遍在するランダムネスにもとづく連結道路領域のフラクタル同定

亀 島 鉦 二*

Randomness-based Approach to the Identification of Fractal Pattern Spanning a Connected Roadway Area

Kohji KAMEJIMA*

A stochastic scheme is presented for the identification of a roadway pattern in complex natural scenes. By matching linear scale shift rule with randomly distributed noise images, a version of invariant measure is estimated as the observation of not-yet-identified fractal attractor spanning the roadway area within a generic ground-object structure. The expansion of the invariant measure is restricted by associated breakdown pixels with respect to the linear scale shift rule to design the self-similarity process generating the attractors. The consistency of designed process is verified via invariant feature detection and visualization on the scene images. Proposed method is verified through experimental studies using various types of roadway scene images.

Key Words: roadway scene analysis, ground-object structure, invariant measure, fractal modeling, randomness-based approach

1. はじめに

前方に拡がった平面領域を知覚することは移動知能の基本過程であり、長年にわたり研究ならびにシステム開発が進められている^{1),2)}。従来の知覚システムでは、道路の境界や障害物を情景画像から検出し、移動経路が生成されていた。この際、境界線の間を平面とみなし、障害物を回避することで移動可能性が判断できるものとされている。ただし、移動体を実際の速度で誘導するためには、物体の形状や位置の3次元決定に先行して平面領域の存在自体を判定し、境界物体に囲まれた「道路」として同定する必要がある。また、滑らかな移動軌跡を生成するためには、道路境界の配置に加えて、前方に拡がる平面領域の連結性を陽に表現することも必要となる。本研究では、前方情景の総称的構造のみを先験的知識として、このような認知的情報を情景画像から直截的につくり出すメカニズムの計算機実現を目指す。

さて、生態学的視覚論では、移動を誘発する平面の拡がり、移動過程とのインタラクションを通して知覚する情報処理メカニズムの役割が強調されており³⁾、計算論的初期視覚論では、奥行き知覚の手がかりとなるスケール分布を生成する神経回路網の実在が指摘されている⁴⁾。また、近年の神経心理学的実験を通して、“知覚の意識”に先行する無意識的、情動

的な情報生成の意義が明らかにされつつある⁵⁾。とくに、視覚系が“計算”の容易な形態に反応しやすく⁶⁾、とりわけ、情景中のフラクタルパターンに対して低ストレスで反応する⁷⁾との指摘は、認識対象に自己相似性を仮定するアプローチ⁸⁾の可能性を示唆する。これらの経験的事実を踏まえ、本論文では、未知の連結道路領域が提示する画像特徴分布にもとづいて先験的な総称的構造を表現するフラクタルアトラクターを直截的に同定するプロセスを考察する。

与えられた画像から自己相似規則を求めるフラクタル逆問題は、まず、符号化の観点からとり上げられ^{9),10)}、領域分割や輪郭抽出への応用の視点からも考察されてきた^{11),12)}。ただし従来の定式化では、自己相似規則を検出すべき領域 (range) を事前に定めておく必要があり、未知領域の存在判定に適用することは容易でない。また、情景画像解析ではこの range の事前設定と結果として得られる自己相似規則の間に幾何学的整合性を保証しがたく、対応するフラクタルアトラクターを複雑な対象領域の連結性表現として用いることは自明とはいえない。これらの困難に対処するため、以下、フラクタル逆問題を確率的に定式化する。具体的には、画像特徴の確率分布にもとづいて道路領域上の不変測度を推定し、対応するフラクタルアトラクターを生成する縮小写像群をデザインする。

2. 確率的フラクタル逆問題

境界を除いた画面を Ω とし、 Ω の部分集合からなる Borel 集合族を $\mathcal{F}[\Omega]$ と書く。 $\mathcal{F}[\Omega]$ 上には確率測度 $P: \mathcal{F}[\Omega] \rightarrow [0, 1]$ を導入し、 $\mathcal{F}[\Omega]$ 上の測度を画像、測度の台を形態とそれぞれよぶ。このように定義される形態は Ω 内のコンパクト部分集

* 大阪工業大学情報科学部 枚方市北山 1-79-1

* Faculty of Information Science and Technology, Osaka Institute of Technology, 1-79-1 Kitayama, Hirakata
(Received November 11, 2011)

(Revised November 21, 2012)

Fig. 1 Fractal representation of roadway pattern in multi-viewpoint imagery

合であり、その全体を $\mathcal{H}[\Omega]$ と書く。 $\mathcal{H}[\Omega]$ にはハウスドルフ距離 $\eta: \mathcal{H}[\Omega] \times \mathcal{H}[\Omega] \rightarrow [0, \infty)$ を導入しておく。以上の準備のもとで Ω から Ω への縮小写像の集合 $\nu = \{\mu_i\}$ を考える。このような写像群 ν 上に縮小写像 $M_\nu(\cdot) = \bigcup_{\mu_i \in \nu} \mu_i(\cdot)$ を構成すると、この $M_\nu: \mathcal{H}[\Omega] \rightarrow \mathcal{H}[\Omega]$ は、自己相似則

$$\Xi = \bigcup_{\mu_i \in \nu} \mu_i(\Xi), \quad (1)$$

をみたすアトラクター $\Xi \in \mathcal{H}[\Omega]$ をもつことが証明されている¹³⁾。逆に、与えられた形態 $\Lambda \in \mathcal{H}[\Omega]$ をコラージュ近似するようにデザインされた写像群は、対応する誤差で複雑パターンをフラクタル近似することも知られている¹⁴⁾。

一方、自己相似則 (1) は、不変性

$$\chi_\Xi^p(\cdot) = \sum_{\mu_i \in \nu} p_i \chi_\Xi^p[\mu_i^{-1}(\cdot)], \quad (\cdot) \in \mathcal{F}[\Omega], \quad (2)$$

をみたす測度 χ_Ξ^p を通して明暗分布を提示する¹⁵⁾。ただし、 $\mathbf{p} = \{p_i\}$ は写像群 $\{\mu_i\}$ の選択確率である。逆に、与えられた不変測度 χ_Ξ^p にもとづいて捕獲確率を生成することにより、観測形態を支配する写像群 ν を確率的に検出することができる¹⁶⁾、さて、多くの道路領域は、**Fig. 1** に示すように、鳥瞰画像内では長方形 ($\tilde{\Xi}$) の連鎖として近似できる。この $\tilde{\Xi}$ は、縮小写像群 $\tilde{\nu} = \{\tilde{\mu}_i\}$ のアトラクターと同一視でき、前方画像内の台形領域 (Λ) に投影される。幾何学的には、投影領域 Λ は $\tilde{\Xi}$ を無限遠方まで延長した長方形の投影パターン Ξ に含まれる。すなわち、 Λ の存在範囲は消失点情報にもとづいて計算可能である。実際、この投影パターン Ξ も縮小写像群 $\nu = \{\mu_i\}$ を用いて生成される。ただし、 Ξ が道路領域として観測できるのは、 $\tilde{\nu}$ による描画範囲 (horizon of imaging) に限定される。このような総称的生成-観測構造に着目し、まず、情景画像から抽出可能な特徴にもとづいて不変則度 χ_Ξ^p

Fig. 2 Shopping street with complex texture

Fig. 3 Power spectrum of $\frac{\partial^2}{\partial x^2} f(x, 0)$

Fig. 4 Directional Fourier transform of Δf

を推定する。

3. 不変測度の推定

物体像の変化を計量することにより物体の認識に先行して情景の奥行 (depth: y) と拡がり (expansion: x) を計算でき

る。さて、Fig. 2 に示すような実情景中の物体は、さまざまな損傷を受け、その表面は微細な凹凸で被われている。実際、画面の下辺 ($y = 0$) の走査線に沿って抽出した 1 次元明暗分布には Fig. 3 に示すような豊富な微細情報が含まれている。ここで Δ -Power は分布の 2 階微分のパワースペクトルを表わす。この 1 次元スペクトルを $y > 0$ に従って積み重ねると、Fig. 4 に示すような周波数画像が得られる。ここでは、周波数変移が収束する位置、すなわち消失点、を y_∞ と表示している。本図より、情景画像中にはランダム成分が遍在すること、およびそのランダム成分のスケール変移にもとづいて実情景の奥行きを直截的に知覚できることを示している。

ところで、パラメータ $\tau > 0$ をもつガウス分布

$$g_\tau(\omega) = \frac{1}{2\pi\tau} \exp\left[-\frac{|\omega|^2}{2\tau}\right],$$

に従って拡散された点画像の明暗分布は発展方程式

$$\frac{\partial g_\tau}{\partial \tau} = \frac{1}{2} \Delta g_\tau, \quad g_0 = \delta,$$

の解として生成される。ただし、 δ は点画像を表現する Dirac's delta function である。ここで、十分小さなパラメータ τ に対して近似

$$\begin{aligned} \frac{\partial g_\tau(\omega)}{\partial \tau} &\sim \frac{g_\tau(\omega) - g_0(\omega)}{\tau} \\ &= \frac{1}{2} \Delta g_\tau(\omega), \end{aligned} \quad (3)$$

が成り立つことに注意すると、不変測度上でパラメータ τ_ω を拘束するつぎの関係が得られる。

$$g_{\tau_\omega} * \chi_\Xi^p - \chi_\Xi^p \simeq \frac{\tau_\omega}{2} \Delta g_{\tau_\omega} * \chi_\Xi^p. \quad (4)$$

不変測度の観測を通して画面上に生成される明暗分布を f_ω とかく。この f_ω には背景物体からの反射光などに由来する bias が含まれている。多くの撮像過程ではレンズの収差などによるガウス拡散が生じることを考慮すると、近似 (3) が成り立つ程度の十分小さなパラメータ τ_ω に対して、拘束 (4) をつぎの観測不等式で置き換えることができる。

$$\begin{aligned} f_\omega - \frac{\tau_\omega}{2} \Delta f_\omega &\geq g_{\tau_\omega} * \chi_\Xi^p - \frac{\tau_\omega}{2} \Delta g_{\tau_\omega} * \chi_\Xi^p \\ &\simeq \chi_\Xi^p > 0. \quad (a.e.) \end{aligned}$$

これは、明暗分布のみを用いて拘束 (4) をみたすスケールの上限 $\hat{\sigma}_\omega$ をつぎのように評価できることを意味する。

$$\hat{\sigma}_\omega = \sqrt{\frac{2f_\omega}{|\Delta f_\omega|}}. \quad (a.e.) \quad (5)$$

Fig. 2 の画素ごとに f と Δf を関係づけた結果を Fig. 5 および Fig. 6 に示す。Fig. 5 中、小さな点は画素ごとに計算した Δf_ω を f_ω の関数としてプロットしたものであり、大きな点は、各 f_ω に対する $|\Delta f_\omega|$ の最大値を表示したものである。Fig. 6 には、Fig. 5 の大きな点に対応する $1/\hat{\sigma}_\omega^2$ のみを表示している。Fig. 5 で、さまざまなレベルの f_ω に対して $|\Delta f_\omega|$ が大きく変動していることから、自然な情景画像には

Fig. 5 Δg_σ -scalability ($f \sim \Delta f$)

Fig. 6 Δg_σ -scalability ($f \sim \tau$)

豊富なスケール情報 $\hat{\sigma}_\omega$ が散在していること、および、(5) 式にもとづく推定値の下限は、明暗の変化にあまり影響されないことがわかる。実際、Fig. 6 に示すように、極端な暗部を除いて $\hat{\sigma}_\omega^2$ の下限値はほぼ一定区間に分布し、最大値と最小値の比は 4 程度を保っている。これらの点に着目して、以下、 $\hat{\sigma}_\omega$ を通して周波数変移を評価するとともに、その最小値

$$\sigma_0 = \min_{\omega \in \Omega} \hat{\sigma}_\omega, \quad (6)$$

を用いてスケール変移モデルをつぎのように構成する。

$$\bar{\sigma}(d) = \max\left(\frac{\kappa\sigma_0}{d_\infty - d_0}(d_\infty - d), \sigma_0\right). \quad (7a)$$

ここに κ はスケール変移の変動幅を与えるパラメータである。Fig. 6 で $\hat{\sigma}_\omega$ の下限値が区間 $[\sigma_0, 2\sigma_0]$ 内に分布していることに着目して、以下、 $\kappa = 2$ と定める。また、 d は情景画像内で撮影地点と Ξ の消失点を結ぶベクトル Ω^d に沿って計量した奥行きである。ただし、 d_0 および d_∞ はそれぞれ撮影地点および消失点の奥行きを表わす。

さて、Fig. 1 より、縮小画像群 ν で結びつけられた Ξ の構成点ではスケールは $d_\infty - d$ に比例して縮小するはずである。この点に着目して、以下、奥行きモデル $\bar{\sigma}_d$ とスケール情報 $\hat{\sigma}_\omega$ の一致度を画素ごとに評価する確率分布

Fig. 7 Δg -scale image $\hat{\sigma}_\omega$ Fig. 9 Capturing probability $\varphi(\omega|\nu)$ based on $\bar{\sigma}_d$ -model Fig. 8 Conditional Δg -measure $\hat{\chi}_\Xi^p$

$$\hat{\chi}_\Xi^p = \frac{1}{\sqrt{2\pi\bar{\sigma}_d^2}} \exp\left[-\frac{|\hat{\sigma}_\omega - \bar{\sigma}_d|^2}{2\bar{\sigma}_d^2}\right] dP(\omega). \quad (7b)$$

を不変測度の推定値とする。Fig. 2の情景から抽出したスケール情報 $\hat{\sigma}_\omega$ を Fig. 7 に、また、消失点を画面中央と仮定して推定した不変測度 $\hat{\chi}_\Xi^p$ を Fig. 8 に示す。Fig. 7 および Fig. 8 では、それぞれ、 $\hat{\sigma}_\omega$ および $\hat{\chi}_\Xi^p$ に比例する直径をもつウインドウを通して情景画像を観測した結果を示している。Fig. 7 に示すように、比較的大きなスケール情報は路面に多く散在しているが、その情報のみを用いて連結した道路領域を再現することは容易ではない。一方、Fig. 8 より、スケール分布と線形変移則の一致度を通して路面のほぼ全域を観測できることがわかる。これは、 $\hat{\chi}_\Xi^p$ にもとづいて連結道路領域を推定するアプローチの妥当性を支持する。

4. 境界物体の分離

$\hat{\sigma}_\omega$ の定義 (5) より、 $\hat{\chi}_\Xi^p$ の台には、より小さな局所スケールをもつ画素も含まれることになる。この点に着目して、線形変移則 (7) の成立境界を推定する。画素 $\omega_l = (\omega_x, \omega_y)$ に対応する路面上の点に足をもつ垂直線の像を $\{\omega^\dagger\}$, $\omega^\dagger = (x, y + dy)$, $dy \geq 0$, と表わし、 $\omega^\dagger$ に ω_l と同じスケール情報が分布する確率を次式で評価する。

$$p(\omega^\dagger|\omega_l) = \begin{cases} \frac{1}{\sqrt{2\pi\hat{\sigma}_{\omega_l}^2}} \exp\left[-\frac{|\hat{\sigma}_{\omega^\dagger} - \hat{\sigma}_{\omega_l}|^2}{2\hat{\sigma}_{\omega_l}^2}\right]; \\ \sigma_0 < \hat{\sigma}_{\omega_l} < \kappa\sigma_0, \\ 0; & \text{otherwise.} \end{cases}$$

この $p(\omega^\dagger|\omega_l)$ は線形変移則 (7) とスケール情報の不整合性のひとつの尺度を与える。これは、垂直線パターン $\{\omega^\dagger\}$ に沿ったスケール分布が線形変移則 (7) と対立する確率を

$$\hat{\chi}_B = \max_{\substack{\omega_l \in \Omega \\ \omega^\dagger \in \langle \omega_l \rangle}} \prod_{\omega^\dagger \in \langle \omega_l \rangle} p(\omega^\dagger|\omega_l) dP(\omega), \quad (8)$$

で評価できることを意味する。ここに、 $\langle \omega_l \rangle$ は線形変移則 (7) が破綻する画素列 (breakdown pixel) であり、

$$\langle \omega_l \rangle = \left\{ \omega^\dagger \in \Omega \mid |\hat{\sigma}_{\omega^\dagger} - \hat{\sigma}_{\omega_l}| < \hat{\sigma}_{\omega_l} \right\},$$

と定める。

推定測度 $\hat{\chi}_\Xi^p$ および存在確率 $\hat{\chi}_B$ を用いると、投影パターン Ξ および境界物体群 B を未知のフラクタルアトラクターとして捕獲する確率をつぎのように生成することができる¹⁷⁾。

$$\frac{1}{2}\Delta\varphi(\omega|\nu) = \rho[\hat{\chi}_\Xi^p - \varphi(\omega|\nu)], \quad (9a)$$

$$\frac{1}{2}\Delta\varphi_b(\omega|\nu_b) = \rho_b[\hat{\chi}_B - \varphi_b(\omega|\nu_b)]. \quad (9b)$$

ただし、 $\varphi(\omega|\nu)$ および $\varphi_b(\omega|\nu_b)$ はそれぞれ Ξ および B の捕獲確率であり、式中の ρ および ρ_b は ν および ν_b による写像過程の複雑さを表わすパラメータ¹⁶⁾である。Fig. 1のように、総称的に形態が定まる道路領域に対しては、 $\rho = \log_2 \|\nu\| = 1.585$ と定める。ここで $\|(\cdot)\|$ は集合 $(\cdot)$ のサイズを表わす。一方、さまざまな形態の物体が散在する境界分布に関しては、人間の視覚系がフラクタル次元 1.3 をもつシルエット風景に親和性を示すことに着目して⁷⁾, $\rho_b = 1.3$ と定める。

推定測度 $\hat{\chi}_\Xi^p$ および $\hat{\chi}_B$ の幾何学的複雑さにかかわらず、(9) 式は、 ν , ν_b の決定に先行して滑らかな分布 $\varphi(\omega|\nu)$ および $\varphi_b(\omega|\nu_b)$ を生成する。以下、分布 $\varphi_b(\omega|\nu_b)$ の確率的複雑さにもとづいて推定測度から境界物体を分離する¹⁸⁾。さて、

Fig. 10 $\varphi_{\Xi \setminus B}(\omega|\nu)$ -distribution

分布 $\varphi_b(\omega|\nu_b)$ の確率的複雑さは、つぎのように評価することができる。

$$H_b = \mathcal{E}\{-\log p_b(\omega|\nu_b)\}, \quad (10a)$$

$$p_b(\omega|\nu_b) = C_b \varphi_b(\omega|\nu_b),$$

ただし C_b は正規化定数である。この H_b は、ノイズのみからなる画像のもつエントロピー H_0 から、境界分布の情報分だけ減少することになる。この情報を最大エントロピー基準のもとで評価することにより、境界物体の分布領域はつぎのように限定される。

$$\hat{B} = \left\{ \omega \in \Omega \mid \varphi_b(\omega|\nu_b) \geq \partial\varphi_b \right\}, \quad (10b)$$

$$\log \partial\varphi_b = 1 - \frac{1}{2} \left(1 - e^{H_b - H_0} \right) - H_0.$$

(10) 式にもとづく分離結果を Fig. 9 および Fig. 10 に示す。ここで、Fig. 9 は (9a) 式により生成した捕獲確率 $\varphi(\omega|\nu)$ を示し、Fig. 10 は $\partial\varphi_b$ を用いた分布 $\varphi(\omega|\nu)$ の制限

$$\varphi_{\Xi \setminus B}(\omega|\nu) = \begin{cases} \varphi(\omega|\nu); & \varphi_b(\omega|\nu_b) < \partial\varphi_b, \\ 0; & \text{otherwise,} \end{cases} \quad (11)$$

を示す。Fig. 9 は捕獲確率 $\varphi(\omega|\nu)$ を通して道路領域と境界物体の配置を観測できることを示している。一方 Fig. 10 は滑らかな分布 $\varphi(\omega|\nu)$, $\varphi_b(\omega|\nu_b)$ にもとづいて道路領域を制限する境界物体を分離できることを示している。これらの図より、個別的物体識別に先行して道路-境界構造を同定できることがわかる。

5. 自己相似則のデザイン

Fig. 1 に現れるフラクタルアトラクターはつぎのタイプの縮小画像群 ν を用いて生成することができる。

$$\nu = \{\mu_i\}, \quad (12a)$$

$$\mu_i(\omega) = \frac{1}{2}[\omega + \omega_{\mu_i}^f]. \quad (12b)$$

ただし、 $\omega_{\mu_i}^f$ は画像 μ_i の不動点である。すなわち、道路領域 Ξ の同定は情景画像から消失点、左右の道路端に対応する不動点を推定する問題に帰着する。さて、滑らかな分布 $\varphi_b(\omega|\nu_b)$

Fig. 11 Vanishing point based on $\varphi_b(\omega|\nu_b)$

を用いると、Fig. 11 に示すように、道路境界を2値パターンとして可視化することができる。ここでは、画面下端から上端に向かって左右の境界パターンを走査することにより、Fig. 2 に示す道路領域に対応する不動点集合 $\hat{\Omega}^f = \{\hat{\omega}_{\mu_i}^f\}$ の初期仮定値を検出している。本章では、この推定値 $\hat{\Omega}^f$ を未知の道路領域 Ξ に適応させるアルゴリズムを導く。

画像 μ_i の縮小性より、画面 Ω は各不動点 $\hat{\omega}_{\mu_i}^f$ に対応する部分集合 Λ_i に分割される。ただし、

$$\Lambda_i = \left\{ \omega \in \Omega \mid |\omega - \hat{\omega}_{\mu_i}^f| < |\omega - \hat{\omega}_{\mu_j}^f|, \right. \\ \left. \text{for } \hat{\omega}_{\mu_j}^f \neq \hat{\omega}_{\mu_i}^f \right\}, \quad (13a)$$

である。捕獲確率 $\varphi(\omega|\nu)$ を用いて分割 $\{\Lambda_i\}$ に対する平均値と分散をつぎのように評価することにより、

$$\bar{\omega}_i: \int_{\Lambda_i} (\omega - \bar{\omega}_i) dP(\omega|\nu) = 0, \quad (13b)$$

$$\Sigma_i = \int_{\Lambda_i} (\omega - \bar{\omega}_i)(\omega - \bar{\omega}_i)^T dP(\omega|\nu), \quad (13c)$$

$$dP(\omega|\nu) = \begin{cases} \varphi(\omega|\nu) dP(\omega); & \varphi_b(\omega|\nu_b) < \partial\varphi_b, \\ 0; & \text{otherwise,} \end{cases}$$

未知アトラクターのひとつのコラージュ近似がつぎのように得られる。

$$\Lambda_i^{\oplus} = \left\{ \lambda \in \Lambda_i \mid \left(\frac{1}{2} \varepsilon_i^T \Sigma_i^{-1} \varepsilon_i - 1 \right) < 0 \right\}, \quad (14)$$

ただし、 $\varepsilon_i = \lambda - \bar{\omega}_i$ である。

画像群 (12) が、Fig. 12 に示すようにコラージュパターン $\Lambda_i^{\oplus}$ を再生するとき、不動点集合 $\hat{\Omega}^f$ はつぎの幾何学的拘束をみたす (付録 A 参照)。

$$\partial_i - \bar{\omega}_i = -Q_i^{-1} K_{ji} \left(\hat{\omega}_{\mu_i}^f - \bar{\omega}_i \right), \quad (15a)$$

$$Q_i = \left(\vec{\Omega}_{ji}^{\oplus} \right)^T R \vec{\Omega}_{ji}^f, \quad (15b)$$

Fig. 12 Collage pattern controlled by fixed points

$$K_{ji} = \tilde{\Omega}_{ji}^o \left(\tilde{\Omega}_{ji}^f \right)^T R, \quad (15c)$$

$$\tilde{\Omega}_{ji}^o = \partial_i - \bar{\omega}_i, \quad \tilde{\Omega}_{ji}^f = \hat{\omega}_i^f - \bar{\omega}_i^f.$$

ただし, ∂_i は $\tilde{\Omega}_{ji}^f$ と Λ_i^o の接点を表わし,

$$R = \begin{bmatrix} \cos(\pi/2) & -\sin(\pi/2) \\ \sin(\pi/2) & \cos(\pi/2) \end{bmatrix},$$

である. 推定値 $\hat{\omega}_{\mu_i}^f$ に対応する接点 ∂_i の誤差を

$$\phi_{\mu_i} = \frac{1}{2}(\partial_i - \bar{\omega}_i)^T \Sigma_i^{-1}(\partial_i - \bar{\omega}_i) - 1,$$

と計量しよう. このとき,

$$d\phi_{\mu_i}^2 = 2\phi_{\mu_i} \left(\hat{\omega}_{\mu_i}^f - \bar{\omega}_i \right)^T M_{ji}^j d\hat{\omega}_{\mu_i}^f,$$

$$M_{ji}^j = K_{ji}^T (Q_i^{-1})^T \Sigma_i^{-1} Q_i^{-1} K_{ji},$$

と表現できることに注意すると, $\hat{\omega}_{\mu_i}^f$ を逐次更新するアルゴリズムがつぎのように得られる.

$$d\hat{\omega}_{\mu_i}^f = -\alpha \phi_{\mu_i} (\hat{\omega}_{\mu_i}^f - \bar{\omega}_i). \quad (16)$$

ここに, $\alpha > 0$ は調整用定数である. このアルゴリズムでは, 各推定値 $\hat{\omega}_{\mu_i}^f$ は対応する接点 ∂_i の推定誤差を分散的に最小化するように調整されることになる.

$$\sum_{\mu_i \in \nu} |\phi_{\mu_i}|^2 \rightarrow \min.$$

6. 実装と実験

推定測度 $\hat{\chi}_{\Xi}^p, \hat{\chi}_B$ にもとづく道路領域同定アルゴリズムを商用 cpu (MobileCeleron, Pentium4, Core7, いずれも Intel 社製品) 上のソフトウェアシステムとして実装し, 実情景画像を用いた機能確認実験を行なった. 実験システムは道路領域同定機能の確認に主眼を置いて開発したが, 実時間実行可能性の指針を得る目的で, フラクタル同定の計算負荷を, cpu 向きの random logic と専用ハードウェア向きの局所並列演算に分けて測定した. 本システムは, まず, (5) 式を用いてスケール情報を抽出し, 推定測度 $\hat{\chi}_{\Xi}^p, \hat{\chi}_B$ を計算する. 本実験では, Fig. 6 にもとづいて, $\kappa = 2$ とし, 消失点の初期仮定値は画面中央としている. ついで, (9) 式を用いて捕獲確率

Fig. 13 Invariant feature associated with ν

Fig. 14 Fractal attractor (shopping street)

$\varphi(\omega|\nu)$ および $\varphi_b(\omega|\nu_b)$ を生成し, 不動点集合 $\hat{\Omega}^f = \{\hat{\omega}_{\mu_i}^f\}$ の初期配置を求める. 最後に, (13)~(16) 式を用いて $\hat{\omega}_{\mu_i}^f$ を更新し, 写像群 $\nu = \{\mu_i\}$ をデザインする. 得られた ν と道路領域 Ξ のフラクタルパターンとしての整合性是不変特徴の検出を通して確認する¹⁶⁾. 上記手順はすべて C 言語を用いて記述した. 分布情報 ($\hat{\chi}_{\Xi}^p, \hat{\chi}_B$) および ($\varphi(\omega|\nu), \varphi_b(\omega|\nu_b)$) を生成するプログラムサイズは約 40 KB (1,320 行) であり, 不動点 $\hat{\Omega}^f$ を推定し写像群 ν をデザインするプログラムサイズは約 27 KB (780 行) であった. また, 不変特徴の検出手順の記述には約 12 KB (420 行) を要し, 全プログラムをコンパイルしたシステムのサイズは, X window などの基本関数も含めて, 435 KB であった. 以下の実験では, 640×480 画素に JPEG 圧縮された情景画像を用いている.

Fig. 2 に示す情景画像に以上の手順を適用して決定した写像群を Fig. 13 および Fig. 14 に示す. Fig. 13 は, 生成されたアトラクターと推定測度 $\hat{\chi}_{\Xi}^p$ の一致性を表現している. ここでは, 対応する捕獲確率 $\varphi(\omega|\nu)$ の極大点集合 $\tilde{\Theta}$ 上に次式で定義される ν に関する不変集合

$$\Theta = \left\{ \theta \in \tilde{\Theta} \mid \exists \mu_i \in \nu : \mu_i^{-1}(\theta) \in \Theta \right\}, \quad (17)$$

が形成されている. 図中, ● は不変集合 Θ の構成点 θ を示す. これら θ は少なくともひとつの $\mu_i \in \nu$ により相互に結びつけられている. すなわち, $\Theta \neq \emptyset$ の存在は, 未知の投影

Fig. 15 Fractal attractor (crossing)

Fig. 17 Fractal attractor (pathway)

Fig. 16 Fractal attractor (loading lot)

Fig. 18 Fractal attractor (riverbank)

Fig. 19 Fractal attractor (a break)

パターン Ξ が、デザインされた ν に関する連結パターンを含むための必要条件を与える。この連結領域は、Fig. 12 に示す不動点配置より、分布 $\varphi_{\Xi \setminus B}(\omega|\nu)$ の台上に構成される。また、写像 M_ν の縮小性より、 Ξ のすべての構成点は ν 上の合成写像を介して Θ と結びついている。このように、離散集合 Θ の検出を通して、フラクタルモデルの構造的、幾何学的整合性を事前評価できる。実際、Fig. 14 に示すように、 $\Theta \neq \emptyset$ をみたす写像群は、ランダムな境界物体を避けるひとつの連結道路領域をパラメトリックに表現する。

本実験では、消失点の初期仮定値を用いてモデル (7) を設定している。ただし、 $\varphi_b(\omega|\nu_b)$ にもとづく消失点を用いてモデルを修正しても、不動点配置 $\hat{\Omega}^f = \{\hat{\omega}_{\mu_i}^f\}$ は Fig. 11 からほとんど変化しなかった。これは、境界検出基準 (8) のスケール変移モデル (7) に対する頑健性を示している。

Fig. 15～Fig. 19 に他の自然情景での道路領域検出結果を示す。Fig. 15 および Fig. 16 では、消失点が初期仮定どおりほぼ画面中央に現れており、ほぼ正確に道路領域をフラクタルパターンとして同定している。これらの情景では、かなりコントラストの強い影が観測されているが、スケール変移則の当てはめにはほとんど影響を与えていない。ただし、Fig. 15 で、前方に出現する車両は breakdown pixel を生成するため、Fig. 16 に比べて、奥行きは短くモデル化されている。Fig. 17 は消失点が道路の方向と大きく異なる場合の検出結果を示す。

この場合も消失点は手前に推定され、結果として路面の奥行きは過小評価されている。ただし、路面に描かれた標識線は、影と同様、境界分布の検出に影響を与えていない。Fig. 18 および Fig. 19 は下向きのカメラで撮影した場合の検出結果を示す。これらの図より、消失点が画面内に捕捉できる程度の傾きに対しては、breakdown 情報 $\hat{\chi}_B$ はほぼ境界物体の分布を反映していることがわかる。また、Fig. 19 に示すように、比較的近距离の範囲では、Fig. 15、Fig. 16 の場合と同様、物体と影もスケール情報にもとづいて分離されている。ただし、極端な近距离で道路領域が遮られた場合の推定消失点の意味付けには検討の余地が残されている。

Table 1 Finite invariant analysis

scene	$\ \Theta\ $	$\ \tilde{\Theta}\ $	$\ \Theta\ /\ \tilde{\Theta}\ (\%)$
shopping street	53	1089	4.86
crossing	46	1296	3.55
loading lot	115	1190	9.66
pathway	121	1262	9.59
riverbank	299	1465	20.41
a break	144	1454	9.90

Table 2 Geometric consistency

scene	$\ \Xi\ $	$\bar{\varphi}_{\Xi}$	$\bar{\varphi}_{\Xi \setminus B}$	$\bar{\varphi}$
shopping street	7027	142.0396	123.5	54.2
crossing	2036	168.2708	118.0	21.9
loading lot	3133	142.9437	112.9	25.7
pathway	4981	103.0405	70.2	35.6
riverbank	4807	116.3374	109.3	54.1
a break	327	142.7581	76.7	17.4

本論文では, breakdown 情報 $\hat{\chi}_B$ にもとづく消失点および“足元での拡がり”を特徴点としてフラクタルモデルをデザインしている. これら低水準の特徴点は, Fig. 17 から読み取れる“車線の方角”のような高次記述とは必ずしも一致しない. また, Fig. 18, Fig. 19 にも示されるように, 画面内統計量 (13) にもとづく消失点推定 (Fig. 12) はアトラクターの画面外への拡がりを過小評価する傾向がある. このような正確な形状の定義が容易でない場合も含めて, Fig. 1 の総称的対応関係を参照するフラクタル同定アルゴリズムは道路領域に含まれる連結領域の存在を判定している.

道路領域検出アルゴリズムの検証結果の要約を **Table 1** に示す. 表中, $\|\cdot\|$ は集合 $(\cdot)$ のサイズを表わす. 本章で述べた実験では, 640×480 画素の情景写真から Table 1 に示すように, 1,000 点程度の極大点集合 $\tilde{\Theta}$ が抽出され, 再帰的拘束条件 (17) を充足する θ を逐次近似するアルゴリズム¹⁶⁾に従って縮小写像群の存在が検証されている. これは, 検出領域の連結性が画像サイズの 0.3~0.5% 程度に圧縮されたデータにもとづいて判定できることを意味する. また, 極大点集合 $\tilde{\Theta}$ のサイズは 1,000 ~ 2,000 に留まるため, Θ の検出アルゴリズムは 10 回程度の繰り返しで停止する.

推定写像群 ν による道路領域の被覆性を評価した結果を **Table 2** に示す. ここで, $\bar{\varphi}_{\Xi}$ および $\bar{\varphi}$ は, それぞれ, 捕獲確率 $\varphi(\omega|\nu)$ の Ξ 上, および前画面 Ω 上での平均値であり, $\bar{\varphi}_{\Xi \setminus B}$ は, 制限 $\varphi_{\Xi \setminus B}(\omega|\nu)$ の平均値を示す. これら $\varphi, \varphi_{\Xi \setminus B}$ の値は 0 ~ 255 に正規化している. 本表は, 未知境界物体を除去したときの捕獲確率が 2 ~ 5 倍程度に高まること, および, 領域を $\Xi \rightarrow \Xi \setminus B$ に拡張しても, 捕獲確率の低下は, おおむね 6 ~ 30% 程度に留まること, を示している. これは, 写像群 ν を用いて, 連結道路領域のかなりの部分を生成できることを意味する. 逆に, Fig. 19 のように, 単一長方形の投影領域としてのモデル化が適切でない場合には, $\bar{\varphi}$ は大幅に低下する.

Table 3 に実験システムによる計算時間を示す. すなわち, 本同定アルゴリズムでは, 総計算時間 854 ~ 5,522 ms

Table 3 Computation time (ms)

cpu/linux kernel	locally parallel	random logic
IntelCore7×8 2.6.27-71v15	805	49
IntelPentium4 2.6.16-76.55v14	2456	164
MobileIntelCeleron 2.6.16-76.55v14	5158	364

中 93% 程度を局所並列処理に費やしている. このうち, 偏微分方程式 (9) の積分に要する時間は半分程度を占めている. この傾向は, CPU のハードウェア性能にあまり依存しない.

7. 検 討

本論文では, 自然情景に普遍的に潜在する自己相似則を前提としてノイズ情報を組織化し, 遠近感を総称的に表現している. 微細凹凸に由来するスケール情報は, Fig. 6 に示すように, 物体表面ごとの平均的明暗レベルに対して独立とみなせる. 結果として, 線形変移モデル (7) にもとづいて導出された道路領域検出アルゴリズムは装飾パターン (Fig. 2), 陰影 (Fig. 15, Fig. 16), 標識 (Fig. 17) などの影響をあまり受けないものとなっている. このような頑健性を有するスケール情報は物体検出に重要な役割を果たすことが知られている^{19), 20)}. 従来研究では, difference-of-Gaussian 演算にもとづいてスケール変化が評価されていた. これに対して本研究では, 撮像過程での小スケール拡散を前提とした $f_{\omega} \sim \Delta f_{\omega}$ 相関を用いて線形変移モデルの適合確率を評価している. 全画面に偏微分作用素を適用するタイプの計算は, 偏微分方程式の積分も含め, 比較的単純なハードウェアにより実時間実行可能である^{21), 22)}. さらに, 不変特徴 (17) が偏微分方程式 (9) の動的解に先行して収束すること¹⁶⁾および, 商用 cpu にもハードウェアレベルでの並列化技術が採り入れられていることを考慮すると, 得られたフラクタル同定システムは, 移動にもなつてなめらかに変化する領域の実時間検証に適したものとなっている.

フラクタル逆問題は, 画像符号化^{9), 10)}の観点からとり上げられてきた^{11), 12)}. ただし, 従来方法でパラメトリックに推定した自己相似則を用いて複雑な対象領域の連結性を表現することは容易ではない. また, フラクタル次元をノンパラメトリックに推定するアプローチ²³⁾を用いた場合には, 得られたフラクタル特徴量の分布を連結領域として統合する処理を必要とする. これに対して本論文で述べた方法では, 未知形態の生成情報を含む確率的特徴 $\tilde{\Theta}$ を自己相似則検出の手がかりとして用いる. このような対象依存型の特徴点上で自己相似性をテストする結果として, 探索領域は bottom-up 的に定まる. また, 得られた検出領域の連結性は命題 $\Theta \neq \emptyset$ として陽表現され, 連結領域の被覆性は, $\bar{\varphi}$ を尺度として事前評価できる. すなわち, 本論文で導入したアルゴリズムは構造的, 幾何学的整合性に関する自己検証能力を備えている.

このような計算機実現上の利点をもつ半面, 上限推定 $\hat{\sigma}_{\omega}$ は

弱い制約であり、特定物体の奥行きを計量するものではない。本論文では、路面情報 $\hat{\chi}_B^p$ と $\hat{\sigma}_\omega$ に関して対立する breakdown 情報 $\hat{\chi}_B$ を抽出し、道路を意味的に分離するアプローチを採用している。この際、検出領域の連結性を縮小画像群 (12) で陽に表現することにより、滑らかな捕獲確率分布 φ, φ_b にもとづく消失点の安定な推定が可能となる。結果として、Fig. 14, Fig. 15~Fig. 19 に示すようなさまざまな自然情景に含まれるフラクタルモデルが、形状の認識に先行して同定されている。

ただし、(7) および (8) 式に示すように、情報 ($\hat{\chi}_B^p, \varphi$) および ($\hat{\chi}_B, \varphi_b$) は物体表面に実在するノイズパターンが提示するスケール ($\leq \hat{\sigma}_\omega$) に関して論理的に対立しているわけではない。これは、遠近感の成立領域と breakdown 領域が共有するランダム成分を通して境界物体を識別するメカニズムの存在を示唆する²⁴⁾。とくに、情報 ($\hat{\chi}_B, \varphi_b$) は、(9) に示すように ν_b の記述を経由することなく生成できるため、散在する多様な自己相似パターンに適合する自由度を保持している。生体の網膜システムには、比較的弱い入射光にも即応する明暗情報処理系と入射光の蓄積を必要とする色彩情報処理系が共存することが知られている²⁵⁾。本論文で導入した推定測度 $\hat{\chi}_B^p$ および breakdown 情報 $\hat{\chi}_B$ は、明暗分布のみから計算可能であり、これらにもとづいて同定される道路-境界構造は色彩情報処理系による物体識別プロセスを起動する契機となりうる。このような境界物体の分節化については、稿を改めて報告する。

8. おわりに

複雑な自然情景に含まれる道路領域を直截的に知覚するメカニズムの計算機実現を目的に、境界物体に囲まれた連結平面をフラクタルアトラクターとして同定するアルゴリズムを導出した。本論文では、ノイズスケール上での遠近感表現にもとづいて道路領域上の不変測度を推定し、自然情景に普遍的に潜在する自己相似メカニズムをデザインしている。ノイズスケールのみを用いて物体配置を特定することはできないが、スケール変移則と情景の総称的構造に条件付けられた捕獲確率は安定な消失点を与え、得られた同定アルゴリズムはさまざまな自然情景の奥行き推定に適用できる。不変測度の推定基盤をさまざまな特徴分布上に拡張し、同定アルゴリズムを境界物体の識別に適用することは、今後の課題である。

参考文献

- 1) I. Masaki (Ed.): *Vision-based Vehicle Guidance*, Springer-Verlag, New York, New York (1991)
- 2) Ü. Özgner and C. Stiller: Systems for safety and autonomous behavior in cars, The DARPA grand challenge experience, *Proceedings of the IEEE*, **95-2**, 397/411 (2007)
- 3) J.J. Gibson: *The Ecological Approach to Visual Perception*, Houghton Mifflin Company, Boston, Massachusetts (1979)
- 4) D. Marr: *Vision: A Computational Investigation into the Human Representation and Processing of Visual Information*, W.H. Freeman and Company, San Francisco, California (1982)
- 5) B. Libet: The neural time factor in conscious and unconscious events, *Ciba Foundation Symposium*, **174**, 123/146, John Wiley and Sons, New York, New York (1993)
- 6) R. Reber, N. Schwarz and P. Winkielman: Processing fluency and aesthetic pleasure: Is beauty in the perceiver's processing experience?, *Personality and Social Psychology Review*, **8**, 364/382 (2004)
- 7) C. Hagerhall, T. Purcell and R. Taylor: Fractal dimension of landscape silhouette outlines as a predictor of landscape preference, *Journal of Environmental Psychology*, **24-2**, 247/255 (2004)
- 8) K. Kamejima: Stochastic design of imaging parameters for self-similar patterns, *Nonlinear Analysis, Theory, Methods and Applications*, **30-4**, 2231/2236 (1997)
- 9) M.F. Barnsley and L.P. Hurd: *Fractal Image Compression*, AK Peters, Wellesley, Massachusetts (1993)
- 10) A.E. Jacquin: Image coding based on a fractal theory of iterated contractive image transformations, *IEEE Transactions on Image Process.*, **IP-1-1**, 18/30 (1992)
- 11) T. Ida and Y. Sambonsugi: Image segmentation using fractal coding, *IEEE Transactions on Circuit and Systems for Video Technology*, **5-6**, 567/570 (1995)
- 12) T. Ida and Y. Sambonsugi: Self-affine mapping system and its application to object contour extraction, *IEEE Transactions on Image Process.*, **9-11**, 1926/1936 (2000)
- 13) J.E. Hutchinson: Fractals and self similarity, *Indiana University Mathematical Journal*, **30**, 713/747 (1981)
- 14) M.F. Barnsley, V. Ervin, D. Hardin and J. Lancaster: Solution of an inverse problem for fractals and other sets, *Proceedings of the National Academy of Science, USA*, **83-7**, 1975/1977 (1986)
- 15) M.F. Barnsley: *Fractals Everywhere*, second edition, Academic Press, Cambridge, Massachusetts (1993)
- 16) 亀島鉦二: マルチスケール画像解析にもとづく自己相似性の検出, 計測自動制御学会論文集, **46-2**, 114/122 (2010)
- 17) K. Kamejima: Generic representation of self-similarity via structure sensitive sampling of noisy imagery, *Electronic Notes in Theoretical Computer Science*, **46**, 225/244 (2001)
- 18) K. Kamejima: Self-similarity detection in noisy feature distribution, *Proceedings of the 31st ISICIE International Symposium on Stochastic Systems Theory and Its Applications (SSS'99)*, 301/306 (2000)
- 19) J.L. Crowley and A.C. Parker: A representation for shape based on peaks and ridges in the difference of low-pass transform, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **PAMI-6-2**, 156/170 (1984)
- 20) D.G. Lowe: Distinctive image features from scale-invariant keypoints, *International Journal of Computer Vision*, **60-2**, 91/110 (2004)
- 21) K. Kamejima, Y. Hosoda, Y. Nakano, M. Fujie, T. Iwamoto, K. Honma and T. Yoshida: Navigation apparatus for mobile system, United States Patent 4, 628, 453 (1986)
- 22) K. Kamejima, Y.C. Ogawa and Y. Nakano: A fast algorithm for approximating 2D diffusion equation with application to pattern detection in random image fields, *Proceedings of IMACS/IFAC International Symposium on Modelling and Simulation of Distributed Parameter Systems*, 149/156 (1987)
- 23) H. Kaneko: Fractal matrix model and its application to texture analysis, *Transactions of IECE of Japan*, **E71**, 1221/1228 (1988)
- 24) K. Kamejima: Perceptual equivalence of environmental saliency in naturally complex scene, *Proceedings of SICE*

Annual Conference 2010 (SICE2010), 736/741 (2010)

25) M. Ebner: *Color Constancy*, John Wiley and Sons, West Sussex, UK (2007)

《付 録》

A. フラクタルクラスティング

写像群 (12) がコラージュパターン (14) を再生するためには, 不動点集合 $\hat{\Omega}^f$ はつぎの幾何学的拘束をみたす必要がある.

$$\left(\vec{\Omega}_{ji}^f\right)^T R\left(\partial_i - \hat{\omega}_{\mu_i}^f\right) = 0, \quad (\text{A.1})$$

$$\left(\vec{\Omega}_{ji}^\partial\right)^T R\left(\partial_i - \bar{\omega}_i\right) = 0. \quad (\text{A.2})$$

ここで ∂_i での外向き法線ベクトル $\vec{\Omega}_{ji}^\perp$ が

$$\vec{\Omega}_{ji}^\perp = \pm R\vec{\Omega}_{ji}^f, \quad \vec{\Omega}_{ji}^\partial = \pm \Sigma_i \vec{\Omega}_{ji}^\perp,$$

をみたすことに注意して, つぎの関係

$$\left(\vec{\Omega}_{ji}^f\right)^T R\left(\partial_i - \bar{\omega}_i\right) + \left(\vec{\Omega}_{ji}^\partial\right)^T R\left(\bar{\omega}_i - \hat{\omega}_{\mu_i}^f\right) = 0,$$

$$\partial_\omega - \hat{\omega}_{\mu_i}^f = \partial_\omega - \bar{\omega}_i + \bar{\omega}_i - \hat{\omega}_{\mu_i}^f,$$

を組み合わせると,

$$\begin{aligned} & \left[\vec{\Omega}_{ji}^\partial \left(\vec{\Omega}_{ji}^f\right)^T - \vec{\Omega}_{ji}^f \left(\vec{\Omega}_{ji}^\partial\right)^T \right] R(\partial_\omega - \bar{\omega}_i) \\ &= \vec{\Omega}_{ji}^\partial \left(\vec{\Omega}_{ji}^f\right)^T R\left(\hat{\omega}_{\mu_i}^f - \bar{\omega}_i\right), \end{aligned} \quad (\text{A.3})$$

が得られる. さらに,

$$\begin{aligned} & \vec{\Omega}_{ji}^\partial \left(\vec{\Omega}_{ji}^f\right)^T - \vec{\Omega}_{ji}^f \left(\vec{\Omega}_{ji}^\partial\right)^T \\ &= \begin{bmatrix} 0 & -\left(\vec{\Omega}_{ji}^\partial\right)^T R\vec{\Omega}_{ji}^f \\ \left(\vec{\Omega}_{ji}^\partial\right)^T R\vec{\Omega}_{ji}^f & 0 \end{bmatrix} \\ &= \left(\vec{\Omega}_{ji}^\partial\right)^T R\vec{\Omega}_{ji}^f R, \end{aligned}$$

と書き換えると, (15) 式が得られる.

[著 者 紹 介]

亀 島 鉦 二 (正会員)

1949 年 2 月 7 日生. 73 年京都工芸繊維大学工学研究科修士課程修了. (株)日立製作所中央研究所, 機械研究所を経て 94 年より大阪工業大学教授. 機械システムならびに協働情報システムの制御に関する研究に従事. 工学博士, IEEE, システム制御情報学会, 機械学会などの会員.