

動作特徴を考慮した モーションキャプチャデータベース構築に関する研究

佐藤 浩司[†] 青木 工太^{††} 長橋 宏^{††}

近年、映画やテレビ等様々な分野でCGが幅広く普及している。その中で、自然な人間の動作を容易に再現するため、モーションキャプチャデータが広く利用されている。しかし、ユーザーが膨大なモーションデータベースから任意の動作を探索することは非常に困難である。様々な検索手法が提案されてきたが、その殆どの手法では入力動作と正確に一致する動作のみを検索している。そこで本稿では、次元削減手法と学習アルゴリズムを用いることで、動作の全体的な特徴を考慮したデータベースの構築及び検索手法を提案する。本手法により、検索したい入力動作に類似する動作集合の効率的な検索を実現できる。

Construction of a Motion Capture Database Using Human Motion Characteristic

KOJI SATO [†], KOTA AOKI ^{††} and HIROSHI NAGAHASHI ^{††}

Recently, CG has been used in various fields such as movies and the televisions. The motion capture data is widely used to reproduce the natural human motion easily. However, it is very difficult for a user to search for arbitrary human motions from a huge motion data base. A variety of motion retrieval techniques which enable to find accurately corresponding motions have been proposed. This paper proposes a construction and the retrieval technique of the human motion database that considers the overall feature of motion by using the dimension reduction technique and the learning algorithm. An efficient retrieval of a similar motion set to the query motion can be achieved by this technique.

1. まえがき

近年では、人間の自然なアニメーションを生成するために、映画やテレビ等CGの分野でモーションキャプチャデータが幅広く使用されている。これは、人間の身体の主な関節部等にセンサーを取り付けて、センサーからの情報を3次元データに変換することで、人間の動作を容易に取り込むことが可能な技術である。また、CGアニメーションの分野のみならず、リハビリテーションやバイオメカニクスの分野においてもモーションキャプチャシステムを用いた動作計測手法は広く利用されている。

さらに、Web上でもモーションキャプチャ・データベー

ス等^{4),16)}が公開されており、一般の人々でも容易に動作データを利用できる環境が整ってきている。このため、数多くのモーションキャプチャデータを扱う機会が多くなっていると言える。それゆえに、膨大な動作データを管理することが可能なモーションキャプチャデータベースシステムの必要性が高まっている。

一般的なデータベースシステムでは、データはタグ付けされてファイル名等の属性で管理されるが、モーションキャプチャデータは時系列データであるため、ファイル名での検索処理には適さない。

また、人間の自然なアニメーションを生成するための、モーションキャプチャデータの補間を行う手法として、多様な手法が考案されている^{3),9)}。モーションキャプチャデータを用いてアニメーションを生成する手法は、物理シミュレーション等に基づく手法に比べ、少ない計算量で制御可能なアニメーションが生成出来るという利点がある。例えば、様々な位置に荷物を置く動作から、任意の位置に荷物を置く動作を生成することが可能である。しかし、これらの手法は補間に基づくアルゴリズムであるため、類似する複数の動作が必要で

[†] 東京工業大学大学院 総合理工学研究科, 〒 226-8503 横浜市緑区長津田町 4259, E-mail:sato.k.aj@m.titech.ac.jp
Interdisciplinary Graduate School of Science and Engineering, Tokyo Institute of Technology, 4259 Nagatsuta-cho, Midori-ku, Yokohama, 226-8503

^{††} 東京工業大学大学院 理工学研究科, E-mail:{aoki,longb}@isl.titech.ac.jp, Graduate School of Science and Engineering, Tokyo Institute of Technology

ある。このため、補間によりアニメーションを生成する場合は、データベースから同種類でさらにその中から類似する動作を検索しなければならない。タグ名によるデータベースは、このような類似動作の検索には適さない。つまり、よりコンテンツベースの検索が必要であると言える。このような背景の下で、様々な動作データベースを構築・検索する手法が提案されてきた^{7),10)}。しかしこれらの手法は、大規模なデータベースから大まかに同種類の動作を検索するものである。さらに、動作の特徴を用いて検索をするためにパラメータを発見的に設定する必要がある。

そこで本稿では、学習を用いることにより少ないパラメータのみで、同種類の動作の中からさらに細かく類似動作を検索する手法を提案する。これにより、動作の全体的な特徴を取り入れつつ、従来手法より詳細な検索が可能になる。

本手法では、Laplacian Eigenmaps²⁾を用いて姿勢空間でモーションデータの次元を削減し、特徴を抽出する。また、その他の多次元データの低次元化の手法としては、線形写像であるPCA¹²⁾、MDS¹⁴⁾、そして非線形写像であるISOMAP⁶⁾等が挙げられる。

PCAは、分散を最大にするような射影を求める手法である。またMDSは、ユークリッド距離に限らずサンプル間の距離が最も保存されるような射影を求める手法であり、マーケティングや心理学等でも利用されている。ISOMAPはMDSの拡張であり、距離の定義を、直線距離ではなく近傍のサンプル同士を繋いだグラフにより定義している。これにより、元の空間での特徴を保存した射影を求めることができる。一方、Laplacian Eigenmapsは、重み行列によってサンプルの近傍の類似度を重点的に保存するような射影を求める手法であり、クラスタリング等に用いられる。本研究では、非線形な動作データを扱うので、線形写像であるPCAやMDSは適さない。さらに、ISOMAPほどの距離の正確さは必要としない。また、Laplacian Eigenmapsは計算量が少なく、局所最適解に陥ることがないという長所があるため、本手法では多様体学習アルゴリズムであるLaplacian Eigenmapsを、モーションデータの姿勢の低次元化及び特徴抽出のために用いる。

多様体学習アルゴリズムは、元の高次元空間におけるデータ間の距離をなるべく保つように、データを低次元空間に写像する手法である。そしてLaplacian Eigenmapsは、グラフラプラシアン行列のスペクトル分解を利用した次元削減法である。本手法により、グラフ構造をスペクトル分解することが可能になる。実際には、モーションデータの姿勢間の距離によってグラ

フラブラシアン行列を生成し、これを固有値分解することによってグラフ構造を詳細度に応じて分解できる。本稿ではモーションデータの詳細な特徴を抽出するため、固有値・固有ベクトルの高次成分を用いた。

その後、低次元化後の姿勢データをClustering Large Applications¹¹⁾を用いてクラスタリングする。これは、大規模データベースに対する効率的な分割アルゴリズムであり、k-medoids methodを利用している。そのため、データ中のノイズや外乱に強いという特徴を持つ。

そして、姿勢空間でクラスタリングを行うことで類似した姿勢を分類し、全ての動作を姿勢クラスターの遷移によって表現する。さらに、この姿勢の遷移をHMM(隠れマルコフモデル)によってモデル化する。高次元データの場合、HMMを適用する際に計算量が大きくなってしまふ事と、次元の高さによりデータの特徴解析に支障をきたす事という2つの問題点が存在する。本手法によって低次元化し、必要な特徴のみを利用してHMMを適用することで、動作全体の特徴を考慮しつつ動作のモデル化が実現可能になる。動作をモデル化して動作間の類似度を定義することで、データベースシステムへの入力動作に対し、類似する順番での動作集合の出力を実現できる。

2. Laplacian Eigenmapsによる動作データの低次元化

Laplacian Eigenmaps²⁾は、高次元データの低次元空間への写像を求めるための手法であり、データのサンプル間の距離が近い物同士が、写像においても距離が近くなる。つまり、線形写像である主成分分析等とは異なり、重み行列によってサンプル間の近傍の関係を保存したまま、低次元化する写像を求めることが可能である。これより、データ間の距離関係が重要であるクラスタリング等に用いられる。

また、グラフラプラシアン行列のスペクトル分解を行うため、固有ベクトルの高次成分を用いることで動作データの細かな特徴を抽出することができる。

2.1 Laplacian Eigenmapsのアルゴリズム

全N個のデータにおける i, j 番目のサンプルを $\mathbf{x}_i, \mathbf{x}_j$ とする。また、写像後のデータを式(1)における \mathbf{Y} とする。

$$\mathbf{Y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N) \quad (1)$$

$\mathbf{x}_i, \mathbf{x}_j$ の写像を $\mathbf{y}_i, \mathbf{y}_j$ とし、 $\mathbf{x}_i, \mathbf{x}_j$ 間の距離を表す類似度となる重みを $W_{i,j}$ とすると、写像を求めるには、式(3)の制約条件の下で式(2)を満たす \mathbf{Y} の最適値

\mathbf{Y}^* を求めれば良いことになる。

$$\mathbf{Y}^* = \underset{\mathbf{Y}}{\operatorname{argmin}} \sum_{i,j} \|\mathbf{y}_i - \mathbf{y}_j\|^2 W_{i,j} \quad (2)$$

$$\mathbf{Y}^T \mathbf{D} \mathbf{Y} = 1 \quad (3)$$

ここで、式(3)の D は重みの対角行列であり、式(4)のように表せる。また、写像された空間でのサンプルの大きさを一意に決定する必要があり、このために式(3)の制約条件は、射影 \mathbf{Y} の倍率の制限を表している。

$$D_{i,j} = \begin{cases} \sum_j W_{i,j} & (i = j) \\ 0 & (i \neq j) \end{cases} \quad (4)$$

そして、式(5)のように L を定義する。式(5)における L がグラフラプラシアン行列であり、グラフ構造を行列表現したものである。また、式変形により式(2)の右辺は式(6)のように表現できる。なお、式(5)での W は、 $\mathbf{x}_i, \mathbf{x}_j$ 間の重み(類似度) $W_{i,j}$ を (i, j) 成分に持つ重み行列である。

$$L = D - W \quad (5)$$

$$\sum_{i,j} \|\mathbf{y}_i - \mathbf{y}_j\|^2 W_{i,j} = 2\mathbf{Y}^T \mathbf{L} \mathbf{Y} \quad (6)$$

$$\mathbf{Y}^* = \underset{\mathbf{Y}}{\operatorname{argmin}} \mathbf{Y}^T \mathbf{L} \mathbf{Y} \quad (7)$$

さらに、式(3)の制約条件の下で式(7)を満たす \mathbf{Y} は、ラグランジュの未定乗数法を用いることで、式(8)における一般化固有値問題の解として与えられる。今回はこの固有ベクトルのうち、固有値の大きい物から順に取ることで低次元化を実現した。

$$\begin{aligned} h(\mathbf{y}) &= \mathbf{Y}^T \mathbf{L} \mathbf{Y} - \lambda(\mathbf{Y}^T \mathbf{D} \mathbf{Y} - 1) \\ \frac{\partial h}{\partial \mathbf{y}} &= 0 \Rightarrow \mathbf{L} \mathbf{Y} = \lambda \mathbf{D} \mathbf{Y} \end{aligned} \quad (8)$$

$$\text{where } D_{i,i} = \sum_j W_{i,j}, L = D - W$$

2.2 Laplacian Eigenmaps の適用方法

$$W_{i,j} = \exp\left(-\frac{d(\mathbf{x}_i, \mathbf{x}_j)}{2c}\right) \quad (9)$$

$$d(\mathbf{x}_i, \mathbf{x}_j) = \sum_{k=1}^n \min(|x_{ik} - x_{jk}|, 360 - |x_{ik} - x_{jk}|)^2$$

$$\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})^T, \mathbf{x}_j = (x_{j1}, x_{j2}, \dots, x_{jn})^T$$

本稿では、モーションデータに対して Laplacian Eigenmaps を適用する。Laplacian Eigenmaps の重み行列 W は、式(9)で与えるものとする。この重み行列では、サンプル間の距離が近いほど重みは1に近付き、サンプル間の距離が遠いほど重みは0に近づく。

そのため、サンプルの近隣の距離関係を保存したまま、低次元化することが可能になる。また、 n は姿勢の次元数であり、 c はカーネルのサイズを変化させるパラメータであり、本稿では経験的に $c = 50000$ とした。 $\mathbf{x}_i, \mathbf{x}_j$ は i, j 番目のサンプルであり、本手法では i, j フレームでの姿勢に対応している。サンプル間の距離に関しては、式(10)のように定める。これより、サンプルである関節角同士の距離を定義している。

本稿では、人間の自然な動作を表現できるデータの次元数に関する研究¹²⁾を考慮し、モーションデータの次元数を5次元に下げる。

2.3 低次元化結果

低次元化の対象としたモーションキャプチャデータは様々な位置に手を伸ばす Reaching 動作であり、空間統計学を用いた補間手法⁹⁾により、少数のモーションデータから補間してデータベースのレコードとなる動作データを生成した。補間する元となる動作データには、文献⁹⁾の手法中で用いられている動作データを使用した。

動作は関節数31、フレーム数10000であるbvh形式のモーションキャプチャデータである。Laplacian Eigenmaps を用いて姿勢データを低次元化した結果を、図1に示す。この図では、93次元の動作データを5次元に低次元化し、そのうち第1、第2主成分を軸に取り、平面上にプロットした。この図においては、各グラフ上の点が、それぞれ到達運動における人間の姿勢に対応している。つまり、動作フレーム数だけ、グラフ上に点がプロットされている。図1の中央部分には直立状態の姿勢がプロットされ、グラフ上の右側には手を伸ばした状態の姿勢がプロットされている。つまり、高次元データの中からうまく動作の特徴を抽出することが可能であり、モーションデータの姿勢特徴を的確に低次元化して表現していることが分かる。

3. Clustering Large Applications による姿勢の分類

動作の姿勢に対し、Laplacian Eigenmaps を適用して5次元に低次元化した姿勢を、分割クラスタリング手法によって分類する。本研究では、人間のモーションという高次元データを複数取り扱うため、大規模データ向けのクラスタリング手法であるCLARA(Clustering Large Applications)¹¹⁾を用いた。

3.1 Clustering Large Applications の適用

CLARA とは、非階層型クラスタリング手法の一つであり、k-medoids method を利用したアルゴリズムである。medoid(最もクラスタの中心付近に位置する




図 1 Laplacian Eigenmaps による動作データの低次元化

オブジェクト) を用いて分割を評価する。具体的には、クラスタリングによって分割されたデータと medoid の相違度の総和をポテンシャル (クラスタリングの評価関数) として選び、これが小さくなるよう反復して更新していく。ポテンシャルは式 (10) により定義される。ここで、 U はクラスタリングする全データを、 k は分割するクラスタ個数を表す。

$$\sum_{A \in U} \min_{i \leq j \leq k} \text{distance}(A, O_j) \quad (10)$$

具体的なアルゴリズムは、以下のように表現できる。

- (1) データの小さなサンプル (分割数の 2 倍強程度) を取る
- (2) このサンプルの中から、PAM (Partitioning around Medoids)¹¹⁾ を用いて medoid を決定する
- (3) サンプルをいくつかとり、得られた結果の中から最も良いものを出力する

本稿では試行回数を 50 回として CLARA を実行し、クラスタリングを行った。

3.2 分類結果

Laplacian Eigenmaps によって射影したサンプルを CLARA によってクラスタリングした結果を図 2 に示す。図 1 の場合と同様に、低次元化後の上位第 1, 2 主成分をプロットした。

図 2 では、5 次元上での分割を 2 次元に射影して表現しているので明確ではないが、CLARA によりデータは 5 個のクラスタに分割されている。Laplacian Eigenmaps により姿勢空間で特徴を抽出したため、類似する姿勢がクラスタリングされ、クラスタごとに特徴の異なった姿勢が分類されている事が分かる。




図 2 CLARA による姿勢の分類

4. 到達運動の分類

各一回ごとの到達運動が CLARA で生成された姿勢集合を通過した順番によって、各動作を分類する。この時、全ての動作一つ一つは、この順番によって特徴付けられる。

例として、姿勢集合 A, B, C に対して AAAABCC という順番で通過する到達運動は、ABC という文字列の並びとして特徴付けることが可能である。このように特徴付けることで、姿勢の遷移という空間的特徴を取り入れ、簡潔に動作の特徴を表現することができる。

次に、類似する動作を併合してまとめていき、動作集合を生成する。ここで、動作類似性の定義には、姿勢集合要素の重心位置間のユークリッド距離で重みづけされたレーベンシュタイン距離¹³⁾を用いる。また、この動作併合においては、単一動作が複数の動作集合に含まれることを許すものとする。

4.1 レーベンシュタイン距離

レーベンシュタイン距離 (編集距離)¹³⁾ とは、長さの異なる 2 つの文字列がどの程度異なっているかを示す値である。具体的には、文字の挿入や削除、置換によって、一つの文字列を別の文字列に変形するのに必要な手順の最小回数として与えられる。また、レーベンシュタイン距離においては、文字の挿入や削除、置換という一つの手順につき、長さ 1 の距離が定義される。しかし本稿では、到達運動が通過した姿勢のクラスタが、レーベンシュタイン距離での文字に対応する。このため、大きく異なる姿勢のクラスタ間の距離も、ほぼ同じである姿勢のクラスタ間の距離も、異なるクラスタであれば全て長さ 1 と定義されてしまう。これでは、類似する動作を正しく分類することはできない。そこで、重み付けを行うことによって、より実際の距離関係を反映するように改善する。具体的には、姿勢クラスタの重心間におけるユークリッド距離でレーベンシュタイン距離を重み付けし、姿勢の違いを距離に反映させる。

5. 隠れマルコフモデルによるモデル化

隠れマルコフモデル (HMM) は、不確定な時系列のデータをモデル化するために有効な統計的手法である。HMM は、出力シンボルによって一意に状態遷移先が決まらないという意味での非決定性確率有限オートマトンとして定義される。出力シンボル系列が与えられても状態遷移系列は唯一に決まらない。観測できるのはシンボル系列だけであることから隠れマルコフモデルと呼ばれる¹⁵⁾。

本研究では、姿勢空間での低次元化したデータを HMM で学習させることでモデル化を実行する。本手法により、少ない計算量で重要な特徴のみを抽出しつつ動作のモデル化を行うことができる。このモデル化により動作間の尤度を求めることで、2 つの動作間の距離 (類似度) を定義することが可能になる。これより、入力動作に対する類似度に応じて動作集合を出力することが可能になる。具体的には、姿勢空間でクラスタリングすることにより一意に特徴づけした動作に対し、類似する特徴を持つ動作を同じ種類の動作と考え、従来の動作認識手法⁵⁾と同様に HMM で学習させモデル化を行う。

モデルの選定に関しては、各状態における出力分布を全共分散、混合ガウスとした連続出力型 HMM を用いて実験を行った。事前実験より、HMM は Ergodic 型構造を用いた。なお、テストサンプルが不足する場合は考えられたため交差検定による実験を行った。各状

態の混合係数を 1 と固定し、状態数を変えながら算出した認識率の結果を図 3 に示す。




図 3 各状態数における動作認識率

図 3 より、3 状態以上では認識率が 100 % になっていることがわかる。本手法を用いてうまく類似動作を分類することができており、この動作群については、3 状態の HMM モデルを生成すれば十分であることがわかる。

HMM を適用することで、動作間の類似度を定義することが可能になった。その後、この類似度に応じてデータベース中の動作についてインデックス付けを行うことで、類似動作を検索可能な動作データベースを構築することができる。

6. 実験

6.1 他動作に対する実験

本手法を、他のモーションデータに適用する実験を試みた。動作データは、Punching 動作、荷物移動動作 (Transfer)、Reaching 動作の 3 種類である。今回は空間統計学を用いた補間手法⁹⁾により、少数のモーションデータから補間してデータベースのレコードとなる動作データを生成した。各動作はそれぞれ、関節数 20 ~ 30、フレーム数 10000 程度である bvh 形式のモーションキャプチャデータである。実験には動作表示としてサンプルプログラム⁸⁾を用い、文献⁹⁾の手法中で用いられている動作データに加え、豊橋技術科学大学の提供するモーションキャプチャデータ¹⁶⁾を用いた。各動作について、対象となる動作データ集合を図 4(a), (d), (g) に、低次元化を行いクラスタリングした結果を図 4(b), (e), (h) に示す。また、HMM によるモデル化を行い、入力動作と類似する動作集合を求めた結果を図 4(c), (f), (i) に示す。

6.2 他手法との比較実験

比較実験として、低次元化手法に PCA, MDS を用

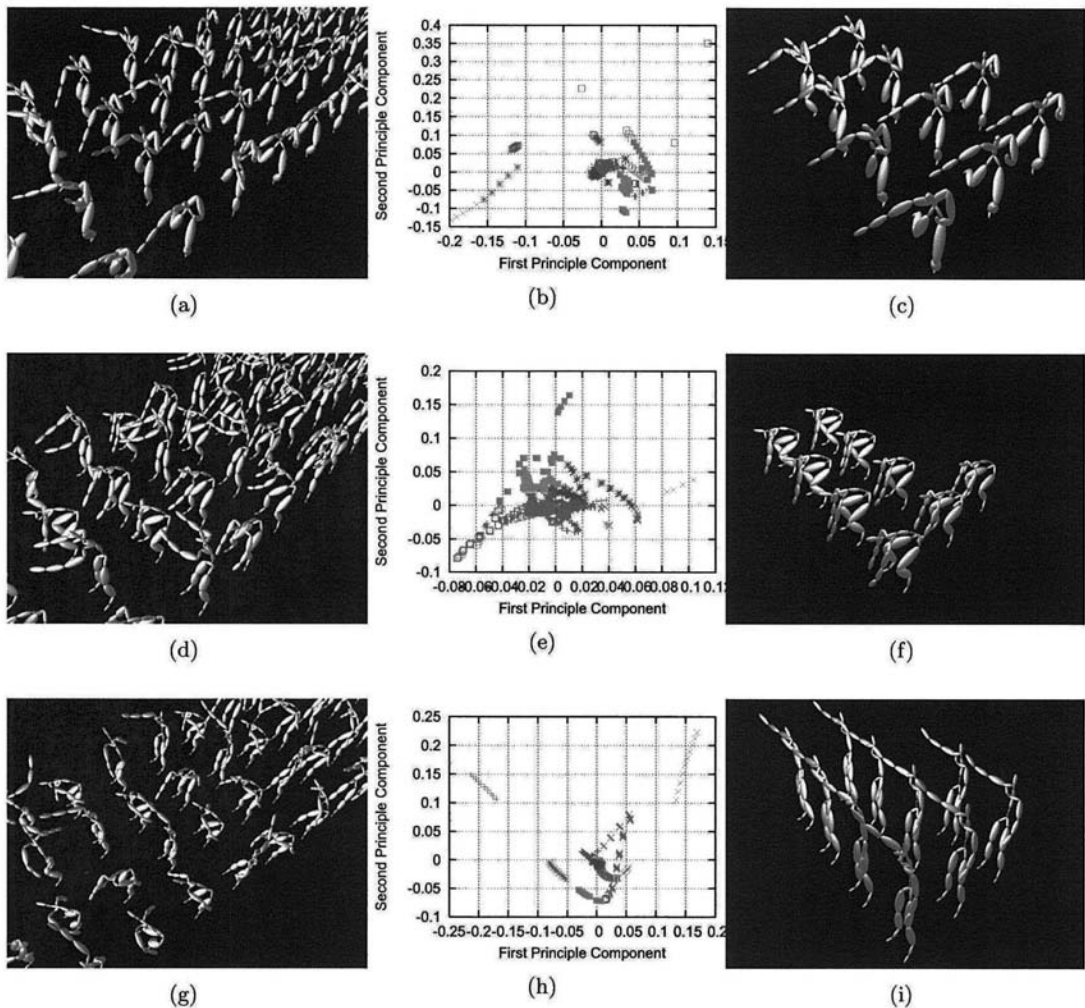


図4 本手法の適用結果;
 上段: Punching (a) 対象動作データ集合 (b) CLARA による分類結果 (c) 類似動作集合;
 中段: Transfer (d) 対象動作データ集合 (e) CLARA による分類結果 (f) 類似動作集合;
 下段: Reaching (g) 対象動作データ集合 (h) CLARA による分類結果 (i) 類似動作集合

いた実験を行う。対象データは、全200個の Reaching 動作である。これは、位置や物体を掴む向きを変えて取得した動作データである。この Reaching 動作に対して Laplacian Eigenmaps の代わりに PCA, MDS を用いて、その他の条件は同様にして実験を行った。この時の対象となる動作データ集合を図5に、低次元化を行いクラスタリングした結果を図6(a), (c), (e)に示す。また、HMM によるモデル化を行い、入力動作と類似する動作集合を求めた結果を図6(b), (d), (f)

に示す。さらに、HMM モデルを作成して同様に交差検定による実験を行った。各状態の混合係数を1と固定し、各手法を用いて状態数を変えながら算出した認識率の結果を図7に示す。

本手法とその他の手法を適用した結果を比較する。まず低次元化後のクラスタリング結果(図6(a), (c), (e))では、PCA, MDS とも広く全体的にデータが分布していることがわかる。それに対して本手法では、データが偏って左右に分布しており、これが Reaching 動作

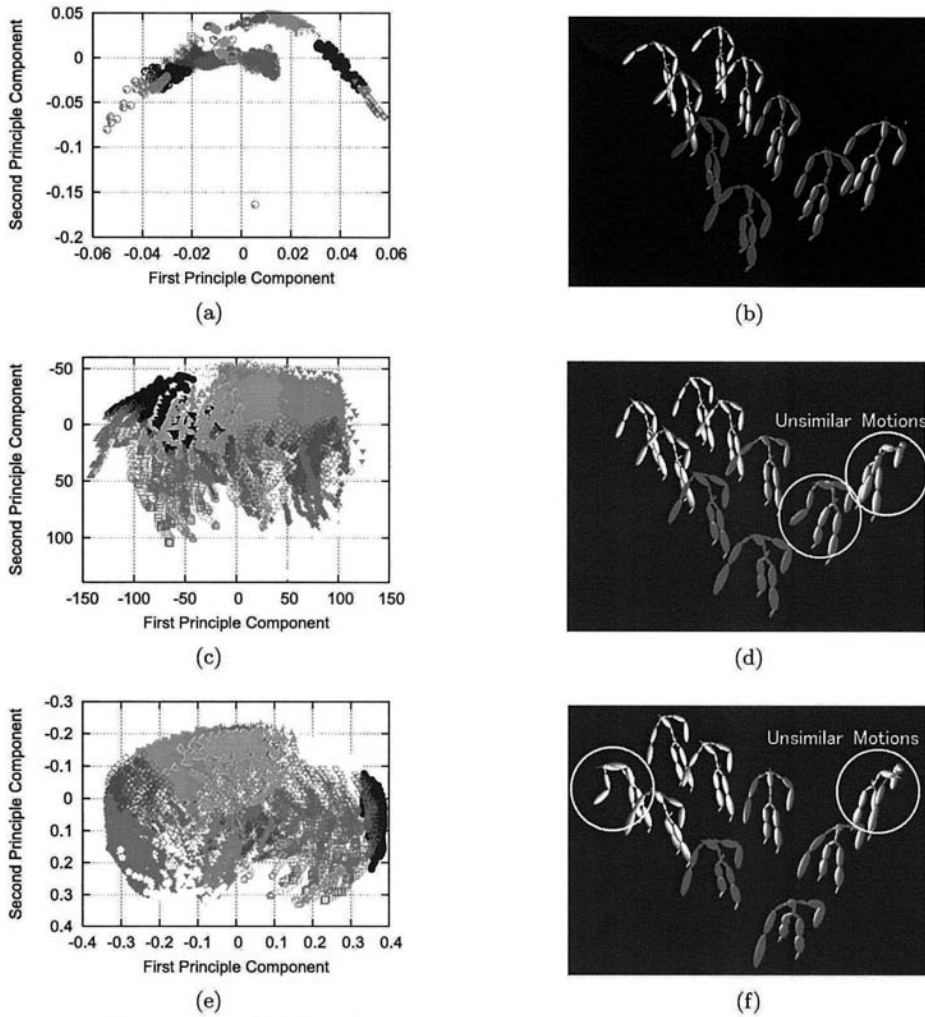


図 6 Reaching 動作に対する比較実験結果;
 上段: Our Method (a) CLARA によるクラスタリング結果, (b) 類似動作集合;
 中段: PCA (c) CLARA によるクラスタリング結果, (d) 類似動作集合;
 下段: MDS (e) CLARA によるクラスタリング結果, (f) 類似動作集合;

の手を伸ばした位置に対応している。これは、データの
 詳細な特徴を抽出することが可能な Laplacian Eigen-
 maps の特性によるものであり、動作の特徴をうまく
 表現できていると言える。このため、的確に低次元化
 ができずに全体的にデータが分散してしまい、多くの
 動作が同じような特徴になってしまう PCA, MDS に
 比べ、動作が特徴に応じて的確に分類できるため、図
 7 で示される最終的な動作認識率も本手法の方が高
 くなっている。これは、図 6(d), (f) における分類された
 動作中に、一部他の動作と異なる特徴を持つ動作が含

まれていることから確認できる。

7. 結 論

本論文では、次元削減手法によって抽出した姿勢デー
 タをクラスタリングによって特徴づけし、HMM を用
 いて学習することで動作データベースのインデックス
 付けを行う新たな手法を提案した。まず、動作データ
 を低次元化し、姿勢空間でクラスタリングする。そし
 て、クラスターの遷移によって動作を特徴づけ、HMM
 によって姿勢の遷移を学習することにより、様々な動



図 5 対象動作データ集合




図 7 状態数における各手法の動作認識率

作集合に適用可能な動作の類似度を導入でき、これを用いてインデックス付けを実現する。

これより、従来手法での問題点のように、検索時において動作毎に異なる検索条件を発見的に与える必要が無い。また、自動的に類似する動作集合を集めるため、他多数の動作と大きく異なる動作や、ノイズ・エラー値を含むような動作データが混在した場合でも、クラスタリングにより自動的に分類されるため、類似集合から除去することも可能である。

今後の課題としては、本論文では動作データの特徴量として関節角のみを用いているため、他に位置や速度、加速度等の特徴量も考慮¹⁾して、より動作分類の精度を向上させたいと考えている。

参 考 文 献

- 1) Assa, J., Caspi, Y. and Cohen-Or, D.: Action synopsis: pose selection and illustration, *SIGGRAPH '05: ACM SIGGRAPH 2005 Papers*, ACM Press, pp.667–676 (2005).
- 2) Belkin, M. and Niyogi, P.: Laplacian eigenmaps

for dimensionality reduction and data representation (2002).

- 3) Charles F Rose III, Peter-Pike J Sloan, M. F.C.: Artist-Directed Inverse-Kinematics Using Radial Basis Function Interpolation, *Computer Graphics Forum 20 (3)*, pp.239–250 (2001).
- 4) CMU: Carnegie-Mellon MoCap Database. <http://mocap.cs.cmu.edu>. (2003).
- 5) Elgammal, A., Sht, V., Yacooob, Y. and Davis, L.: Learning dynamics for exemplar-based gesture recognition (2003).
- 6) J.B.Tenenbaum, V.deSilva, J.: A Global Geometric Framework for Nonlinear Dimensionality Reduction, Vol.290, pp.2319–2323 (2000).
- 7) Kovar, L. and Gleicher, M.: Automated extraction and parameterization of motions in large data sets, *SIGGRAPH '04: ACM SIGGRAPH 2004 Papers*, ACM Press, pp.559–568 (2004).
- 8) MUKAI, T.: TMPWiki. <http://www.tmps.org/> (2006).
- 9) Mukai, T. and Kuriyama, S.: Geostatistical motion interpolation, *SIGGRAPH '05: ACM SIGGRAPH 2005 Papers*, ACM Press, pp.1062–1070 (2005).
- 10) Muller, M., Roder, T. and Clausen, M.: Efficient content-based retrieval of motion capture data, *SIGGRAPH '05: ACM SIGGRAPH 2005 Papers*, ACM Press, pp.677–685 (2005).
- 11) Ng, R.T. and Han, J.: Efficient and Effective Clustering Methods for Spatial Data Mining, *20th International Conference on Very Large Data Bases, September 12–15, 1994, Santiago, Chile proceedings* (Bocca, J., Jarke, M. and Zaniolo, C., eds.), Los Altos, CA 94022, USA, Morgan Kaufmann Publishers, pp.144–155 (1994).
- 12) Safonova, A., Hodgins, J.K. and Pollard, N.S.: Synthesizing physically realistic human motion in low-dimensional, behavior-specific spaces, *SIGGRAPH '04: ACM SIGGRAPH 2004 Papers*, ACM Press, pp.514–521 (2004).
- 13) Soukoreff, R.W. and MacKenzie, I.S.: Measuring errors in text entry tasks: an application of the Levenshtein string distance statistic, *CHI '01: CHI '01 extended abstracts on Human factors in computing systems*, ACM Press, pp.319–320 (2001).
- 14) TORGERSON, W.: Multidimensional scaling: 1. theory and method., *Psychometrika*, Vol.17, pp.401–419 (1952).
- 15) 中川聖一: 確率モデルによる音声認識, (社) 電子情報通信学会 (1988).
- 16) 豊橋技術科学大学: TOYOHASHI MOTION LIBRARY on Web. <http://tomolow.vcl.ics.tut.ac.jp/> (2005).