

# 特徴空間の部分空間を用いた 繰り返しパターンの検出と画像間の対応付け

丹野 芳樹<sup>1,a)</sup> 金澤 靖<sup>1,b)</sup>

**概要:** 本論文では、規則的な繰り返しパターンを含むシーンの3次元復元を行うために、繰り返しパターンの特徴量空間を利用したパターン平面の検出法と対応付け法を提案する。シーン内のタイルやレンガなど規則的な繰り返しパターンを含む画像は、従来より対応付けが難しいものとされている。坂本らは、繰り返しパターンの要素に関する特徴量空間の部分空間を利用した繰り返しパターン領域の検出と対応付けを行ったが、様々な繰り返しパターンに柔軟に対応できるものではなかった。そこで本研究では、特徴量空間内において、幾何学的 AIC を用いた幾何学的なクラスタリングを行うことにより、繰り返しパターン検出し、その後、部分空間間の重ね合わせにより、対応付けを行う方法を提案する。実画像を用いた実験により、提案法の有効性を示す。

## 1. はじめに

画像間の対応付けは、多視点画像からの3次元復元やモザイク合成など、コンピュータビジョンの多くの技術において、最も基本かつ重要な技術である [2], [9], [11], [12], [13], [14]。画像間の対応付けが難しいとされる代表的なものの一つが規則的なパターンを含むシーンの画像である。このようなシーンは建物の窓や壁のタイル、道路のレンガなど、市街地のシーンに数多く存在する。したがって市街地のシーンにおいては、画像間の対応付けが難しくなることも多い。その一方で、これらの規則的なパターンからは建物の壁の向きがわかったり、また建物自体の特徴となるなど、シーン理解においても有用な情報となっている [3], [15], [16]。

このような規則的なパターンを含むシーンの画像では、一般にキーポイントなどの特徴点は大量に検出されるが、逆にその規則性のために、異なる視点の画像間の異なる位置の類似度が高くなり、誤った対応が得られることも多い。例えば、図 1(a) の画像に対し、SIFT[11] で対応付けを行った結果を図 1(b) に示す。この図 1(b) は同図 (a) の左右の画像の対応する特徴点を結んだもの (フロー) を示している。見てわかる通り、SIFT[11] を用いても正しい対応はわずかしか検出できない。

本研究では、この繰り返しパターンの規則性を利用し、

まずパターン要素の特徴量空間における幾何学的なクラスタリングにより繰り返しパターン領域を検出する。そして、各部分空間を画像間で重ね合わせることで、画像間の対応付けを行う方法を提案する。そして実画像を用いた実験により、提案法の有効性を示す。

## 2. 関連研究

SIFT[11] は、画像中のキーポイントの検出とその特徴量の記述を行うアルゴリズムであり、スケールと回転、照明変化にロバストなキーポイントの検出と特徴量記述が行える。このため、画像間の対応付けだけでなく、物体認識などにも広く利用されている。さらに、SIFT から派生した対応付け法も多く提案されている [2], [9]。これらはいずれも相似不変量を採用しているため、視点の位置の変化が大きくなると特徴量が変化してしまい、対応付けの精度が低下する。これに対し、アフィン不変特徴量を用い、視点位置の変化の大きな画像に対応させた手法も提案されている [12], [13], [14]。これらの不変量を用いた対応付けは、個々の特徴記述が一般に異なっていることを前提としている。したがって、市街地シーンのように窓や壁など、極めて規則的な繰り返しパターンが存在すると、図 1 に示したように、そのパターン内部では個々の箇所の区別ができずに対応付けに失敗してしまう。

一方で、画像内に含まれる規則的なパターンはそのシーンに関する極めて有効な特徴であり、従来より、多くの検出手法が提案されている [3], [15], [16]。Park ら [16] は、KLT[20] を使って画像から特徴点を検出後、検出点周辺の

<sup>1</sup> 豊橋技術科学大学 情報・知能工学系。Department of Computer Science and Engineering, Toyohashi University of Technology, Japan.

a) y-tanno@img.cs.tut.ac.jp

b) kanazawa@cs.tut.ac.jp



図 1 繰り返しパターンを含むシーンの例. (a) 原画像. (b) SIFT[11] による対応付けの結果.

画素を要素としたクラスタリングにより、繰り返しの要素をグルーピングし、グループ内の要素を基準とし格子モデルを生成し、同一画像内においてそのモデルを追跡することで、画像内の規則性パターンを格子状に検出した。さらに Park ら [15] は、KLT[20], MSER[12], SURF[2] を組合せて利用し、それらに対する並進対称性を利用して同一画像中に含まれる複数の規則的パターンを分けて検出する手法を提案した。Doubek ら [3] は、Park ら [16] を基に SIFT 特徴量で記述された MSER 領域を用いて繰り返しパターン要素を検出後、その SIFT 特徴量をクラスタリングすることで繰り返しパターン領域を検出し、それらからパターンに対する並進不変量を求めることで、画像検索に応用した。これらはいずれも画像内から繰り返しパターンを検出することのみに着目しており、視点の異なる画像間での対応付けを目的としていない。

これらに対し、Kamiya ら [6] は、レンガやタイルなどを規則的パターンを含むシーンの 3 次元復元を行うことを目的とした対応付け法を提案した。彼らは、まず画像を繰り返しパターン領域とそうでない領域に分けることで、繰り返しパターン領域内での誤った対応付けが他の領域の対応に影響することを避け、それぞれ異なるアプローチで対応付けを行った。そして、従来の対応付けが不得手とする、シーン内に大きな繰り返しパターン領域がある場合には有効であることを示したが、その計算コストが高く、実用的でないという問題があった。坂本ら [18] は、この Kamiya ら [6] の研究をベースとし、特徴量空間における部分空間当てはめによって繰り返しパターン領域を検出するだけでなく、異なる画像間の異なる特徴量空間での変換を求めたことで、対応付けが可能であることを示した。更に、その拡張として、坂本ら [19] では、特徴空間における階層的クラスタリングを用いる方法を提案したが、階層数または閾値を画像毎に適切に定める必要があり、様々シーンに容易に対応できるものではないという問題があった。

### 3. 繰り返しパターンと特徴量空間

本論文では、画像内の繰り返しパターンを検出するために、坂本らの手法 [18], [19] と同様に、画像内の繰り返しパターンを構成する要素に対する複数の特徴量を定義し、それらを用いて特徴量空間を定義する。そして、その空間を用いて、単一画像内での繰り返しパターン領域の要素の

グルーピングによる繰り返しパターン領域の検出を行うことを考える。ここでは、繰り返しパターン領域の要素として、内部の濃淡変化がほぼ一定である領域を考え、以下のような仮定を置く。

- 同一パターンの要素は 3 次元空間内ではほぼ同一の平面上に載っている。
- 同一パターンの要素の面積は 3 次元空間内ではほぼ等しい。
- 同一パターンの要素内の画素の平均輝度および分散はほぼ等しい。
- パターン自身の奥行きに対し、カメラからパターンまでの距離は十分長い。

パターンの要素  $p$  に対し、以下の特徴量を計算する。

- 要素の重心位置 (画像上の) :  $(u_p, v_p)$
- 要素の面積 (画素数) :  $S_p$
- 要素内の画素の平均輝度:  $m_p$

これらの特徴量を用いて、それぞれを各軸に持つ 4 次元空間を定義し、その要素を 4 次元空間内のベクトル

$$\mathbf{p}_p = (u_p, v_p, S_p, m_p) \quad (1)$$

で表す。特徴量空間の例を図 2 に示す。図 2 において、図 2(a) の画像に対し、画像から輝度のほぼ一樣な小領域を検出した結果が図 2(b) であり、その特徴量をプロットした結果が図 2(c) である。ただし図 2(c) では輝度  $m_p$  の軸を無視し、残る 3 次元空間でプロットしている。この特徴量空間は次のような性質を持つ。

- 同じ繰り返しパターンの要素に含まれる画素の平均輝度あるいは輝度分散はほぼ等しい。
- カメラから近い要素は大きく、遠い要素は小さく画像上に投影され、要素の重心位置および面積 (画素数) の分布は 3 次元空間内の位置に関してほぼ線形な関係を持つ。

したがって、同一の繰り返しパターンの要素の点の分布は、図 2(c) に示す通り、特徴量空間内ではほぼ平面状の部分空間をなす。よって、このほぼ平面状の部分空間内の要素を抽出することで、3 次元空間内ではほぼ同一の平面上に載っている繰り返しパターンの領域を検出することができる。

さらに、これを図 3(a) のように画像間で考える。対応する要素間の関係は厳密には平面射影変換となるが、カメラとの距離に対して、パターン自身の奥行き距離が長いとす




図 2 繰り返しパターンと特徴量空間. (a) 原画像. (b) セグメンテーション結果. (c) 特徴量空間での分布.

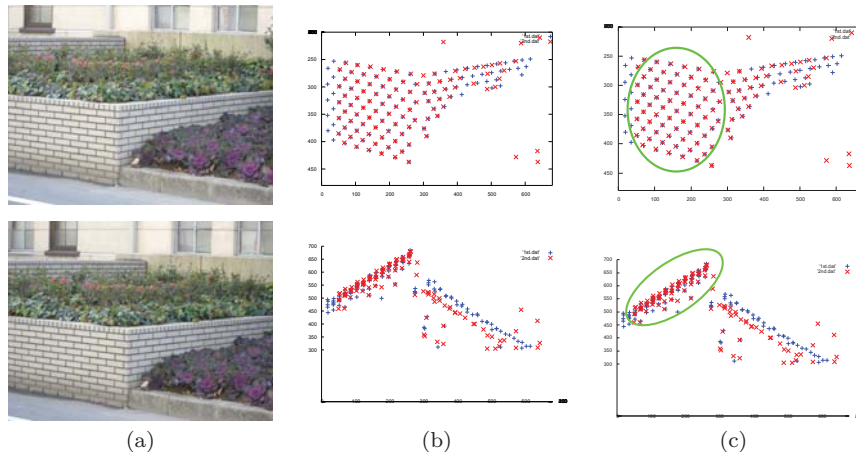


図 3 部分空間の重ね合わせ. (a) 原画像. (b) 特徴量空間をそのまま重ねた場合. (c) 適切なアフィン変換を用いて重ねた場合.

ると、アフィン変換で近似できる。例えば、図 3(b) はそれぞれの特徴量空間を重ねたものであり、これに適切なアフィン変換を施すことで、対応する繰り返しパターンの分布を図 3(c) のように、ほぼ重ねることが可能となる。

このような対応付けを行うためには、特徴量空間でほぼ平面状に分布している要素をグループ化する必要がある。坂本ら [18] では、この分布に対し平面を当てはめることでグループ化を図った。またその改良版である坂本ら [19] では、通常のクラスタリング手法を用いて特徴量空間内のクラスタを求めることで、グループ化を行っている。しかし、画像内における繰り返しパターン要素の特徴量は、実際のパターンの形や色、大きさ、カメラの射影歪みの大小などで大きく変化するため、画像毎にパラメータの調整が必要となっていた [18], [19]。そこで本研究では、特徴量空間における幾何学的な特徴を利用し、このような変化にロバストなクラスタリング法として、幾何学的 AIC [8] を用いた幾何学的なクラスタリング法を用いる。これにより、安定に繰り返し領域の検出が可能となると考えられる。

#### 4. 提案法

提案法では、画像から繰り返しパターンの要素を検出し、その要素を特徴量空間における幾何学的 AIC を用いたクラスタリングを行うことにより、得られたクラスタを繰り返しパターン領域とし、そのクラスタをアフィン変換により適切に重ね合わせることで対応付けを行う。まず、繰り

返しパターン要素の抽出方法および、幾何学的 AIC を用いたクラスタリング方法を説明し、検出した繰り返しパターンを対応付けるために用いた坂本らの対応付け方法 [18] について述べる。

##### 4.1 パターン要素の抽出

坂本ら [18] と同様に、繰り返しパターン要素の抽出法としては Kamiya ら [6] の Watershed アルゴリズムを用いた。これは、小林らの Watershed アルゴリズム [10] をベースとしており、通常の Watershed [17] と違って、セグメンテーションのための seed を必要とせず、タイルやレンガといったほぼ輝度値が平坦な領域を検出可能である。具体的なアルゴリズムは次の通りとなる。

- (1) 画像をガウス平滑化し、注目画素とその近傍の領域の画素との分散が閾値  $\sigma_s$  以下である場合に同一の画素値とし、平坦な領域とする。
- (2) 平坦部以外の画素に対して、8 近傍の最大勾配方向を求める。
- (3) 各画素の勾配の流れにそって画素を移動させる。
- (4) 極値、もしくは平坦部に流れ着いたら、流れを止める。
- (5) 同じ極値、もしくは平坦部を持つものを 1 つの小領域とする。

このようにして抽出した各小領域を繰り返しパターン要素として、式 (1) の特徴ベクトルを求める。

## 4.2 幾何学的 AIC を用いたクラスタリング

式 (1) の特徴ベクトルの中の平均輝度  $m_p$  に関しては、同じ繰り返しパターン内においてはほぼ一定であり、部分空間 (超平面) を当てはめると退化していることになるため、このクラスタリングは、輝度  $m_p$  を除く、重心  $(u_p, v_p)$ 、面積  $S_p$  の 3 次元空間内で行う。ただし、輝度  $m_p$  は、AIC を用いた併合条件とは別に、クラス間分離度を用いた併合条件として用いる。以下に、手順の概要を示す。

- (1) 特徴空間において、重心、輝度、面積の各特徴量について、 $[0, 1]$  の範囲に納まるように正規化を行う。
- (2) 特徴量空間内に存在する全ての要素  $\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N$  に対し、それぞれ異なるクラスタ  $C_1, C_2, \dots, C_N$  を割り当てる。
- (3) クラスタ  $C_1, C_2, \dots, C_N$  から、二つの要素からなる、初期クラスタを生成する。ここでは、あるクラスタに対して距離が最小となるクラスタを求め、その距離  $d$  が次式を満足するとき、そのペアを併合する。

$$d < d_{ave} + t\sigma_d \quad (2)$$

ここで、 $d_{ave}, \sigma_d^2$  はそれぞれ各クラスタペアの最短距離の平均値および分散であり、係数  $t$  は小さいパターンでは小さく、大きなパターンでは大きくとる。

- (4) 次のクラスタ間距離  $d(C_\alpha, C_\beta)$  を計算し、最短となるクラスタを併合候補とする。

$$d(C_a, C_b) = d((\mathbf{p}_\alpha, \mathbf{p}_\beta \mid \mathbf{p}_\alpha \in C_a, \mathbf{p}_\beta \in C_b)) \quad (3)$$

もし、併合候補がない、あるいはクラス間距離が一定以上などの終了条件を満たしている場合、ステップ 6 へ行く。

- (5) 併合候補において併合前・併合後の幾何学的 AIC を計算し、併合条件を満たしていれば候補を併合してステップ 4 へ行く。そうでなければ、次の最短距離となるクラスタペアを併合候補としてステップ 5 を行う。
- (6) 最後に得られた結果から、指定した要素数より大きなクラスタを部分空間として抽出する。

## 4.3 幾何学的 AIC を用いた併合条件

本研究では、パターン要素の特徴量空間における幾何学的モデルとして、「点」、「直線」、「平面」の 3 つのモデルを考える。そして併合は次の組合せとする。

- 「2 直線」対「1 直線」
- 「2 平面」対「1 平面」
- 「1 直線と 1 平面」対「1 平面」
- 「1 点と 1 平面」対「1 平面」
- 「1 点と 1 直線」対「1 直線」
- 「1 点と 1 直線」対「1 平面」

そして、これらのモデルの幾何学的 AIC を比較し、併合後のモデルの幾何学的 AIC が小さければ併合を行う。

## Algorithm 1 併合のアルゴリズム

```

if 候補の輝度におけるクラス分離度 <  $\sigma_m$  then
  if 候補がどちらも平面 &  $gAIC_S^{s+s}/gAIC_S^S > t_{aic}$  then
    併合する
  else if 候補が平面と直線 &  $gAIC_S^{s+l}/gAIC_S^S > t_{aic}$  then
    併合する
  else if 候補がどちらも直線 &  $gAIC_L^{l+l}/gAIC_L^L > t_{aic}$  then
    併合する
  else if 候補が平面と点 &  $gAIC_S^{s+p}/gAIC_S^S > t_{aic}$  then
    併合する
  else if 候補が直線と点 &  $gAIC_S^{l+p}/gAIC_S^S > t_{aic}$  then
    併合する
  end if
end if

```

以後、ノイズレベルの基準となるモデル名を下添字で、AIC を求めるモデルを上添字で表し、点を  $p$ 、直線を  $l, L$ 、平面を  $s, S$  とし、小文字であれば併合前のモデル、大文字であれば併合後のモデルとする。例えば、併合前の「1 直線と 1 平面」モデルとそれを併合した「1 平面モデル」を考えると、併合後の「1 平面」モデルから推定したノイズレベルによる「1 直線と 1 平面」の幾何学的 AIC を  $gAIC_S^{l+s}$  のように表す。また、この条件での併合後の「1 平面」モデルの幾何学的 AIC は  $gAIC_S^S$  のように表す。実際の併合には輝度平均のクラス分離度も条件とする。併合のアルゴリズムの概略は Algorithm 1 のようになる。

ここで、条件  $gAIC_L^{l+l}/gAIC_L^L > t_{aic}$  はどちらも直線で 1 直線にできない場合、平面である可能性が高いことから考慮に入れている。また、しきい値  $t_{aic}$  はノイズによる影響を考慮し 0.75 から 1 で設定する。このしきい値  $t_{aic}$  の値を大きくすると過分割、小さくすると過併合となる。また  $\sigma_m$  は併合のための輝度平均のクラス間分離度のしきい値とする。

## 4.4 パターン要素の対応付け

次に、異なる画像間で検出された繰り返しパターン領域間の対応を求めることを考える。ここでは、坂本らの手法 [18] と同様に、繰り返しパターンの特性により、直接点と点の対応を求めることが難しいことから、まずパターン領域の要素間での大まかな対応付けを行った後、点と点の厳密な対応付けを行うというアプローチを取る。

### 4.4.1 領域の要素間のおおまかな対応付け

ここでは、まず、RANSAC[4] を用いてパターン領域間の適切なアフィン変換を求め、特徴量空間内の繰り返しパターン領域に対応する部分空間の重なりを最大化するものを求めることで、異なる画像間でのパターン領域間の対応付けを行う。以下にその手順を示す。

- (1) 片方の画像  $I$  において、最も要素数の多いグループ  $G_m$  を選び、そのグループに含まれる要素の特徴ベクトルを  $\mathbf{p}_\alpha, \alpha = 1, \dots, N$  とする。
- (2) 他方の画像  $I'$  において  $G_m$  と要素個数や平均輝度が

最も近いグループ  $G'_n$  を対応の候補とする。

(3)  $G_m, G'_n$  からそれぞれ要素をランダムに3つ選択し、

$$\begin{pmatrix} u' \\ v' \\ S' \\ m' \\ 1 \end{pmatrix} = \begin{pmatrix} \mathbf{A} & 0 & 0 & u_0 \\ & 0 & 0 & v_0 \\ 0 & 0 & |\mathbf{A}| & 0 & 0 \\ 0 & 0 & 0 & \lambda & t \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} u \\ v \\ S \\ m \\ 1 \end{pmatrix} \quad (4)$$

ここで、 $\mathbf{A}$  と  $u_0, v_0$  は、選んだ3組の要素間の重心から計算された2次元アフィン変換であり、 $\lambda$  と  $t$  は要素間の平均輝度の関係  $m' = \lambda m + t$  を表す。

(4) グループ  $G_m$  内の  $\mathbf{p}$  を上記アフィン変換で変換し、変換した後のベクトルに最も近い  $G'_m$  内のベクトル  $\mathbf{q}'$  と比較し、対応が決定されておらず、かつ、個々の要素の差が閾値以下である組を仮の対応とし、その個数  $k$  を数える。

(5) その個数が最大かつ閾値以上となるまで、以上の処理を繰り返す。

(6) 対応が決定された要素を取り除き、残りの要素に対して、処理を繰り返す。

#### 4.4.2 厳密な点と点の対応付け

前節の手順により、要素間のおおまかな対応を決定した後、点と点の厳密な対応を決定する。ここでは、要素の形状は多角形として、その頂点を用い、アフィン変換ではなく射影変換を用いることで、より多くの、かつ正確な対応を求める。その手順を以下に示す。

(1) 対応のついた要素の重心を用いて射影変換  $\mathbf{H}$  を求める。

(2) それぞれの各要素に対し、輪郭のコーナーを検出する。

(3) 画像  $I$  の特徴点  $\mathbf{x}_i$ 、画像  $I'$  の特徴点  $\mathbf{x}'_j$  に対して、射影変換行列  $\mathbf{H}$  からのずれ  $D^H$  を以下のように評価する。

$$D^H = \mathbf{x}'_j - Z[\mathbf{H}\mathbf{x}_i] \quad (5)$$

ここで、 $Z[\cdot]$  はベクトル第3成分を1とする正規化とする。

(4) 次式を満たす場合、その特徴点組を対応とみなす。

$$D^H < \frac{d}{f} \quad (6)$$

ここで、 $d$  は要求精度を指定する定数 (単位は画素)、 $f$  は射影変換を計算する際に用いたスケール定数とする。

## 5. 実験

実際に繰り返しパターンを含むシーンの画像を用いて実験を行った。ここでは、画像内の繰り返しパターン領域の検出精度と画像間の対応付けの精度を求めた。実験に用いた計算機は、CPU は Intel Core i7 2600 (3.40GHz)、メモリは8GB、OSとしてOpenSUSE 11.4を用いている。画像サイズは1280×960画素である。

表1 繰り返しパターン領域の検出率 (%)。

	坂本らの手法		提案法	
	検出率	誤検出率	検出率	誤検出率
(a)	68.92	7.50	89.29	7.89
(b)	72.02	6.31	69.76	5.96
(c)	78.06	33.12	98.44	8.55
(d)	98.90	52.11	97.73	64.08

### 5.1 繰り返しパターン領域の検出実験

まず、繰り返しパターン領域の検出実験について示す。

要素抽出のための Watershed における平滑化の係数や平坦領域と見なすしきい値については手動で設定した。また各特徴量の正規化に関し、Q分位偏位により繰り返しパターンが多く部分分布している部分を切り出し、切り出した範囲が  $[0, 1]$  の範囲に納まるよう自動で正規化を行った。その際、Qの値は経験的に8とした。また2つの要素からなる初期クラスタの生成においては、そのしきい値  $t$  を  $t=1$  または  $t=5$  として実験を行った。実験結果を図4に示す。図において、左から、原画像、坂本らの手法 [19] による検出結果、提案法による検出結果、および、特徴量空間での分布を示している。その際、パターン領域の検出結果と特徴量空間での分布においては、異なるクラスタを色を変えて示している。また表1に繰り返しパターン平面の検出率と誤検出率を示す。検出率は平面ごとの検出率の平均、誤検出率は誤って検出された要素数を全体の繰り返しパターンの要素数で割ったものとする。見てわかる通り、いずれの例においても、特徴量空間内ではほぼ平面状に分布しているクラスタ、すなわち画像内での繰り返しパターン領域平面をほぼ正しく検出できていることがわかる。また、手動でクラスタリングの階層数を設定している坂本らの手法と同等または精度の向上ができていくことがわかる。そして、坂本らの手法では、手動でのクラスタリングの階層設定が必要であったが、本手法では、 $thd_{aic}$  と  $\sigma_m$  を適切に設定することで自動的にクラスタリングの階層が決まるのが利点となる。

### 5.2 対応付けのシミュレーション実験

次に、視点変化におけるロバスト性を確認するためにシミュレーション実験を行った。その結果を図6に示す。ここでは、SIFTとSURFを比較対象とした。シミュレーションでは、図5の右側の物体を1度から45度まで回転させ、0度の時の画像との対応付けを行った。その結果を図5に示す。0度と1度の画像間における対応の数は提案法が686個、SIFTが234個、SURFが102個であり、図6のグラフでは、横軸を回転とし、この0度と1度の対応数に対する比率をプロットしている。わかる通り、提案法は、SIFTやSURFに比べ、0度to1度の画像間での対応数が多いだけでなく、視点の変化に対してもロバストであることがわかる。

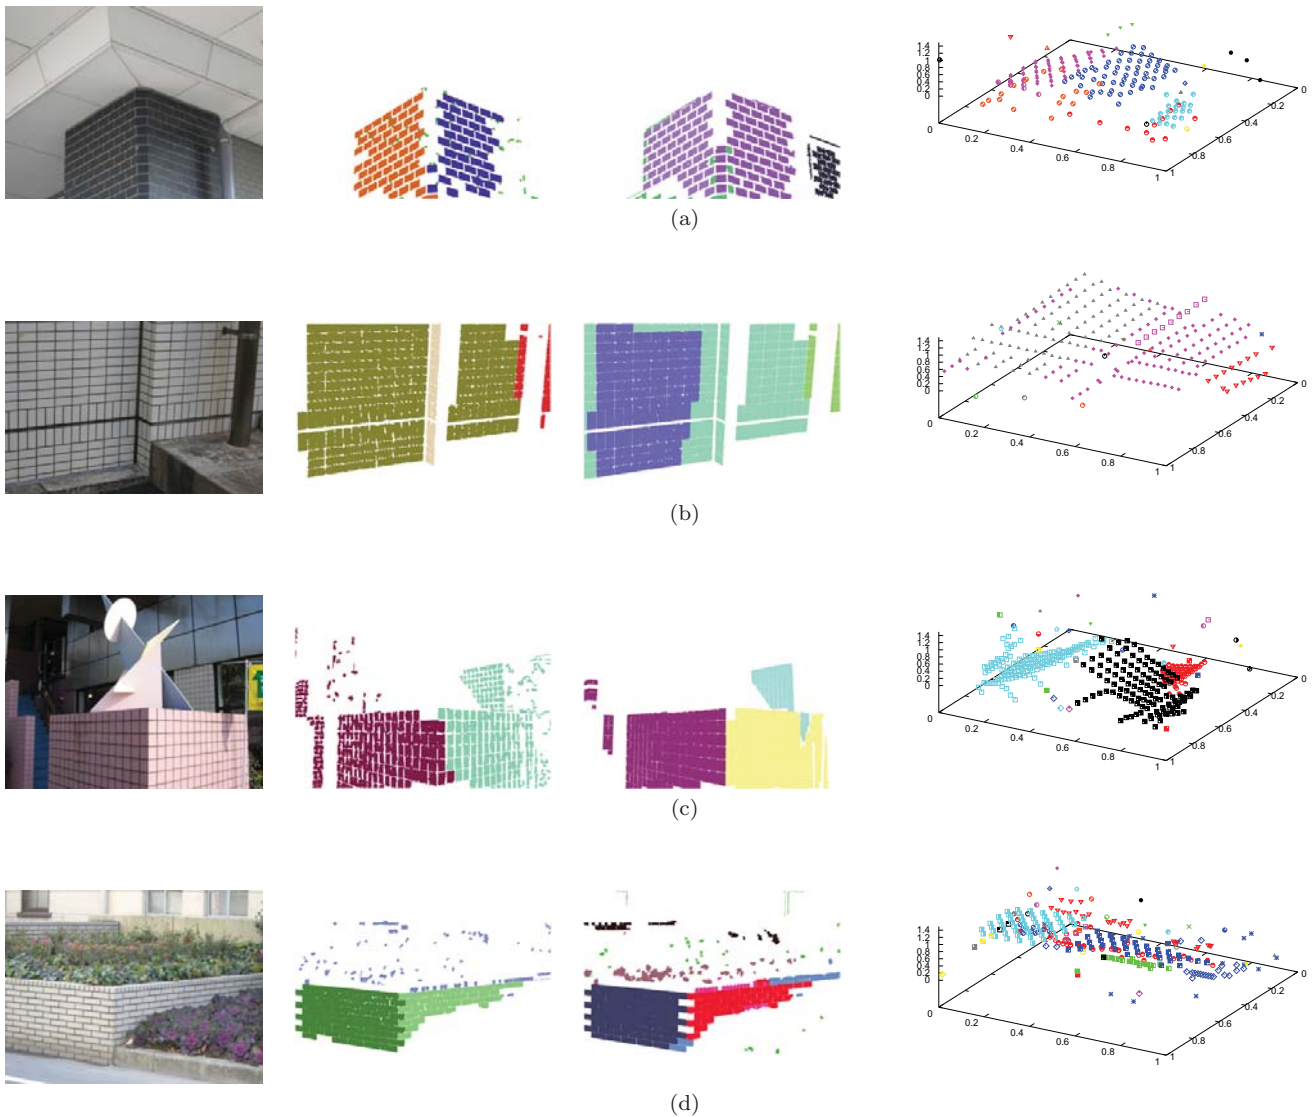


図 4 繰り返しパターン領域の検出結果. 左から, 原画像, 坂本らの手法 [19] による結果, 提案法による結果, 特微量空間での分布.




図 5 シミュレーション画像例. (a) 回転なし (0 度). (b) 12 度回転させたもの.

### 5.3 対応付けの実画像実験

次に実画像を用いた対応付けの実験を行った. その結果を図 7~12 に示す. 比較として SIFT による対応付けの結果も示している.

見てわかる通り, SIFT は, 図 7 や図 9 のように, 画像内に大きな繰り返しパターンがある場合はもうまく対応を求




図 6 回転に対する対応付け精度の推移.

めることができないが, 図 8 のように視点変化が少なく, タイルに汚れ等がある場合は数多くの対応を求めることができる. それに対し, 提案法では繰り返しパターン領域に数多くの対応が検出できていることがわかる. しかし, 図 11 や図 12 では, 提案法でも対応付けに失敗しており, こ

これはパターン領域に対する射影歪みが大きく、大きな領域が検出できなかったことと、更にそれが影響し、大まかな要素間の対応を取る際にRANSACで正しいアフィン変換を推定できなかったことなどが原因として考えられる。

## 6. おわりに

本論文では、規則的な繰り返しパターンを含むシーンの画像から3次元復元を行うために、高精度な対応付け法を提案した。ここでは、規則的な繰り返しパターンの要素に対する特徴量空間を用いて幾何学的なモデル状に分布することを利用し、幾何学的AICを用いた幾何学的なクラスタリングを行うことで、繰り返しパターン領域の検出を行った。そして、分布を重ね合わせることで、画像間での対応付けを行った。シミュレーション実験や実画像による実験より、その有効性が確認できた。

今後の課題として、検出に関しては繰り返しパターンの中に別の繰り返しパターンが含まれている場合など、複雑なパターンに対しても適用できるようにすることが考えられる。その際パターンを区別するためにSIFTやSURFなどの他の特徴量と組合せたり、スケール情報などを利用することが考えられる。また、射影歪みによる影響を考慮するために、クラスタリングの際に、曲面モデルを加えることで、より広範な画像に対する対応付けが行えるのではないかと考えている。

**謝辞:** 本研究の一部は、日本学術振興会科学研究費補助金基盤研究(C)(No. 24500202)の助成による。

## 参考文献

- [1] 赤池弘次: 情報量規準 AIC とは何か—その意味と将来への展望, 数理科学, Vol. 14, No. 3, pp. p5–11 (1976).
- [2] Bay, H., Tuytelaars, T. and Van Gool, L.: Surf: Speeded up robust features, *Proc. 9th European Conf. Computer Vision*, Graz, Austria, Springer, pp. 404–417 (2006).
- [3] Doubek, P., Matas, J., Perdoch, M. and Chum, O.: Image Matching and Retrieval by Repetitive Patterns, *Proc. 20th Int. Conf. Pattern Recognition (ICPR 2010)*, pp. 3195–3198 (2010).
- [4] Fischler, M. and Bolles, R.: Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography, *Communications of the ACM*, Vol. 24, No. 6, pp. 381–395 (1981).
- [5] Hartley, R. and Zisserman, A.: *Multiple view geometry in computer vision*, Cambridge Univ Press (2000).
- [6] Kamiya, S. and Kanazawa, Y.: Accurate image matching in scenes including repetitive patterns, *Proc. 2nd Workshop on Robot Vision (RobVis 2008)*, Auckland, New Zealand, Springer, pp. 165–176 (2008).
- [7] 金谷健一: 幾何学的モデルの選択基準について, 情処研報: 数理モデル化と問題解決研究報告, Vol. 95, No. 66, pp. 27–32 (1995).
- [8] 金谷健一: 幾何学的当てはめにおけるモデル選択, 信学論A, Vol. 84, pp. 1385–1393 (2001).
- [9] Ke, Y. and Sukthankar, R.: PCA-SIFT: A more distinctive representation for local image descriptors, *Proc.*

- IEEE Conf. Computer Vision and Pattern Recognition*, Vol. 2, pp. 511–517 (2004).
- [10] 小林 剛, Xiaolin, Z., 小池康晴, 佐藤 誠: Watershed アルゴリズムによる画像解析ソフトウェアの開発, 画像センシングシンポジウム, pp. 301–302 (2005).
- [11] Lowe, D. G.: Distinctive image features from scale-invariant keypoints, *Int. Journal of Computer Vision*, Vol. 60, No. 2, pp. 91–110 (2004).
- [12] Matas, J., Chum, O., Urban, M. and Pajdla, T.: Robust wide-baseline stereo from maximally stable extremal regions, *Image and Vision Computing*, Vol. 22, No. 10, pp. 761–767 (2004).
- [13] Mikolajczyk, K. and Schmid, C.: Scale & affine invariant interest point detectors, *Int. Journal of Computer Vision*, Vol. 60, No. 1, pp. 63–86 (2004).
- [14] Mikolajczyk, K., Tuytelaars, T., Schmid, C., Zisserman, A., Matas, J., Schaffalitzky, F., Kadir, T. and Gool, L.: A comparison of affine region detectors, *Int. Journal of Computer Vision*, Vol. 65, No. 1, pp. 43–72 (2005).
- [15] Park, M., Broeklehurst, K., Collins, R. and Liu, Y.: Translation-symmetry-based perceptual grouping with applications to urban scenes, *Proc. 10th Asian Conf. Computer Vision (ACCV 2010)*, Queenstown, New Zealand, Springer, pp. 329–342 (2010).
- [16] Park, M., Broeklehurst, K., Collins, R. and Liu, Y.: Deformed lattice detection in real-world images using mean-shift belief propagation, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 31, No. 10, pp. 1804–1816 (2009).
- [17] Roerdink, J. and Meijster, A.: The watershed transform: Definitions, algorithms and parallelization strategies, *Fundamenta Informaticae*, Vol. 41, No. 1-2, pp. 187–228 (2000).
- [18] 坂本大樹, 金澤 靖: パターン特徴量空間を用いた繰り返しパターンを含む画像間の対応付け, 信学技報: パターン認識とメディア理解, Vol. 109, No. 88, pp. 77–82 (2009).
- [19] 坂本大樹, 高橋将貴, 金澤 靖: パターン特徴量空間を用いた繰り返しパターンを含む画像間の対応付け, 第14回画像の認識・理解シンポジウム MIRU2011, 金沢市文化ホール, 石川, pp. 1589–1596 (2011).
- [20] Shi, J. and Tomasi, C.: Good features to track, *Proc. Computer Vision and Pattern Recognition (CVPR 1994)*, pp. 593–600 (1994).



図 7 実験例 1. (a) 原画像. (b) 提案法による結果. (c) SIFT による結果.




図 8 実験例 2. (a) 原画像. (b) 提案法による結果. (c) SIFT による結果.




図 9 実験例 3. (a) 原画像. (b) 提案法による結果. (c) SIFT による結果.




図 10 実験例 4. (a) 原画像. (b) 提案法による結果. (c) SIFT による結果.




図 11 実験例 5. (a) 原画像. (b) 提案法による結果. (c) SIFT による結果.




図 12 実験例 6. (a) 原画像. (b) 提案法による結果. (c) SIFT による結果.