

# RANSACを用いた部分画像の複写検出手法の改良

川嶋 健司<sup>1</sup> 松本 哲也<sup>1</sup> 工藤 博章<sup>1</sup> 竹内 義則<sup>2</sup> 大西 昇<sup>1</sup>

**概要:** 本稿では、画像における、スケーリング、回転、反転を含む部分複写を検出する手法を提案する。提案手法は SIFT 特徴量によって対応付けを行い、各対応間の位置関係を基にクラスタリングを行う。生成された対応のクラスター毎に LO-RANSAC を用いて、部分複写領域に加えられたアフィン変換行列を推定する。行列を用いて変換した画像との差分から複写領域を特定し、領域における差分値の統計量から信頼値を計算する。最終的に信頼値が最も高い領域を画像に色付けして出力する。提案手法は従来手法よりも良い性能を示した。

## Improving the method detecting partially duplicated regions using RANSAC

KENJI KAWASHIMA<sup>1</sup> TETSUYA MATSUMOTO<sup>1</sup> HIROAKI KUDO<sup>1</sup> YOSHINORI TAKEUCHI<sup>2</sup>  
NOBORU OHNISHI<sup>1</sup>

**Abstract:** This paper proposes a method to detect partial duplications in images with scaling, rotation, and reflection. The proposed method matches SIFT features each other and build the clusters based on a positional relationship between matched points. For each cluster, we estimate an affine transformation matrix between duplicated regions using LO-RANSAC. We detect duplicated region from difference between input image and image transformed by estimated matrix, and calculate confidence value from the statistic of difference in the detected region. Finally, the region whose confidence value is the highest is colored and outputted. The proposed method gives better performance than the conventional method.

### 1. はじめに

近年、画像編集ソフトウェアの普及によってデジタル画像の加工が容易に行えるようになり、捏造された画像が論文や報道で使われていたという事例がある。このような場面で加工画像が使用されると、その機関の信頼性が低下することになるため、画像の加工を自動検出する研究が行われている。

画像の一部をコピーし同一画像内の別の領域に貼り付ける加工（部分複写）を検出する研究として、画像をいくつもの矩形領域に分割し、各領域の特徴量を主成分分析によって計算する研究 [1] があり、複写領域の平行移動のみを対象としていた。この手法を応用して複写領域の回転と反転

に対応させた研究 [2] がある。

複写領域に回転とスケーリングが加えられていても検出できる研究として、SIFT(Scale-Invariant Feature Transform) 特徴量 [3] と RANSAC(Random Sample Consensus)[4] を用いた研究 [5] がある。しかしこの手法は反転には対応しておらず、検出結果も SIFT 特徴点の対応点しか表示されなかった。そこで富澤らの研究 [6] では、入力画像を反転させた画像との対応を取ることで反転複写の検出を可能にし、加えて検出結果を、対応点のみの表示から複写関係にある領域の表示を可能とした。

また、Zheng らの研究 [7] では、画像中の局所的な輝度の極値を取る点を特徴点とし、得られた特徴点同士との角度と辺の長さの比という位置関係を計算し、比較することで回転とスケーリングに不変な対応付けを行い、複写領域の特定を行なっている。

富澤らの手法では、まず SIFT 特徴量により特徴点を対

<sup>1</sup> 名古屋大学 大学院情報科学研究科  
Graduated School of Information Science Nagoya University  
<sup>2</sup> 大同大学 情報学部  
School of Informatics Daido University

応付け, RANSACにより複写領域間のアフィン変換行列を推定する. 推定された行列を用いて画像を変換し, 入力画像と変換画像を重ね合わせた際の輝度差が閾値以下の画素を抽出し, 領域として検出していた. しかし, RANSACにおける推定の際, 推定倍率によって正規化された検出領域の面積を信頼値としていたため, 検出面積が大きい推定が出力されやすく, 人工物などの周期的なパターンが画像に含まれる際は誤検出を生じやすくなるという問題があった.

また, Ameriniらの研究[8]では, 特徴点を画像座標上でクラスタリングすることで精度を上げていた. しかし, 複写領域の形状や特徴点の分布によっては, 複写領域内の特徴点がそれぞれ異なるクラスターに属することで検出精度が落ち, また, 複写元と複写先の領域間の距離が短いと, それぞれの特徴点と同じクラスターに属してしまい検出ができなくなるといった問題があった.

本研究では, まず対応点を, 対応点同士の角度と辺の長さの比を用いた位置関係に基づき, 回転とスケールに対して頑健性を残しつつ, クラスター間の距離に依存しないクラスタリングを行う. そうして得られた対応点の各クラスターそれぞれに対して, RANSACに局所最適化処理を加えたLO-RANSAC(Locally Optimized RANSAC)[9]を適用し, その信頼値に画素値の差分情報を加えることによって, 誤検出を減らし, 検出精度の向上を目指す.

## 2. 複写領域の検出方法

### 2.1 概要

部分複写検出処理の流れを図1に示す. まず, 入力画像

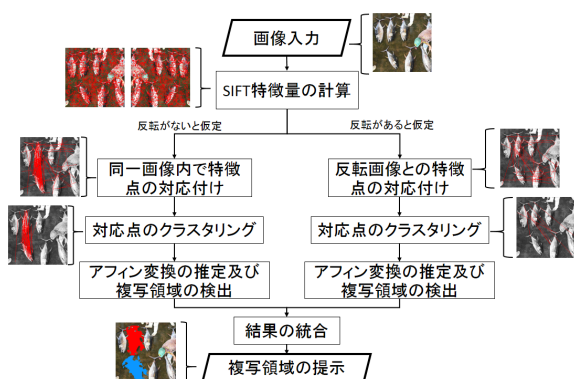


図1 部分複写検出処理の流れ

のSIFT特徴量を計算し, 入力画像内で特徴点を対応付ける. 同時に, 入力画像を左右反転させた画像を作成し, そのSIFT特徴量を計算し, 入力画像の特徴点と対応付ける. 得られた2通りの対応点の集合それぞれに対して, 対応点同士の位置関係に基づくクラスタリングを行う. そして得られた対応点のクラスターそれぞれに対して, LO-RANSACによるアフィン変換の推定を実行する. アフィン変換の推

定処理では, 対応点のクラスターから複写の関係にある可能性が高い対応点を取り出し, アフィン変換行列を計算する. その行列により入力画像をアフィン変換した画像を作成し, 入力画像と変換画像の輝度差が小さい領域を検出する. 検出された領域における輝度差の平均と標準偏差を用いて, アフィン変換の信頼値を評価することで検出精度を向上させる. 最終的に, 反転がある場合とない場合それぞれにおける, 各クラスターに対するLO-RANSACの結果を統合し, アフィン変換の信頼値が高いものを出力する. 検出結果では, 複写の関係にあると判断された領域にそれぞれ別の色を重ねた画像を出力する.

### 2.2 SIFT特徴量の計算及び対応付け

本研究では, SIFT特徴量を用いて複写領域内の画素を対応付ける. SIFTは輝度勾配から回転とスケールに不変な画像特徴を取得する方法である. まず, 異なるスケールでの平滑化画像の差分から極値を検出し, 特徴点とスケールを決定する. 得られた特徴点に対して, 輝度勾配の方向ヒストグラムが記述された128次元のベクトル(SIFT特徴量)が得られる. このSIFT特徴量を比較することで特徴点の対応付けを行う. SIFT特徴量は反転に対して不変ではないが, 入力画像を反転させた画像に対して特徴量を計算することで, 反転にも対応できる.

まず, 入力画像のSIFT特徴量を計算する. ある特徴点 $p_i$ について, その特徴点以外の全ての特徴点 $p_j$ との特徴量間のユークリッド距離 $d_{ij}$ を計算する. 各特徴点のSIFT特徴量を $\mathbf{v}^{p_i}$ と $\mathbf{v}^{p_j}$ ,  $\mathbf{v}^{p_i}$ の1番目の特徴量を $v_i^{p_i}$ とすると,  $d_{ij}$ は次式で算出される.

$$d_{ij}(\mathbf{v}^{p_i}, \mathbf{v}^{p_j}) = \sqrt{\sum_{l=1}^{128} (v_l^{p_i} - v_l^{p_j})^2} \quad (1)$$

特徴点 $p_i$ に対して $d_{ij}$ が最小となる特徴点を対応点として検出する. しかし, この方法で検出された対応点には多くの誤対応が含まれるので, 誤対応を減らすために次式を満たす対応点のみを使用する.

$$\frac{d_{ij1}}{d_{ij2}} < Th_p \quad (2)$$

ここで,  $d_{ji1}, d_{ji2}$ はそれぞれ $d_{ij}$ の最小値と2番目に小さい値を示し,  $Th_p$ は閾値である.

SIFT特徴量を入力画像内で対応付けた場合と, 入力画像と反転画像で対応付けた場合の, 2通りの対応付けの結果が得られる. 次節でのクラスタリング処理を, これら2通りの対応付けに対して, それぞれ実行する.

### 2.3 対応点のクラスタリング

前節で得られた対応点の集合に対して, 複写領域間を結ぶ正しい対応とそれ以外の誤った対応を分類し, 最終的な

検出精度を向上させるために対応点のクラスタリングを行う。クラスタリングには、回転やスケーリングに対する頑健性を持つように、対応点間の位置関係を利用する。

クラスタリングは以下のように実行される。

- (1) クラスタに属していない対応点の集合  $\mathbf{P}$  から、対応点の組  $(\mathbf{a}, \mathbf{a}')$  をランダムに選ぶ
- (2)  $\mathbf{a}$  に最も近い 2 点  $\mathbf{b}$  と  $\mathbf{c}$  を選ぶ。この時、点  $\mathbf{a}$  と  $\mathbf{b}$ 、 $\mathbf{a}$  と  $\mathbf{c}$  間の距離が閾値  $R$  より大きければ、手順 1 へ戻る。ここで  $R$  は、入力画像の縦方向の長さを  $height$ 、横方向の長さを  $width$  とすると、次の式で決定される。

$$R = \frac{\max(width, height)}{4} \quad (3)$$

- (3)  $\mathbf{b}$  の対応点  $\mathbf{b}'$ 、 $\mathbf{c}$  の対応点  $\mathbf{c}'$  について、以下の値を計算する。

$$\text{angle} = \cos^{-1} \frac{(\mathbf{a} - \mathbf{b}) \cdot (\mathbf{a} - \mathbf{c})}{|\mathbf{a} - \mathbf{b}| |\mathbf{a} - \mathbf{c}|} \quad (4)$$

$$\text{angle}' = \cos^{-1} \frac{(\mathbf{a}' - \mathbf{b}') \cdot (\mathbf{a}' - \mathbf{c}')}{|\mathbf{a}' - \mathbf{b}'| |\mathbf{a}' - \mathbf{c}'|} \quad (5)$$

$$\text{length} = \frac{|\mathbf{a} - \mathbf{b}|}{|\mathbf{a} - \mathbf{c}|} \quad (6)$$

$$\text{length}' = \frac{|\mathbf{a}' - \mathbf{b}'|}{|\mathbf{a}' - \mathbf{c}'|} \quad (7)$$

- (4) 式 (8) を満たす場合に、 $(\mathbf{a}, \mathbf{a}')$ 、 $(\mathbf{b}, \mathbf{b}')$ 、 $(\mathbf{c}, \mathbf{c}')$  をクラスタの初期値とする。満たさなければ手順 1 へ戻る。

$$\begin{aligned} |\text{angle} - \text{angle}'| &< Th_{\text{angle}} \\ Th_{\text{length}} &< \frac{\text{length}}{\text{length}'} < \frac{1}{Th_{\text{length}}} \end{aligned} \quad (8)$$

- (5) 集合  $\mathbf{P}$  から  $(\mathbf{a}, \mathbf{a}')$ 、 $(\mathbf{b}, \mathbf{b}')$ 、 $(\mathbf{c}, \mathbf{c}')$  を除外し、新しい対応  $(\mathbf{a}, \mathbf{a}')$  を選ぶ。
- (6) クラスタの中で  $\mathbf{a}$  との距離が短い上位 2 点を持つ対応  $(\mathbf{b}, \mathbf{b}')$ 、 $(\mathbf{c}, \mathbf{c}')$  を選ぶ。この時、上位 2 点どちらか一方との距離が  $R$  より大きければ、手順 5 からやり直す。
- (7)  $(\mathbf{a}, \mathbf{a}')$ 、 $(\mathbf{b}, \mathbf{b}')$ 、 $(\mathbf{c}, \mathbf{c}')$  について、式 (5)、式 (7) を計算し、式 (8) を満たせば  $(\mathbf{a}, \mathbf{a}')$  をそのクラスタに分類し  $\mathbf{P}$  から除外する。満たさなければ手順 5 へ戻る。
- (8)  $\mathbf{P}$  に属する全ての対応について調べたら、新しいクラスタについて、手順 1 からやり直す。
- (9)  $\mathbf{P}$  の要素数が 2 つ以下になる、または新しいクラスタが形成されなくなれば、処理を終了する。

上記の処理によって得られる対応点のクラスタそれぞれについて、次節の処理を適用する。

## 2.4 アフィン変換推定及び複写領域の検出

RANSAC(Random Sample Consensus) は、正しいデータと誤ったデータが混在する中から、正しいデータのみを取り出す手法である。また、RANSAC に局所最適化処理

を加えた LO-RANSAC(Locally Optimized RANSAC) という拡張手法がある。

LO-RANSAC では、全データから必要最低限の個数のデータをランダムに選び、モデルパラメータを計算し、これを仮説とする。残りのデータからパラメータの妥当性を評価し、これを繰り返し行なう。繰り返しの中で、最大の評価を得た仮説が更新された場合、局所最適化処理を行う。最終的に最大の評価を得た仮説とそれを支持したデータを取り出す。

本研究では、データに対応点の集合とし、モデルをアフィン変換行列として、LO-RANSAC を用いる。

画素  $p = (x, y, 1)^T$  から画素  $p' = (x', y', 1)^T$  へのアフィン変換は次式で表現される。

$$\begin{pmatrix} x' \\ y' \\ 1 \end{pmatrix} = \mathbf{H} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (9)$$

ここで、行列  $\mathbf{H}$  は以下の  $3 \times 3$  の行列である。

$$\mathbf{H} = \begin{bmatrix} \mathbf{A} & \mathbf{t} \\ \mathbf{0} & 1 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & t_x \\ a_{21} & a_{22} & t_y \\ 0 & 0 & 1 \end{bmatrix} \quad (10)$$

行列  $\mathbf{A}$  は回転やスケーリング、ベクトル  $\mathbf{t}$  は並進を表す成分である。変換行列  $\mathbf{H}$  を求めるには、3 つの対応点の組が必要となる。そのため、特徴点の対応付けによって、3 組以上の対応点の組が得られていると仮定する。

複写領域の検出処理の概要を図 2 に示す。




図 2 領域検出処理

まず、前節で得られたクラスタから、対応点をランダムに 3 組選択し、仮のアフィン変換行列  $\mathbf{H}'$  を推定する。得られた  $\mathbf{H}'$  を全ての対応点の組  $(\mathbf{p}_i, \mathbf{p}'_i)$  に当てはめ、次式により座標の変換誤差  $E$  を計算する。

$$E = \|\mathbf{p}'_i - \mathbf{H}'\mathbf{p}_i\| \quad (11)$$

$E$  が閾値  $Th_E$  以下となる対応点の組  $(\mathbf{p}_i, \mathbf{p}'_i)$  を正対応とする。これらの正対応を用いて、アフィン変換行列  $\mathbf{H}$  を最小二乗法により計算する。

そして入力画像  $I$  を推定行列  $\mathbf{H}$  でアフィン変換した画

像  $I_{\mathbf{H}}$  を作成する. 次に, 画像  $I$  と  $I_{\mathbf{H}}$  の共通領域の輝度値の差  $E_g$  を式 (12) によって計算し, その値を画素値とする差分画像  $diff_{\mathbf{H}}$  を作成する.

$$E_g = |I(x, y) - I_{\mathbf{H}}(x, y)| \quad x, y \in I \cap I_{\mathbf{H}} \quad (12)$$

同様に, 画像  $I$  を行列  $\mathbf{H}^{-1}$  でアフィン変換した画像  $I_{\mathbf{H}^{-1}}$  を作成し, 画像  $I$  との共通領域の輝度差を画素値に持つ差分画像  $diff_{\mathbf{H}^{-1}}$  を作成する.

差分画像から,  $E_g \leq Th_g$  を満たす画素を 1 (黒), 満たさない画素を 0 (白) とした 2 値画像を作成する. この時, 計算されたアフィン変換による面積倍率  $|\det(\mathbf{H})|$  が大きい (小さい) ほど, アフィン変換前後で輝度差が大きくなりやすいと考え, 閾値  $Th_g$  を式 (13) で決定する.

$$Th_g = \begin{cases} a_g |\det(\mathbf{H})| & \text{if } |\det(\mathbf{H})| \geq 1.0 \\ a_g / |\det(\mathbf{H})| & \text{otherwise} \end{cases} \quad (13)$$

ここで,  $a_g$  は定数である.

また, 複写領域は正対応の重心付近に集中すると予想されるため, 重心から半径  $R$  内の検出画素を残し, それ以外は除外する.

このようにして得られる検出画素に対して, クロージング処理を行い, 未検出領域の細かい穴を埋める. さらに, 得られた領域に対してラベリングを行い, 正対応の点を含まない領域を除去する. こうして得られた領域を検出候補領域とする.

入力画像  $I$  と変換画像  $I_{\mathbf{H}}$  の差分から得られた候補領域を  $D$ , 入力画像  $I$  と変換画像  $I_{\mathbf{H}^{-1}}$  の差分から得られた候補領域を  $D'$  とする. これらの重なりが大きい場合, それらは位置の近い類似した領域の誤検出である可能性が高いため,  $D$  と  $D'$  の重なり率が次式を満たす場合のみ, 仮説が採用される.

$$\frac{|D \cap D'|}{|D \cup D'|} \leq Th_o \quad (14)$$

ここで,  $|D|$  は候補領域  $D$  の面積 (画素数) を表す. また,  $|D|$  か  $|D'|$  のどちらか一方が 0 の場合, 複写領域の一方が存在しないということを意味するので, その場合は仮説を棄却する.

以上の処理によって, 複写領域間のアフィン変換を表す可能性が高い仮説が残り, 検出候補領域が得られる.

## 2.5 仮説の記録と更新

通常の RANSAC では, 対応点の選択から誤差評価までの処理を繰り返し, 正対応の数が最大になるような行列  $\mathbf{H}$  を推定結果とする. しかしそれでは, 複写領域内の対応点数が少ない場合に換行列を推定できない. そこで富澤 [6] は, 推定候補の行列  $\mathbf{H}$  を評価する指標として, 輝度差によって領域を検出し, その面積を推定された倍率で正規化した値を用いた. しかしこの場合, 周期的なパターン等の

面積が大きく, 類似した領域を誤検出しやすくなる. そこで, 推定候補行列  $\mathbf{H}$  の評価指標として, 検出候補領域  $D$ ,  $D'$  における差分値の統計量を提案する.

前節の処理で得られた検出候補領域に対して, 正対応数  $n$  と候補領域における差分値の統計量を用いて信頼値  $c$  を計算し, その仮説を記録する. 座標  $(x, y)$  における差分画像  $diff_{\mathbf{H}}$  の画素値を  $diff_{\mathbf{H}}(x, y)$  とすると, 信頼値  $c$  は次式によって計算される.

$$c = n + \frac{5}{avg} + \frac{1}{sdv} \quad (15)$$

ここで,  $avg$  は検出領域における差分値の平均値を,  $sdv$  は検出領域における差分値の標準偏差を示す.

すなわち信頼値  $c$  は, 差分値の平均と標準偏差の逆数と正対応数の重み付き和を表す. これは, 正対応数が多いほうが複写領域である可能性が高く, また複写領域の差分値は理論的には 0 になることから, 差分値の平均と標準偏差が小さいほうがより複写領域である可能性が高いという考えに基づいている.

実際に富澤の手法 [6] を用いて, 複写領域の検出に成功した画像 10 枚と別の領域を誤って検出した画像 10 枚における, 検出領域の差分値の平均と標準偏差の分布を図 3 に示す. 図 3 を見ると, 誤検出時よりも成功時のほうが平均




図 3 平均と標準偏差の分布

や標準偏差の値は 0 に近い傾向がある.

得られた仮説の信頼値  $c$ , 正対応, 検出候補領域  $D$  と  $D'$ , アフィン変換行列  $\mathbf{H}$  をリストに記録する. この時, 信頼値  $c$  に関して降順に並べる. 対応点の選択から仮説の記録までを繰り返し行う.

また,  $k$  回目の試行において, リストの最上位の要素が更新された場合, 以下に示す局所最適化処理を行う. ここで,  $I_k$  はその試行で得られた正対応の集合を示す.

- (1)  $I_k$  からモデルの推定に必要な最小限のデータを選択し, 仮のアフィン変換行列  $\mathbf{H}'$  を推定する.
- (2)  $\mathbf{H}'$  を全ての対応点に当てはめ, 誤差が  $\theta$  以下のデータ点を新しい正対応集合  $I_k$  とする.
- (3)  $I_k$  から新しい行列  $\mathbf{H}$  を計算し,  $I_k$  の要素の数  $n$  と検出領域から信頼値  $c$  を計算し,  $\mathbf{H}$  の支持とする
- (4)  $\theta$  を減少させ, 1 へ戻る.  $\theta$  がある値まで達したら,

ループを抜ける。

(5) ループの内、最も  $c$  の値が高い行列  $\mathbf{H}$  を、 $k$  回目の試行における出力とする。

得られた正対応の中から、 $\theta$  が示す許容誤差を徐々に減少させつつサンプルを取り出し、新しい行列を推定していくことによって、正しい行列に当てはまらない誤ったデータの影響を除去することができる。

## 2.6 繰り返し回数

上記の対応点の選択から仮説の記録までの処理を  $T$  回繰り返し実行する。各繰り返しにおいて、条件を満たした仮説を記録し、信頼値に基いてリストを更新する。繰り返し回数  $T$  は RANSAC に関する文献 [10] に基づき、次のように決定される。

全対応点数中の正対応の比率を  $\epsilon$  とすると、 $m$  個の正対応を選ぶ確率は  $\epsilon^m$  となり、 $T$  回の試行で少なくとも 1 つの外れ値が混入する確率は  $(1 - \epsilon^m)^T$  である。信頼性パラメータを  $\eta_0$  とすると、この確率が  $(1 - \eta_0)$  を下回ることを保証する最小の試行回数は、次式で表される。

$$T = \frac{\log(1 - \eta_0)}{\log(1 - \epsilon^m)} \quad (16)$$

初期値として  $\epsilon$  と  $\eta_0$  の値を与える。 $\epsilon$  の値は処理が進むにつれて、最大支持の正対応数の値に応じて更新される。ここで、アフィン変換行列の計算では  $m = 3$  となる。

反転がある場合とない場合で作成されたクラスターそれぞれに対する繰り返しを経て、最終的に作成されたリストの最上位の検出候補領域を検出結果として、画像上に色分けして提示する。

## 3. 実験

### 3.1 検出精度の比較実験

#### 3.1.1 方法

検出精度の比較実験を、比較手法に富澤の手法 [6] を用いて行った。

256 × 256 [pixels] の自然画像 200 枚を用意し、これらを元画像として部分複写を行なった画像を作成した。元画像から 64 × 64 [pixels] の矩形領域をランダムに選び、スケール変化、回転、反転を加えて、同一画像内のランダムな位置に複写を行なった。この時、複写元と複写先の領域は重ならないようにした。スケール変化は縦横比が同じ倍率であり、0.6, 0.8, 1.0, 1.2, 1.4 倍の 5 通りである。この 5 つのパラメータ毎に複写画像を 200 枚ずつ用意した。複写毎に回転 ( $0^\circ \sim 179^\circ$  の範囲で  $1^\circ$  刻み) をランダムに与え、200 枚中 100 枚は反転を伴う。実験で使用したパラメータは、次のように設定した。  $Th_p = 0.49$ ,  $Th_E = 10$ ,  $Th_{angle} = 10^\circ$ ,  $Th_{length} = 0.7$ ,  $a_g = 3$ ,  $Th_o = 0.5$ ,  $\eta_0 = 0.94$ ,  $\epsilon$  の初期値 = 0.2,  $\theta$  の値は 0.625 から 0.125 まで 0.125 刻みで減少させた。

### 3.1.2 結果と考察

複写領域をどれだけ検出できたかを評価するために、LO-RANSAC における第一位の検出結果に対して、次式の再現率を用いる。

$$\text{再現率 (\%)} = \frac{|(\text{真の複写領域}) \cap |(\text{複写と指摘した領域})|}{|(\text{真の複写領域})|} \quad (17)$$

再現率が 70% 以上の画像を検出成功とした。検出に成功した画像枚数を図 4 に示す。図 4 を見ると、どのスケール倍率の時も、提案手法は富澤の手法よりも成功枚数が多くなった。検出精度が向上した要因として、以下の 2 つが挙げられる。




図 4 検出成功枚数

まずクラスタリングによって、複写領域を結ぶ正しい対応とそれ以外の誤った対応に分類され、それにより誤った対応がアフィン変換行列に与える影響が少なくなった。さらに、クラスタリングされた対応に対して、LO-RANSAC の局所最適化処理により変換行列の推定精度が上がり、領域を正しく検出できたと考える。


図 5 がその例である。図 5(b) では、複写領域以外の対応が含まれており、その結果アフィン変換の推定に誤差が生じ、図 5(c) で複写領域全体を検出しきれていない。それに対して、図 5(d) のクラスタリングを行なった後の対応点では誤った対応が少なく、図 5(e) でより正確に検出できている。

また、従来手法で生じていた誤検出が提案手法では生じにくくなった。従来手法では 42 枚の誤検出が生じていたが、提案手法では 12 枚の誤検出が生じた。これは、LO-RANSAC の評価指標に差分値の平均と標準偏差を加えたからだと考える。アフィン変換が正確に推定できていれば、画像の共通領域の差分値は理論的には 0 になる。しかし、周期的なパターン等の類似した物体は、視点の角度の違いやノイズの影響から、多少の誤差が出る。そのため、差分値の統計量を用いることで、より画素値が一致する複写領域を検出しやすくなったと考える。


図 4 より、スケール倍率が小さくなるほど検出成功枚数は少なくなっている。複写領域が縮小された場合、元



(a) 複写画像




(b) 従来手法での対応点



(c) 従来手法の検出結果  
(再現率 58%)



(d) 提案手法での  
クラスタリング後対応点



(e) 提案手法の検出結果  
(再現率 87%)

図 5 クラスタリングの効果

の領域よりも SIFT 特徴点の数が減り対応が取りづらくなる。また、特徴点の座標の誤差によってアフィン変換行列の正確な推定が困難になることも原因と考える。さらに、複写領域の輝度変化がゆるやかな場合も、そもそも SIFT 特徴点を検出できないため、対応が取れずに検出に失敗する。

## 3.2 クラスタリングの比較実験

### 3.2.1 方法

本研究でのクラスタリングと Amerini ら [8] の階層的クラスタリングを比較する実験を行った。800 × 600[pixels] の自然画像 100 枚を用意し、これらを元画像として部分複写を行なった画像を作成した。元画像から一定サイズの領域をランダムに選び、回転と反転を加え複写を行なった。領域のサイズは 100 × 100, 200, 300 × 100[pixels] の 3 通りであり、それぞれについて 100 枚ずつ複写画像を用意した。回転は 0° ~ 179° の範囲で 1° 刻みにランダムに与え、100 枚中 50 枚に反転を加えた。

階層的クラスタリングは、空間中のデータ点に対して、全てのデータ点をクラスターの初期値とし、クラスター間の距離が最も短い組を順番に結合していく。処理の過程は

樹形図として表すことができ、得られる樹形図に対して不整合係数 (IC: Inconsistency Coefficient) を評価することで、クラスタリングを終了する段階を決定できる。終了条件を定めなければ、最終的にクラスターは 1 つに統合される。不整合係数は各クラスター間の平均の距離と偏差値で計算され、この値が高いほど結合されているクラスターの類似度は低いことを表す。この手法は、クラスタリングを終了する IC の閾値設定が検出精度に大きな影響を与える。実験に際して、100 × 100[pixels] の複写を行なった 10 枚のテスト画像に対し、閾値を 1.4 ~ 3.0 まで 0.2 刻みで変化させた出力結果の内、最も精度が良かった 2.8 を今回の実験に用いた。

### 3.2.2 結果と考察

検出に成功した画像枚数を図 6 に示す。




図 6 検出成功枚数

図 6 を見ると、検出枚数は提案手法が高いことが分かる。その要因として、階層的クラスタリング手法の閾値設定の難しさが考えられる。前節で述べたが、階層的クラスタリングでは IC の閾値がクラスタリング結果に大きな影響を与える。また、画像の対応点の分布から、適切な閾値は画像毎に変わってくる。そのため、今回のように実験を通して単一の閾値を用いると、複写領域内のクラスタリングが上手くいかない場合がある。

図 7 にその例を示す。図 7(a) では、複写領域内の対応点が 1 つのクラスターに統合されておらず、図 7(b) では領域の端のクラスターしか計算に用いていない。そのため、アフィン変換の推定に誤差が生じ、領域が上手く検出できていない。

一方、提案手法では、複写領域の対応を 1 つのクラスターにまとめることができ、領域全体の対応をアフィン変換の推定に用いることで精度が向上している (図 8)。画像毎に適切な閾値を設定する必要がない分、提案手法のほうが頑健性に優れていると言える。

## 4. まとめ

同一画像内での部分複写のアフィン変換行列を推定し、入力画像と変換画像の差分値から複写領域を検出する従来研究を基に、対応点の位置関係によるクラスタリング処理

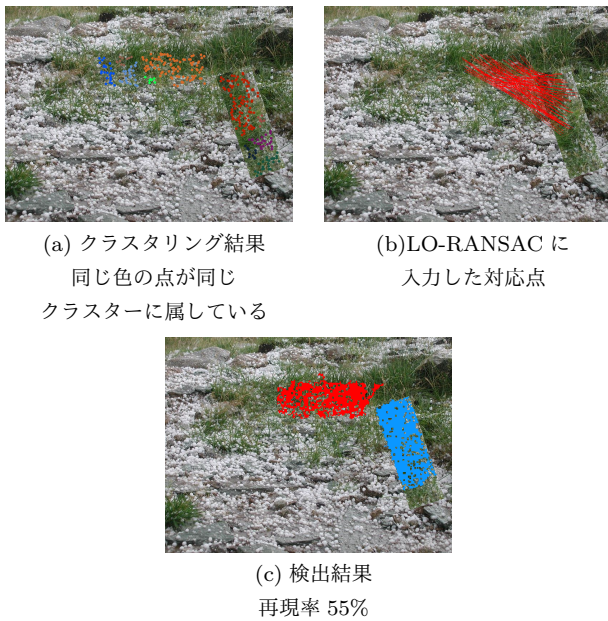


図 7 階層的クラスタリングの例




図 8 提案手法の例

を加えた。また、LO-RANSAC による局所最適化処理を追加した。これにより、回転やスケールに対する頑健性を維持しつつ、複製領域を結ぶ正しい対応と誤った対応を分類し、検出結果の高精度化を試みた。また、検出領域の差分値の統計量を RANSAC の信頼値計算に加えることで、誤検出を減らすことを試みた。

基にした従来手法との比較実験から、提案手法は回転やスケールへの頑健性を保持しつつ、検出精度を向上させた。また、従来手法よりも誤検出は少なくなった。

クラスタリングの性能評価として、階層的クラスタリングを用いた手法との比較を行った。その結果提案手法は、比較手法よりも多くの画像に対して高精度な検出を行った。

今後の課題として、特徴点の対応付けが取れないために、複製領域のアフィン変換推定が行えない場合への対応がある。対応が取れない理由として、複製領域の輝度変化が緩やかなために効果的な SIFT 特徴点が検出できないことが考えられる。そのため、特徴点を用いないブロックマッチング手法と組み合わせた手法が必要となる。

また、誤検出を減らすために、人工物などの周期的なパターンと部分複製を分離・判別できる手法を確立すること

も重要である。

## 参考文献

- [1] A. Popescu and H. Farid: "Exposing digital forgeries by detecting duplicated image regions", Department of Computer Science, Dartmouth College, Tech. Rep. TR2004-515(2004).
- [2] 野田恵司, バシヤール カイルル, 竹内義則, 大西昇: "デジタル画像内での部分複製の検出", 映像情報メディア学会誌, 63, 11, pp. 1645-1651(2009).
- [3] D. Lowe, "Distinctive image features from scaleinvariant keypoints", Proc. of International Journal of Computer Vision (IJCV), 60(2), pp. 91-110, 2004.
- [4] M. A. Fischler, R.C. Bolles, "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] I. Amerini, L. Ballan, R. Caldelli, A. DelBimbo, and G. Serra, "Geometric tmapering estimation by means of a SIFT-based forensic analysis", in Proc. of IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), Dallas, USA, 2010.
- [6] 富澤 圭, 松本 哲也, 工藤 博章, 竹内 義則, 大西 昇, "改ざん画像におけるアフィン変換を伴う部分複製領域の検出", 電子情報通信学会技術研究報告, IE, 画像工学 111(442), 207-212, 2012.
- [7] Jiming ZHENG, Wanrui HAO, Wei ZHU, "Detection of Copy-move Forgery Based on Keypoints' Positional Relationship", Journal of Information & Computational Science 9: 16, 4729-4735(2012).
- [8] I. Amerini, L. Ballan, R. Caldelli, A. DelBimbo, and G. Serra, "A SIFT-BASED Forensic Method for Copy-Move Attack Detection and Transformation Recovery", IEEE Transactions on Information Forensics and Security, Vol. 6, No. 3(2011).
- [9] O. Chum, J. Matas, and J. Kittler, "Locally Optimized RANSAC", Proc. DAGM, Springer-Verlag, 2003.
- [10] Rahul Raguram, Jan-Michael Frahm, Marc Pollefeys, "A Comparative Analysis of RANSAC Techniques Leading to Adaptive Real-Time Random Sample Consensus", ECCV 2008, Part II, LNCS 5303, pp. 500-513(2008).