

局所形状情報と大域的形状情報の融合による 3次元モデル検索に基づく土器片分類手法

鬼木 一優^{1,a)} 小篠 裕子^{1,b)} 斎藤 英雄^{1,c)}

概要：本研究では、複数種類の土器から得られる複数の土器片を同一土器毎に分類することを目標とする。提案手法では、3次元モデル検索システムにおける土器片の検索結果が同一土器から得られる土器片毎で類似する傾向に基づき、土器の類似検索結果を用いて土器片の特徴を表現する。得られた特徴をGMMによってクラスタリングすることで土器片を複数の組に分類する。実験では、3次元点群で表現された土器及び土器片を用いて土器片を分類し、4つの評価手法で提案手法の分類精度を評価する。

キーワード：土器片分類, 3次元モデル検索, GMM, クラスタリング

Potsherd classification using 3D object retrieval based on local and global features

KAZUMASA ONIKI^{1,a)} YUKO OZASA^{1,b)} HIDEO SAITO^{1,c)}

1. はじめに

考古学分野における土器復元作業の負担を軽減するため、土器片を撮影して得られた3次元点群を接合し、元の土器形状を復元する研究が進められている[1]。従来の土器復元手法[1], [2]では、土器片が同一土器毎に予め分類できていることを前提としているが、土器片分類の自動化については十分に議論されていない。本研究では、複数の土器に属する土器片の3次元点群を同一の土器毎に分類するタスクを設定する。

同一の土器に属する土器片であっても形状が大きく異なる場合は多い。そのため、土器片をクラスタリングする際、形状が類似しているもの同士を同じクラスタとするのではなく、同じ物体から得られる形状同士を同じクラスタとする必要がある。同一の土器に属するが形状が異なる土器

は、3次元形状を表現する特徴量が類似しないため、単純に土器片の形状特徴を用いて分類することは困難である。

本研究では、物体の部分的な形状からそれと類似した物体を提示する3次元部分形状検索システムに、同じ土器に属する土器片を入力したときに得られる検索結果が、土器片の形状が似ていなくとも類似している傾向があることに着目する。3次元モデル検索システムで得られた検索結果を用いて、土器片の特徴を表現することができれば、同一土器から得られる土器片間で類似する特徴表現となると考えられる。

3次元物体の部分形状検索手法は数多く提案されているが、中でもSavelonasら[3]の提案する検索手法が高い検索精度を有する。Savelonasらの手法では、クエリとなる物体と検索対象物体間の局所的な距離と大域的な距離を統合して、検索に用いることで、精度の高い検索を可能としている。

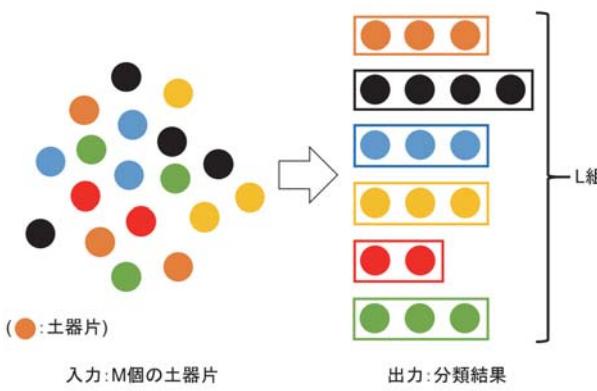
本稿では、土器片の3次元点群を分類するための特徴ベクトルを提案する。3次元部分形状検索手法を用いて算出した、土器片と検索対象となる土器間の距離を用いて、土器片の特徴ベクトルを表現する。検索には、Savelonas

¹ 慶應義塾大学理工学部
Faculty of Science and Technology, Keio University, Yokohama, Kanagawa, 223-8522, Japan

a) onikikazumasa1017@keio.jp

b) yuko.ozasa@keio.jp

c) hs@keio.jp



ら [3] の手法を用いる。算出した特徴ベクトルを、混合ガウス分布 (GMM) を用いてクラスタリングすることで土器片の分類が可能となる。

我々が設定する土器片分類問題に適した既存のデータセットは存在しないため、実験では、3次元モデル検索の研究で使用されている Hampson Pottery Dataset[4] を元に、土器片分類に適した新たなデータセットを構築した。構築したデータセットを用いて土器片を分類し、その性能を 4 つの評価手法で確認した。

2. タスク設定

本研究で設定する土器片分類タスクの概念図を図 1 に示す。土器片分類タスクの入力は、 M 個の異なる土器片の 3 次元点群であり、出力は分類結果となる。 M 個の土器片の元となる土器の個数が L 個であるとき、 M 個の土器片を L 個の土器毎に分類した結果を分類結果とする。土器片分類が実用される際、 L は未知であると想定されるが、本稿では、研究の第一歩として、 L を既知とした土器片分類をタスク設定とする。

3. 3 次元モデル検索に基づく特徴ベクトル

本稿では、土器片の 3 次元点群をクエリとし、予め用意した複数の土器との距離を 3 次元部分形状検索手法を用いて算出し、提案特徴ベクトルの要素とする。このとき、検索対象となる土器は、入力される土器と同じものが含まれる必要はない。

3.1 3 次元モデル検索

本研究では、3 次元部分形状検索手法に Savelonas ら [3] の手法を用いる。Savelonas らの手法による 3 次元モデル検索手法を以下に示す。

まず、局所形状情報に着目した距離算出手法について述べる。はじめに、入力となる土器片の 3 次元点群 Q と、検索対象の 3 次元点群 T に対し、ボクセルフィルタリングを施し、点群の密度を均一にする。次に、FPFH[5] を拡張した局所特徴量 dFPFH を式 (1) により生成する。

$$dFPFH(q_p, r) = [\text{FPFH}(q_p) \Delta \text{FPFH}(q_p, r)]. \quad (1)$$

ここで q_p は点群で表されたモデル Q の各点を表す。 r はモデルの各点を中心とするサポート球の半径であり、サポート球内にある点を注目点における近傍点 (r 近傍) とする。dFPFH は FPFH に加えて注目点周りの FPFH の変化量を特徴量として持つため、FPFH よりモデルの凹凸を詳細に表現することができる。次に、点群の粗密に適応した局所特徴量を抽出するために、注目点とその r 近傍の重心間の距離を変数とする一次関数から dFPFH の半径を決定する。得られた dFPFH を用いて入力のモデル Q と検索対象のモデル T の局所的な距離 $dm_w(Q, T)$ を算出する。具体的には、まず、モデル Q の各点 q_p において L_1 距離 $L_{d1}(q_p, t_p(i))$ が小さい T の点 t_p を昇順に k 点選び、 k 点の距離の加重平均を求める。求めた加重平均に対して、 $w_i = (1 - (i/k))$ により重み付けすることで、注目点の dFPFH と類似した点ほど重みが大きくなるようにする。 Q の全点で同様に加重平均を求め、それらの平均値を局所的な距離 $dm_w(Q, T)$ とする。距離 $dm_w(Q, T)$ を以下に示す。

$$dm_w(Q, T) = \text{mean}[(1/k) \sum_{q_p \in Q} w_i L_{d1}(q_p, t_p(i))]. \quad (2)$$

次に、大域的形状情報に着目した距離算出手法について述べる。まず、検索対象 T の各点の dFPFH を用いて点群の GMM を計算し、モデルを K 個の点群の組にクラスタリングする。クラスタリングによって得られたモデルパラメータ (混合比率 π_k 、平均ベクトル μ_k 、共分散行列 Σ_k) を用いて、各正規分布の平均成分 \mathbf{u}_k と分散成分に対応したベクトル \mathbf{v}_k を以下に示す。

$$\mathbf{u}_k = \frac{1}{N\sqrt{\pi_k}} \sum_{i=1}^N q_{ik} \Sigma_k^{-1/2} (\mathbf{x}_i - \mu_k). \quad (3)$$

$$\mathbf{v}_k = \frac{1}{N\sqrt{2\pi_k}} \sum_{i=1}^N q_{ik} [(\mathbf{x}_i - \mu_k) \Sigma_k^{-1} (\mathbf{x}_i - \mu_k) - 1]. \quad (4)$$

ここで、 N はモデルを構成する点の個数であり、 q_{ik} はモデルの i 番目の点の k 番目の正規分布に対する事後確率を表す。各正規分布における $\mathbf{u}_k, \mathbf{v}_k$ を求め、それらを結合させることで大域的特徴量である Fisher Vector $\mathbf{f} = [\mathbf{u}_1^T, \mathbf{v}_1^T, \dots, \mathbf{u}_K^T, \mathbf{v}_K^T]$ を生成する。同様に、 Q の Fisher Vector を T のコードブックを用いて生成する。 Q と T の Fisher Vector の各要素の組 $(\mathbf{u}_k, \mathbf{v}_k)$ を比較し、 L_1 距離が昇順になるように要素の組を並び替える。そして、各要素間の L_1 距離に対して単調減少な j の関数 $wf_j = (1 - (j/K))$ を重みとして加重平均をとることで、 L_1 距離が大きいの要素の組ほど大域的な距離の算出に及ぼす影響が小さくなるようにしている。 Q と T 間の大域的な距離 $dF_w(Q, T)$ を以下に示す。



図 2: Hampson pottery dataset に含まれる土器例.

$$dF_w(Q, T) = ((1/k) \sum_{j=1,2,\dots,K} w f_j L_{f1}(Q(j), T(j))). \quad (5)$$

最後に、式(2)、式(5)により算出した距離を統合する方法について述べる。 Q, T をボクセル間隔 s でフィルタリングしてマッチングを行ったときの局所的な距離、大域的な距離をそれぞれ $dm_w(s)$ 、 $dFw(s)$ とすると、両者を統合した距離 $d_{hybrid}(Q, T, s)$ は以下のようにになる。

$$d_{hybrid}(Q, T, s) = w_0 dm_w(s) + dFw(s). \quad (6)$$

ここで、 w_0 は $dm_w(s)$ と $dFw(s)$ の割合を調節する係数である。ここまで手順をモデルの点群の密度を変えて同様に行い、得られた距離 $d_{hybrid}(Q, T, s)$ を式(7)により統合して最終的な QT 間の距離 $d(Q, T)$ を決定する。

$$d(Q, T) = \sum_{s=1, \dots, S} w_s d_{hybrid}(Q, T, s). \quad (7)$$

3.2 特徴ベクトル

本稿における土器片分類の流れは以下のようになる。まず、3次元点群で表現された M 個の土器片をクエリとして、Savelonas ら [3] の手法を用いて各土器片と検索対象となる土器との距離を算出する。入力となる i 番目の土器片 Q_i ($i = 1, 2, \dots, M$) とし、検索対象の n 個の土器を T_1, \dots, T_n とすると、 Q_i と j 番目の検索対象 T_j との距離 $d(Q_i, T_j)$ は、式(7)により求められる。ある Q_i に対して、 n 次元のベクトル $\mathbf{p}_{Q_i} = (d(Q_i, T_1), \dots, d(Q_i, T_n))$ を算出し、各要素の和が 1 となるよう正規化したベクトル $\hat{\mathbf{p}}_{Q_i}$ を提案特徴ベクトルとする。 M 個の土器片から、 $\hat{\mathbf{p}}_{Q_1}, \dots, \hat{\mathbf{p}}_{Q_M}$ を算出し、混合数 L の GMM によってクラスタリングすることで土器片を L 組に分類する。

4. 実験

本研究で扱う土器片分類タスクに適した既存データセットは存在しないため、土器片の3次元点群画像データセットである Hampson Pottery Dataset[4] から、新しくデータセットを構築する。構築したデータセットを用いて、提案特徴ベクトルに基づく土器片分類を行い、評価する。

4.1 データセット

本実験で構築したデータセットには、Hampson Pottery Dataset[4] に含まれる、ボトル、彫像、瓶、ボウル、その他の 5 つのカテゴリから、各カテゴリにつき 20 個の土器をランダムに選択し、そのうち、各カテゴリにつき 10 個

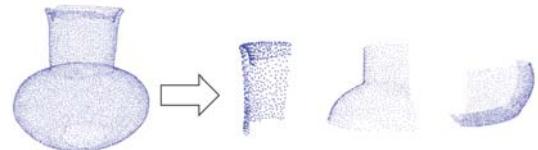


図 3: 土器片データの例.

表 1: カテゴリ別の First Tier (%).

| ボトル | 彫像 | 瓶 | ボウル | その他 | 平均 |
|------|------|------|------|------|------|
| 20.6 | 48.4 | 22.7 | 48.4 | 8.10 | 29.6 |

の土器をテスト、残りの土器を検索対象として選出した。図 2 に、本データセット構築に用いた 5 カテゴリの土器の例を示す。

テストに用いる 10 個の土器から土器片データを生成した。各土器を様々な方向から切断し、各土器につき 10 個の土器片を得た。このとき、1 つの土器片の大きさの平均は、元となる土器の 22.4% であり、分散は 6.39% であった。図 3 に、ある土器から生成された土器片データ例を示す。

4.2 実験条件

本研究の目的である土器片分類の第一歩として、本実験では入力とする土器の種類、各土器を土器片に分割する分割数に対して制約を設ける。入力とする土器の種類を 3、各土器の分割数を 3 とした。つまり、3 個の異なる種類の土器から得られた各土器につき 3 つに分割されている計 9 個の土器片を、3 組に分類する ($M = 9, L = 3$)。

つまり、本実験では、3 種類の土器から得られる 9 つの土器片の組を 1 入力とする。まず、5 つのカテゴリから 3 つのカテゴリを選び、各カテゴリから 1 つの土器を選んだ後、各土器から 3 つの土器片を無作為に選び、これを 1 回のテストに用いる。入力とする 9 つの土器片の組み合わせは計 10,000 通りが考えられるため、そのすべてを用いて合計 10,000 回分類を行い、精度を評価する。

土器間の距離 $d(Q, T)$ (式(7)) の算出に用いる係数のうち、dFPFH を生成するためのサポート球の半径を $r = 5$ 、GMM の混合数を $K = 3$ 、局所的な距離 $dm_w(s)$ と大域的な距離 $dFw(s)$ を統合する割合を $w_0 = 0.25$ 、点群のボクセルサイズはそれぞれ 3.0, 4.0, 5.0 とし、各ボクセルサイズに対応する重みを $w_s = 1.0, 0.5, 0.5$ とした。その他の係数は Savelonas ら [3] の実験条件と同じ値に設定した。

4.1 節で生成した 100 個の土器片データをクエリに、検索対象データとして選択した 5 つのカテゴリから成る 50 個の土器を検索対象として精度を評価した。検索精度評価の指標として First Tier を用いた。First Tier とは、得られた検索リストの上位 C 個の土器のうち、入力の土器と同じカテゴリの土器であったものの割合を表す。表 1 に、本データセットに対する検索システムの検索精度として、カテゴリ毎の土器片検索の First Tier を示す。カテゴリ毎で分類精度が大きく異なる傾向があることが分かる。

表 2: 各特徴ベクトルを用いた場合の分類精度.

| | 正解率 | 誤分類率 | 分離度 | 結束度 |
|----------|-------|-------|-------|-------|
| ベースライン A | 0.024 | 0.264 | 0.549 | 0.390 |
| ベースライン B | 0.038 | 0.309 | 0.449 | 0.375 |
| 提案手法 | 0.240 | 0.203 | 0.713 | 0.639 |

提案手法の比較対象とするベースライン手法を設定した。提案手法でも用いる、土器片から算出した Fisher Vector \mathbf{f} をそのまま GMM により分類し、これをベースライン手法 A とした。ベースライン手法において、各土器片の Fisher Vector を生成する際、検索対象の土器の中から土器を一つ無作為に選び、選んだ土器の GMM により作成されたモデルパラメータを共通のコードブックとして利用した。また、Savelonas ら [3] が検索の際、Fisher Vector を L2 正規化したもの用いていたため、同様に L2 正規化したもの GMM の入力とした手法もベースラインとして比較に用いた(ベースライン手法 B)。

5. 結果

本実験では、9 個の土器片の分類結果を正解率、誤分類率、分離度、結束度と定義した 4 種類の異なる評価指標に基づいて評価した。ベースライン手法 A と B、提案手法の分類精度を表 2 に示す。各結果の算出方法と結果に対する考察を以下の節にて述べる。

1 組に含まれるすべての土器片を正しく分類できた割合を正解率とする。提案手法はベースライン手法の約 10 倍の精度で土器片を分類できることが分かった。

誤分類率は、誤分類の度合いを表す評価指標である。9 個の土器片のうち、誤ったグループに分類された土器片の割合を誤分類率とし、評価した。土器片が正しいグループに属しているかを判別するには各グループにカテゴリがラベル付けされている必要があるため、ここでは全グループに考えられるすべての組み合わせでラベルを与えて、その中で最も誤分類率の低いラベル付けの誤分類率を用いる。提案手法の方が 10% 程度ベースラインと比較し誤分類率が低くなつたことが分かる。

分離度は、グループ内に異なるカテゴリの土器片が含まれるのを避ける度合いを表す。ある入力における分類結果において同じ土器から得られる土器片のみで構成されているグループの割合、つまり適合率が 1 となっているグループの割合を分離度とし、評価した。提案手法の方がベースライン手法と比較し、異なるカテゴリの破片を分離する度合いが強いことが分かった。

結束度は同一のカテゴリの破片をすべて同じグループに含める度合いを表す。ある入力における分類結果において 1 つの土器から得られる 3 つの土器片をすべて含むグループの割合、つまり再現率が 1 となっているグループの割合を結束度として評価した。提案手法での分類の方がベース

ラインに対して約 2 倍弱、異なるカテゴリの破片を結束させる度合いが強いことが分かった。

本実験で利用した検索システムの精度は 29.6%(First Tier) であり、3 次元モデル検索の検索精度は十分ではない。提案手法では、この検索システムに 9 個の土器片を入力して 9 個の異なる検索リストを生成しており、得られた検索リストに基づいて土器片をクラスタリングしている。実験では分類の正誤を表した評価指標から、9 個の土器片を 24% の割合ですべて正しく分類し、誤分類率を表した評価指標から土器片の約 80% を正しいグループに分類した。これは検索システムの精度を考慮すると妥当な分類結果だと考えられる。

6. まとめ

本稿では、複数の土器からの土器片を、それが構成していた土器毎に分類する手法を提案した。実験結果から、4 つの評価指標の全てにおいて提案手法がベースライン手法の精度を上回っており、土器片分類問題における検索リストを利用した特徴ベクトルの有効性を確認することができた。本稿は、土器片分類に適切な特徴ベクトルについて議論したが、分類器においては十分に議論していないため、これを今後の課題とする。また、本研究では入力の土器片の個数や構成を一通りに固定して実験を行っていたが、今後は入力の土器片を構成する土器の個数の自動推定、任意の個数の土器片を入力とした分類、同一カテゴリの複数の土器の破片が混在した状態での分類など、分類する上での制約を無くしていきながら、より汎用性の高い土器片分類システムを考案していきたい。

参考文献

- [1] 高橋俊一, 今野晃市, 金野哲士, 千葉史: 土器復元のための土器片マッチング手法の検討, 画像電子学会研究会講演予稿画像電子学会第 239 回研究会講演予稿, 一般社団法人 画像電子学会, pp. 25–28 (2008).
- [2] 安原彰吾, 加藤昇平, 加藤諭, 伊藤英則: 破片表面の輪郭形状と色彩パターンのマッチングに基づく土器復元の一手法, 画像電子学会誌, Vol. 34, No. 2, pp. 126–133 (2005).
- [3] Savelonas, M. A., Pratikakis, I. and Sifakis, K.: Fisher encoding of differential fast point feature histograms for partial 3D object retrieval, *Pattern Recognition*, Vol. 55, pp. 114–124 (2016).
- [4] Center for Advanced Spatial Technologies: The Virtual Hamson Museum, <http://hampson.cast.uark.edu/>.
- [5] Rusu, R. B., Blodow, N. and Beetz, M.: Fast Point Feature Histograms for 3D registration, *2009 IEEE International Conference on Robotics and Automation*, pp. 3212–3217 (online), DOI: 10.1109/ROBOT.2009.5152473 (2009).