境界周辺は取り除いていない)。図 8 (a) の結果を得たモデルパラメータ ($a_0 = 0.25$, $b = 10$, $D_u = 1.0$, $\varepsilon = 1/100$, $r = 100$) を基本とし、それぞれのパラメータを変化させて群化過程を求め、式 (8) に従って評価値の時間変化を求めた。結果を図 10 に示す。

まず図 10 (a), (e) のように、 a_0 や r を変化させた場合、解が安定するまでの時間 (収束時間) が変化するだけで、最終的には \bar{d} の値はほぼ同様の値に収束している。ただし $r = 20$ の場合、図 10 (i) のように設定領域とまったく異なる群化結果となっている。 r を小さくすることは、モデルに与える刺激の強さを小さくすることに対応する。したがって、あまり r が小さすぎると、いったん刺激が与えられた画素においても、速やかに安定平衡解 A に収束するため、興奮状態とならない。そのうちにすでに興奮状態となった他の領域が広がり、設定領域とは異なった群化結果が得られたものと考えられる。

一方、そのほかのパラメータ b , D_u , ε を変化させた場合、図 10 (b), (c), (d) のように群化結果も大きく異なる (収束しない場合もある)。特に、 $b = 8$, $D_u = 0.20$, $\varepsilon = 0.2/100$ の場合の群化結果をそれぞれ図 10 (f), (g), (h) に示した。 $b = 8$ の場合、孤立した領域が多数得られ、設定領域とは異なっている。また、 $D_u = 0.20$ または $\varepsilon = 0.2/100$ とした場合、まったく設定領域とは異なり、迷路状のパターンが観測された。 D_u を小さく設定した場合、相対的に抑制性因子の拡散の効果が大きくなり、過剰な自己抑制効果によって、本来であれば隣接領域が結合して群化すべき領域においてもそれが妨げられたためであると考えられる。したがって、 D_u を固定し、 D_v を大きくしても同様の現象が観測されるものと予想される。また、 ε を小さくすることは反応項: $f(\cdot)$ の重みを重くし、よって相対的に活性化因子の拡散を小さくすることに対応する。したがって、 D_u を小さくしたのと類似の迷路状のパターンが観測されたものと考えられる。

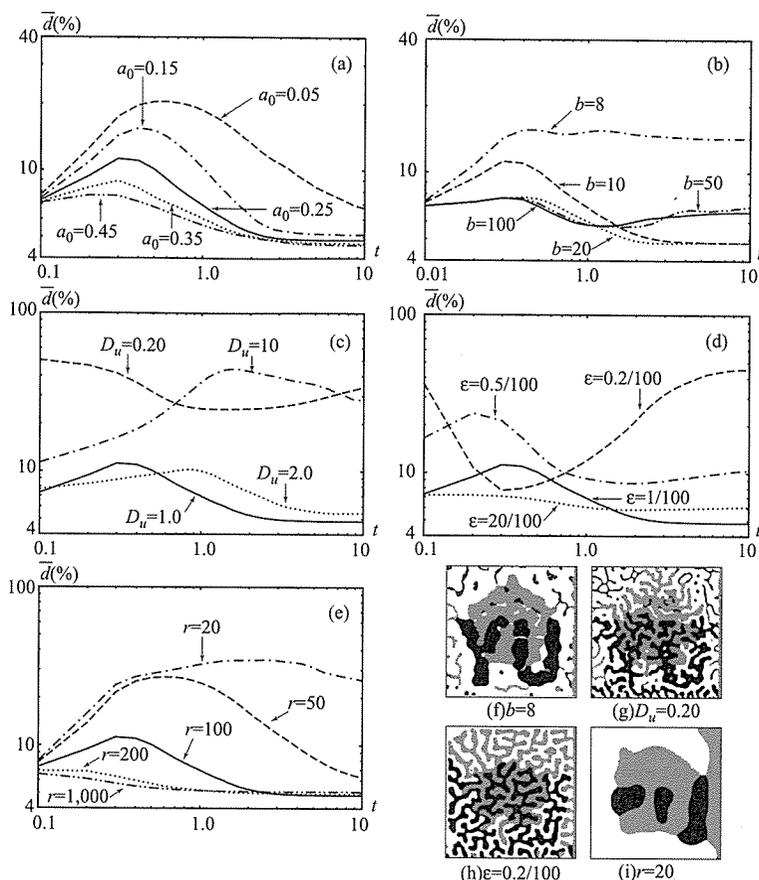


図 10 群化過程のモデルパラメータに対する依存性. 3 領域からなるテスト画像 (図 6) に対して提案モデルを適用し, 群化過程を式 (8) の画像全体での平均によって評価した. (a) a_0 , (b) b , (c) D_u , (d) ε , (e) r を変化させたときの群化過程の評価結果. 横軸が t , 縦軸が評価値 $\bar{d}(\%)$ を表す. 特定のモデルパラメータによって得られた $t = 10$ における群化結果を (f), (g), (h), (i) に示す. $D_v = 4.0$ に固定

Fig. 10 Dependence of the model parameters on results of the grouping process. The proposed model was applied to the test image having three groups (Fig. 6). Wide variety of the model parameters on (a) a_0 , (b) b , (c) D_u , (d) ε , (e) r were chosen for experiments. The horizontal coordinate system refers to t ; the vertical one does to the value $\bar{d}(\%)$ of a quantitative evaluation for a particular grouping process [see Eq. (8) for the quantitative evaluation]. Several typical group maps (f), (g), (h) and (i) were obtained by the proposed model from the same test image at $t = 10$. The parameter D_v was fixed as $D_v = 4.0$ throughout the experiments.

以上の結果と考察から, パラメータ a_0 , r については, 収束時間に関係のあるパラメータであることが予想される. また, パラメータ D_u , ε については小さく設定すると迷路状のパターンが得られ, $D_u < D_v$ の条件でなおかつ (D_v/D_u) を数倍程度にとどめることが必要であると予想される. なお現在のところ, パラメータ設定においては, 上の条件の下でいくつかのパラメータ値を選択して適用し, 解析結果から群化結果としてもっともらしいと思われるものを著者らが選択している.

4.3 実画像の解析

次に, 提案モデルの実画像に対する有効性を確認する. 解析対象の画像を図 11 に示す. ここで, 中央付近では横方向の線分パターンが多く, それ以外の領域においては縦方向の線分パターンが多く存在する. ただし, 左上および右端においては, 縦方向の線分パターンの中で一部横方向の線分パターンが存在する. この画像に対して, 方向検出モジュールを適用した. このとき用いた方向検出モジュールは, 次のような手法である. まず, 対象画素を中心として半径 2 (pixel)

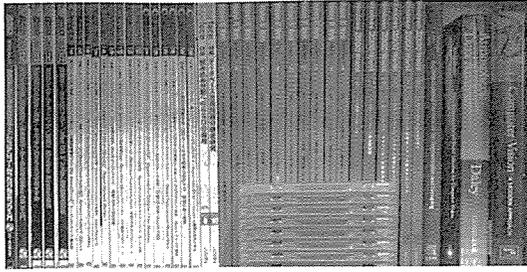
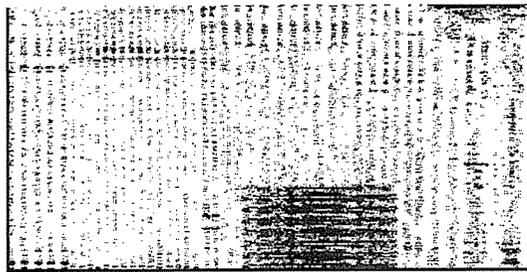
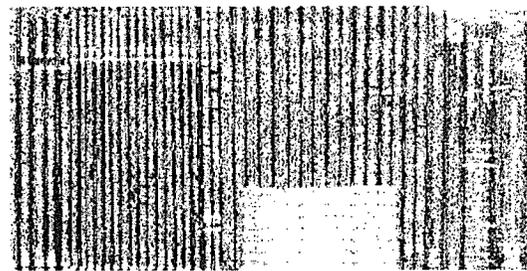


図 11 実験のための実画像. 画像の輝度は 256 段階 (8 bit) に量子化された. 画像サイズは 500×250 (pixel)

Fig. 11 Real test image. Image brightness was quantized into 256 levels (8 bit). The image size is 500×250 (pixel).



(a)

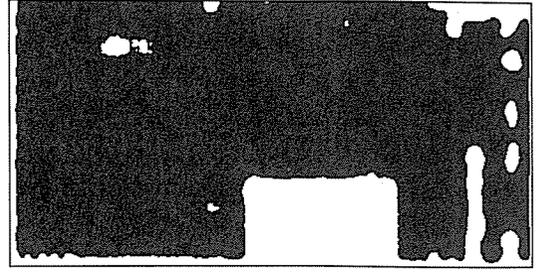


(b)

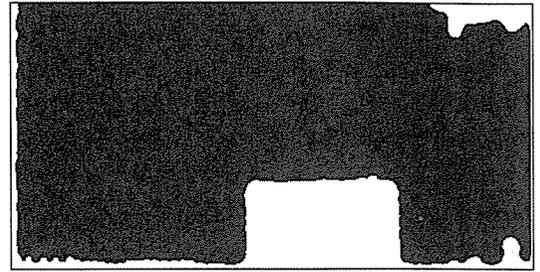
図 12 実画像 (図 11) に対する方向検出結果. (a) 横方向 ($-10\pi/180 \leq \theta \leq 10\pi/180$), (b) 縦方向 ($80\pi/180 \leq \theta \leq 100\pi/180$) の方向検出結果 (ここで, パラメータ θ は方向を表す). 黒色領域・ドットはその方向の線分パターンが存在することを示す

Fig. 12 Outputs of orientation selective modules from the real test image of Fig. 11. (a) Horizontal orientation map ($-10\pi/180 \leq \theta \leq 10\pi/180$). (b) Vertical orientation map ($80\pi/180 \leq \theta \leq 100\pi/180$). The parameter θ denotes orientation. Black regions and dots in each output share the same orientation.

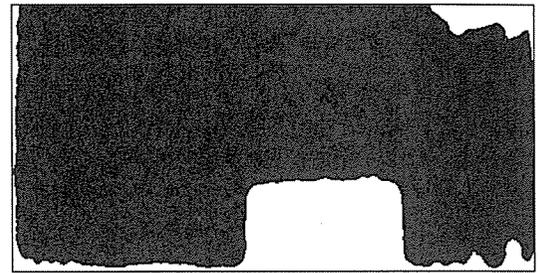
の円形領域を考える. この領域内で, すべての整数方向 $[0, 1, 2, \dots, 179$ (degree)] において画素値の分散を計算し, 最小値を持つ方向をその画素における線分の方向とするものである¹²⁾. 方向検出結果を図 12 に示した. これに対して, 提案モデル ($D_v = 4.0$ の場合と $D_v = 0.0$ の場合), および拡散モデル (提案モデルにおいて反応項をゼロとした場合) の 3 種類の手法



(a)



(b)



(c)

図 13 実画像の解析結果. (a) 提案モデル ($D_v = 4.0$), (b) 提案モデル ($D_v = 0.0$), (c) 拡散モデル (提案モデルの反応項をゼロ) の 3 手法を実画像 (図 11) に適用して得られた群化の結果. 他のパラメータは $a_0 = 0.1$, $r = 10$ とした. 白色領域は横方向, 黒色領域は縦方向の領域であることを示す. (a), (b) は $t = 5.0$ で, (c) は $t = 1.0$ で得られた

Fig. 13 Results for the real image. The results (a) and (b) were obtained by the proposed model with diffusion coefficients $D_v = 4.0$ and $D_v = 0.0$, respectively. The result (c) was obtained by an ordinary diffusion model, that is, the model of Eq. (3) without reaction-terms. Other parameters were set as $a_0 = 0.1$ and $r = 10$. Black regions and white ones refer to groups having vertical and horizontal orientation, respectively. The maps (a) and (b) were obtained at $t = 5.0$; the map (c) was obtained at $t = 1.0$.

を適用した. 群化の結果を図 13 に示す. 提案モデルで $D_v = 4.0$ の場合の結果: 図 13 (a) は, 他のものと比較して, 左上および右端の領域のように小領域でも群化してとらえられていることが分かる.

5. 関連研究

Marr らは, ΔG フィルタを用いて画像のエッジ検

出が可能であることを示した¹⁶⁾。この ΔG フィルタは、2種類の異なる広がりを持つガウスフィルタの差で近似的に表されることも示した (DOG フィルタ)。ガウスフィルタは拡散モデルを用いても表現できる¹⁷⁾。したがって、画像に対してガウスフィルタを適用することは、すなわち拡散モデルを適用することと同じである。彼らはさらに、ガウスフィルタの広がり、抑制性因子のものが活性化因子のものよりも大きくなることを示した。ガウスフィルタの広がり、拡散モデルにおいては拡散係数の大きさに対応するので、彼らの示した条件は、本研究で提案したモデルの拡散係数に対する条件として置き換えると $D_u < D_v$ となる。本研究とは研究対象が異なるものの、実験結果において示された結果から導かれた拡散係数に対する条件は、Marr らがエッジ検出モデルに対して提案したものと類似している。

Kuhnert らは、反応・拡散モデルを用いた画像処理の可能性を示唆した^{18),19)}。彼らは、反応・拡散システムとして現実の化学反応システムを採用した。このシステムは、反応・拡散メカニズムにより空間パターンを形成し、また光に反応する性質 (光感受性) を持つ。Kuhnert らは 2 次元状に上げた化学反応システムに対して光パターンを照射し、そのパターンが時間とともに変化する様子を観察した。その結果から、反応・拡散メカニズムを持つ化学反応システムによるエッジ検出機能の実現の可能性を示唆したものである。さらに、反応・拡散モデルを用いて視覚機能 (記憶や運動錯視) を説明するモデルを構築しようとする試みがある^{20),21)}。なお、反応・拡散モデルはニューラルネットワークの一種ととらえることもでき、従来のニューラルネットワークで扱われてきた画像処理の課題に応用しようとする研究も進められている^{22),23)}。本研究の提案モデルで導入したモデル間の相互抑制のメカニズムは、ニューラルネットワークにおける協調・競合モデルからヒントを得たものである。従来の協調・競合の枠組みで立体視や群化過程のモデルが提案されているが、通常は、1 変数のモデルを複数考え、それらのモデル間で相互に抑制しあうメカニズムを導入する。それに対して、ここで提案したモデルはそれぞれのモデルの内部で抑制性 (自己抑制) を考慮する点が異なる。

Turing は、反応・拡散モデルを用いて、パターンが自己組織的に形成される条件を見出した²⁴⁾。一般に拡散過程は、均一な状態を作り出すように働くが、抑制性因子の拡散係数が活性化因子のそれよりもきわめて大きいとき、均一な状態が不安定化し、周期的な空間パターンが形成されることを示した。今ではこれ

は Turing 条件と呼ばれ、現実の生物システムにおいても、その条件によって引き起こされたと思われるパターンがいくつか発見されている²⁵⁾。すなわち Turing 条件が、現実の生物システムにおいても成り立っていることがあることが実際に示された。本研究で課した条件 ($D_u < D_v$) は、Turing 条件 ($D_u \ll D_v$) ほどの極端な条件ではないが、Marr らおよび Turing 条件と類似した条件となっている。実際、図 10 (g), (h) は、Turing パターンにきわめてよく似通っている。また、著者らがこれまで反応・拡散モデルを用いたエッジ検出・領域分割のモデルを提案してきたが、そこで必要とされた拡散係数に関する条件もここで示されたものとはほぼ同様のものである。以上のことから、抑制性因子の拡散が視覚の様々なモデルにおいても有効であることが示唆された。

本研究では、提案モデルと拡散のみに基づくモデルとを比較した。拡散 (すなわちガウスフィルタ) を基本としたモデルは、画像処理やコンピュータビジョンの様々な課題においてしばしば取り上げられる。一般に拡散モデルは、微細な構造を平滑化して取り除き、適当な大きさの構造を抜き出そうとする課題において利用される。しかしながら、同時に、必要な構造も除いてしまう。先の 3 領域からなる画像に対する結果もこの問題を再提案している。拡散モデルは時間の経過とともにさらに微細な構造を消し去っている。この問題を解決するために、拡散係数に異方性を取り入れた²⁶⁾、あるいは、問題に適した拡散時間を求めて計算を停止させようとする試みがある²⁷⁾。本研究の提案モデルは、そのような拡散の異方性や計算の停止時間を推定する手法の導入は必要ない。ただし、反応項において設定すべきパラメータが多く、その設定方法についてはさらに検討を要する。

6. まとめ

本研究では、反応・拡散モデルを用いた群化過程のモデルを提案した。ここでは、特徴として微小線分の方向を考え、2 変数の反応・拡散モデルを複数組用いたモデルとした。これらのモデルは、相互に反応項を通じて結合するとともに、それぞれのモデル内においても拡散によって空間的に結合している。このとき、モデル間の結合は相互に抑制的に、またモデル内の空間結合についても、抑制性因子の拡散を活性化因子のそれに比べて大きくすることによって、自己抑制的となっている。3 種類のテスト画像から特徴量 (微小線分の方向) を検出し、その出力に対して提案モデルを適用することで提案モデルの群化過程を検証した。そ

の結果, 特に自己抑制の効果が重要であることが, 単純な拡散モデルや自己抑制効果の小さい場合のモデルとの比較において明らかとなった.

群化過程のモジュールは, 様々な視覚機能の基礎となる機能であり, このモデルを実現できたことにより, さらに他の視覚機能のモデル化に対しても広範囲に適用可能であると考えられる. また, 反応・拡散モデルを用いたことにより, 視覚のマクロな機能を生物のミクロな仕組みによって説明することが可能となった. 今後の課題としては以下の項目があげられる.

- 提案モデルでは FHN 型の反応項を修正したものを導入した. FHN 型の反応項は 3 次関数からなるが, 本当に 3 次関数が必要なのか, より簡単な 2 次関数に代えた場合どのような結果を示すのか, 比較検討する必要がある. また, 相互抑制性を活性化因子 u の反応項に導入したが, 抑制性因子 v へ導入した場合でも同様の結果が得られるか検討する必要がある. 様々な反応項を試みることによって, 反応項の果たす機能について明らかにすることが必要である.
- 本研究では, 特徴として線分の方向のみに注目したが, 他の特徴 (たとえば視差や濃淡) に対しても適用し, 提案モデルの有効性を確認する. さらに, 複数種類の特徴からなる画像を対象とした場合についても考えていく必要がある. このとき, いかに特徴の統合を行うかが問題となり²⁸⁾, これに対するモデルを今後考えていくことが必要である.

謝辞 本研究の一部は科学研究費補助金・基盤研究 (B)・課題番号: 15340125 および若手研究 (B)・課題番号: 13780300 による.

参考文献

- 1) Marr, D.: *Vision*, W.H. Freeman and Company, New York (1982).
- 2) Beck, J.: Effect of Orientation and of Shape Similarity on Perceptual Grouping, *Percept. Psychophys.*, Vol.1, pp.300-302 (1966).
- 3) Hodgkin, A.L. and Huxley, A.F.: A Quantitative Description of Membrane Current and its Application to Conduction and Excitation in Nerve, *J. Physiol.*, Vol.117, pp.500-544 (1952).
- 4) FitzHugh, R.: Impulses and Physiological States in Theoretical Models of Nerve Membrane, *Biophys. J.*, Vol.1, pp.445-466 (1961).
- 5) Nagumo, J., Arimoto, S. and Yoshizawa, S.: An Active Pulse Transmission Line Simulating Nerve Axon, *Proc. IRE*, Vol.50, pp.2061-2070 (1962).
- 6) Nomura, A., Ichikawa, M. and Miike, H.: Edge Detection and Segmentation with a Reaction-diffusion Mechanism, *Proc. Advanced Concepts for Intelligent Vision Systems*, pp.300-306 (2002).
- 7) 三口貴史, 三池秀敏, 田中恭治: RDS の考えを用いた奥行き分布検出の試み, 情報処理学会研究報告 CV-098-001, 情報処理学会 (1995).
- 8) Nomura, A., Ichikawa, M. and Miike, H.: Solving Random-dot Stereograms with a Reaction-diffusion Model under the Turing Instability, *Proc. 10th Int. DAAAM Symp.*, pp.385-386 (1999).
- 9) Sunayama, T., Ikebe, M., Asai, T. and Amemiya, Y.: Cellular vMOS Circuits Performing Edge Detection with Difference-of-Gaussian Filters, *Jpn. J. Appl. Phys.*, Vol.39, No.Part 1, No.4B, pp.2278-2286 (2000).
- 10) Asai, T., Nishimiya, Y. and Amemiya, Y.: A CMOS Reaction-diffusion Circuit Based on Cellular-automaton Processing Emulating the Belousov-Zhabotinsky Reaction, *IEICE Trans. Fund.*, Vol.E85-A, No.9, pp.2093-2096 (2002).
- 11) Ferster, D. and Koch, C.: Neural Connections Underlying Orientation Selectivity in Cat Visual Cortex, *Trens Neurosci.*, Vol.10, pp.487-492 (1987).
- 12) Nomura, A., Okada, K., Miike, H. and Yamada, H.: Determination of Oscillating Flow Fields by the Gradient Based Method, *Proc. 10th Int. Symp. Flow Visualization*, Kyoto, Japan, p.F0154 (2002).
- 13) 三池秀敏, 森 義仁, 山口智彦: 非平衡系の科学 III—反応・拡散系のダイナミクス, 講談社サイエンティフィック (1997).
- 14) 川崎順治, 飯島泰蔵: 2次元等価近似法による各種変調画像の評価法, 信学論 D-II, Vol.J82-D-II, No.12, pp.2230-2239 (1999).
- 15) 戸川隼人: マトリクスの数値計算, オーム社 (1990).
- 16) Marr, D. and Hildreth, E.: Theory of Edge Detection, *Proc. R. Soc. Lond. B*, Vol.207, pp.187-217 (1980).
- 17) Koenderink, J.J.: The Structure of Images, *Biol. Cybern.*, Vol.50, pp.363-370 (1984).
- 18) Kuhnert, L.: A New Optical Photochemical Memory Device in a Light-sensitive Chemical Active Medium, *Nature*, Vol.319, No.30, pp.393-394 (1986).
- 19) Kuhnert, L., Agladze, K.I. and Krinsky, V.I.: Image Processing Using Light-sensitive Chemical Waves, *Nature*, Vol.337, No.19, pp.244-247 (1989).

- 20) 伊藤 聡, 湯浅秀男, 伊藤正美: 反応拡散方程式を用いた自己想起型連想記憶による画像認識, 計測自動制御学会論文集, Vol.30, pp.97-103 (1994).
- 21) 上山英三, 湯浅秀男, 細江繁幸, 伊藤正美: 反応拡散方程式を用いた動きによる図地分離—形成されたパターンの界面と主観的輪郭, 信学論 D-II, Vol.J81-D-II, No.12, pp.2767-2778 (1998).
- 22) Liang, P.: Neurocomputation by Reaction Diffusion, *Phys. Rev. Lett.*, Vol.75, pp.1863-1866 (1995).
- 23) Principe, J., Euliano, N. and Garani, S.: Principles and Networks for Self-organization in Space-time, *Neural Networks*, Vol.15, pp.1069-1083 (2002).
- 24) Turing, A.M.: The Chemical Basis of Morphogenesis, *Philos. Trans. Roy. Soc. Lond. B*, Vol.237, pp.37-72 (1952).
- 25) Kondo, S. and Asai, R.: A Reaction-diffusion Wave on the Skin of the Marine Angelfish *Pomacanthus*, *Nature*, Vol.376, No.31, pp.765-768 (1995).
- 26) Perona, P. and Malik, J.: Scale-space and Edge Detection Using Anisotropic Diffusion, *IEEE Trans. Patt. Anal. Mach. Intell.*, Vol.12, pp.629-639 (1990).
- 27) Mrázek, P.: Selection of Optimal Stopping Time for Nonlinear Diffusion Filtering, *Proc. 3rd Int. Conf., Scale-Space 2001*, pp.290-298 (2001).
- 28) Treisman, A.: Features and Objects: The Fourteenth Bartlett Memorial Lecture, *Q. J. Exp. Psychol.*, Vol.40A, No.2, pp.201-237 (1988).

付 録

A.1 川崎らの手法¹⁴⁾を用いた群化モデルの実現

川崎らは, 人間の視覚モデルに基づきパルス密度変調された画像から元の画像を復元する手法を提案した. この手法は, エルミート多項式を用いて元画像を復元するが, その多項式の最大次数を適切に選ぶことにより, 元画像に近い(視覚内部で表現されているであろう)画像が得られることを利用している. したがって, 本論文における方向検出フィルタの出力結果(図7)を, 元画像[図6(a)における各領域]のパルス密度変調された画像ととらえることにより, 川崎らの手法を適用することができる.

3つの方向検出フィルタの出力結果の図7に対して川崎らの手法を適用し, 元画像(図6)の領域分布図を復元する方法を示す. いま, n 番目 ($n = 0, 1, 2$) のフィルタ出力結果 $s_n(x, y)$ に着目する. s_n に含まれるパルス ($s_n = 1$ となる画素) の総数を N_p で表

し, それらすべてのパルスに番号 $\alpha = 1, 2, \dots, N_p$ を付けるものとする. また, s_n に含まれる第 α 番目のパルスが位置する2次元座標を $\mathbf{X}_\alpha = (X_\alpha, Y_\alpha)$ とする. 方向検出フィルタの出力結果 s_n は, ある画像 $R_n(x, y)$ のパルス密度変調された画像と考え, 次式を用いて $R_n(x, y)$ の復元画像 $\hat{R}_n(x, y)$ を生成する (R_n は図6の n 番目のグループのみの領域を取り出した画像である).

$$\hat{R}_n(x, y) = \sum_{p=0}^{P_0} \sum_{q=0}^{Q_0} \left(\frac{1}{p!q!} \right) B_{pq} \times H_p \left(\frac{x - a_0}{\sigma_0} \right) H_q \left(\frac{y - b_0}{\sigma_0} \right) \quad (9)$$

ここで, P_0, Q_0 は非負の整数で, $H_p(x)$ は p 次の x に関するエルミート多項式を表す. また, $\mathbf{r}_0 = (a_0, b_0)$ は画像の中央座標に設定し, σ_0 は定数である. 文献14)では人間の視覚モデルを考えており, \mathbf{r}_0 は視点, σ_0 は視野に相当する. さらに B_{pq} は次式によって表される.

$$B_{pq} = \sum_{\alpha=1}^{N_p} W(\mathbf{r}_0 - \mathbf{X}_\alpha, \tau_0) \times H_p \left(\frac{X_\alpha - a_0}{\sigma_0} \right) H_q \left(\frac{Y_\alpha - b_0}{\sigma_0} \right) \quad (10)$$

ここで, τ_0 は定数でばけのパラメータを表し, $W(\cdot)$ は次のガウス関数である.

$$W(\mathbf{r}, \tau) = \frac{1}{\sqrt{2\pi}\tau} \exp \left(-\frac{\|\mathbf{r}\|^2}{2\tau^2} \right) \quad (11)$$

記号 $\|\cdot\|$ はベクトルのノルムを表す. 最後に, 式(9), (10), (11)をすべての s_n に適用して得られる結果 $\hat{R}_n(x, y)$ から領域分布図 $M(x, y)$ を求める. すなわち, 各点 (x, y) において $\hat{R}_1, \hat{R}_2, \hat{R}_3$ の3つ値を比べ, その点が属するグループは, それらの最大値を持つグループであるとする.

川崎らの手法において設定すべきパラメータとしては, エルミート多項式の次数 P_0, Q_0 , 視野 σ_0 , ばけパラメータ τ_0 があげられる. エルミート多項式の次数については, P_0, Q_0 を別々の値に設定することができるが, 組合せが膨大になることから簡単のため $P_0 = Q_0$ とした. その値の設定方法として, $P_0 = Q_0$ の値を 30, 40, 50, 60, 70 と変化させながらテスト画像(図7)に対して適用し, 評価式(8)によって \bar{d} の値を求めて最小値を示す $P_0 = Q_0 = 70$ を採用した. また, 視野およびばけのパラメータは等しく $\sigma_0 = \tau_0$ とし, 40, 60, 80, 100 と変化させた. あまり小さく

すると特に復元画像の周辺部においてパル的な性質が現れて評価値が悪化し(大きくなり), 大きくしても復元画像が過度に滑らかになってやはり評価値が悪化した. そのため $\sigma_0 = \tau_0 = 80$ とした. 図 9 において図の説明に示した評価値は, ここで記した手法・パラメータを用いたときの結果に対するものである. さらに川崎らは, 等価近似法とよばれるパラメータ $P_0 = Q_0$ の最適推定法を提案している¹⁴⁾. したがって, その手法を導入することでよりよい $P_0 = Q_0$ が選択され, 評価値が向上する(小さくなる)可能性もあることを付記しておく.

(平成 16 年 1 月 16 日受付)

(平成 16 年 3 月 4 日採録)

担当編集委員 井宮 淳)



野村 厚志 (正会員)

1994 年山口大学大学院工学研究科博士後期課程修了. 博士(工学). 同年山口女子大学(現, 山口県立大学)国際文化学部講師. 1998 年同大学助教授. 2001 年山口大学教育学部助教授. 現在に至る. 画像処理の研究に従事. 電子情報通信学会, 日本物理学会各会員.



一川 誠

1994 年大阪市立大学大学院文学研究科博士後期課程修了. 博士(文学). 1994 年ヨーク大学心理学科博士研究員. 1997 年山口大学工学部講師. 2000 年同助教授. 現在に至る. 視覚心理学の研究に従事. 日本心理学会, 日本基礎心理学会, 日本視覚学会, 日本感性工学会, 日本認知心理学会, 関西心理学会, Association for Research on Vision and Ophthalmology 各会員.



三池 秀敏 (正会員)

1976 年九州大学大学院工学研究科博士課程修了. 工学博士. 同年山口大学工学部助手. 1991 年同大学教授. 現在に至る. その間, 1987 年ドイツ・マックスプランク研究所招聘研究員. 動画処理による物理計測, 非平衡反応系の非線形パターンダイナミクス, 流体現象等に関する研究に従事. 電子情報通信学会, 電気学会, 日本物理学会, 形の科学会, IEEE-CS, American Association for the Advancement of Science 各会員.