

関節軌道の相関を考慮した身体動作認識

Motion recognition based on the correlation between joint trajectories

加藤 拓也 † 加藤 昇平 †
Takuya Kato Shohei Kato

1 はじめに

近年, Microsoft の Kinect や任天堂の Wii を始めとする, 人間の身体動作を入力とするハードウェアが普及している. これらのハードウェアによって, 人間の行った動作を認識し, ヒューマノイドロボットや仮想空間上のアバターに反映することで意図した通りの操作が容易になった. そのため, より正確な身体動作の認識が求められている.

これまでに提案されている動作認識の手法には稲邑ら [1] による隠れマルコフモデル (HMM) を用いた手法などが存在する. この認識手法では, HMM を用いて時系列な身体部位情報を用いて認識が可能であり優れた認識性能を示すため, この手法を基にした様々な改良手法が提案されている [2][3][4]. これらの認識手法では, 各身体部位情報は独立と仮定して認識を行っている. しかし人間の身体動作において, 関節角や身体部位などの身体情報が独立して動くことは稀であり, 多くの場合いくつかの身体情報の変化は相関関係をもつ. このため複数の身体情報の相関を考慮して認識を行う必要がある. そこで本研究では主成分分析 (PCA) を用いた身体動作認識手法を考案する. また, 人間による他者の身体動作の認識時には, その動作によって注目する部位が異なると考える. 特に, 他者の動作を模倣する時には, 身体の中心部より先端部の位置を注視することが知られている [5]. そのため, 動作における注目部位を重視して認識を行う手法が有効と考える. そこで本研究では, 複数の関節の相関関係を考慮しつつ, 注目部位を重視して動作を認識する手法 (重み付き PCA 法) を提案する.

2 相関を考慮した身体動作認識

図 1 に重み付き PCA 法の概要を示す. 重み付き PCA 法は学習部と認識部で構成されている.

重み付き PCA 法では, 身体情報の時系列データを使用することで動作認識を行う. また, 身体動作においていくつかの身体情報の変化は相関関係を持つため, 主成分分析を用いることで身体情報の時系列データを相関を考慮した情報に変換する. 主成分分析は多変量解析における手法であり, 多変量の変数から成るデータにおいて, それらの変数が互いに何らかの相関を持つときにこれらの変数を合成・変換して総合指標となる変数を作る

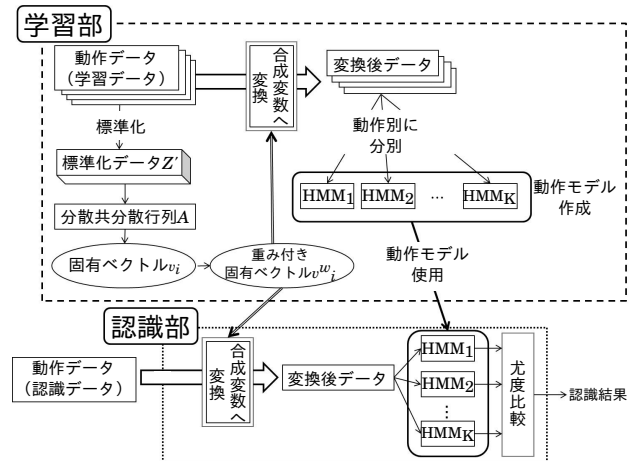


図 1 重み付き PCA 法概要

手法である. ここで, 本研究では手先や足先の位置など動作認識において注目する部位を重視するために主成分分析による変換の過程で変数に対して重み付けを行い変数を変換する. そして, 変換後の時系列データを使用して HMM で認識を行う.

2.1 主成分分析

相関を考慮したデータへ変換を行う主成分分析では, まず E 個の変数から成るデータが N 個あるとき (本研究では, N は時系列長^{*1}), $E \times N$ のデータ行列 Z を作成し変換を行う. Z の標準化データ行列 Z' を使用して分散共分散行列 A を作成し, A から固有値固有ベクトル v_i を求める ($i = 1, \dots, E$). 次にデータ行列 Z を, v_i を用いて式 (1) のように $E \times N$ のデータ行列 X へと変換する.

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_E \end{bmatrix}, \quad (1)$$

$$\text{ただし } x_i = v_i Z \quad (i = 1, 2, \dots, E).$$

固有ベクトルを用いてデータ行列を変換することを, 合成変数への変換という. また, 式 (1) で算出される x_i を第 i 主成分という. 主成分はもとのデータの相関を考慮した変数となっている.

*1 本研究では, 変換時には時間を無視して N 個のデータとみなして主成分分析を行う.

† 名古屋工業大学, Nagoya Institute of Technology

2.2 HMM

動作の認識に使用する HMM は、学習する動作データを使用し動作モデル Λ を作成する。観測データを認識するときには、 Λ とどの程度マッチするか尤度を算出する。動作モデルは $\Lambda = (Q, S, B, C, \pi)$ で表され、状態の有限集合 $Q = \{q_1, \dots, q_F\}$ 、出力記号の有限集合 $S = \{o_1, \dots, o_G\}$ 、状態 q_i から状態 q_j に遷移する確率分布 $B = \{b_{ij}\}$ 、状態 q_i において出力記号 o_j を出力する確率分布 $C = \{c_{ij}\}$ 、初期状態確率分布 $\pi = \pi_i$ 、の 5 項の組で表現される。また、本研究では、時系列データの特徴を保存することに適した Left-to-Right 型の HMM を採用する。

2.3 学習部

学習部では、認識対象の各動作を HMM を用いて学習することで、各動作に対する動作モデルをそれぞれ作成する。このとき重み付き PCA 法では、与えられた学習データから動作モデルを作成するのではなく、主成分分析を用いて相関を考慮した合成変数へと変換してから動作モデルを作成する。

学習部では学習データが与えられたときに、それらの学習データを主成分分析して合成変数へと変換する。 E 個の変数からなる K 種類の動作の学習データが各 M 個ずつ与えられ、動作 k の m 番目の学習データが時間長 T_{k_m} の時系列データとして与えられる。重み付き PCA 法では、これらのデータを主成分分析へと適用するために、 $K \times M$ 個の時系列データを連結することでデータを整形し、データ行列 Z を作成する。行列 Z のサイズは、 $E \times \sum_{k=1}^K \sum_{m=1}^M T_{k_m}$ となる。整形後のデータ行列 Z を用いて 2.1 節で述べた方法により、固有ベクトル v_i の算出を行う。

ここで、認識時に注目すべき部位を重視するために、固有ベクトルの要素に対して重み付けを行う。算出された固有ベクトル $v_i = [a_{1i} \ a_{2i} \ \dots \ a_{Ei}] (i = 1, 2, \dots, E)$ の各要素 a_{ji} に対してそれぞれ重み w_j を決定し、重み付き固有ベクトル v^w_i を式 (2) のように求める。

$$v^w_i = [w_1 a_{1i} \ w_2 a_{2i} \ \dots \ w_E a_{Ei}] . \quad (2)$$

このように決定された重み付き固有ベクトルを用いることで、各学習データを合成変数へと変換する。

主成分分析によって獲得された合成変数に対して、動作ごとに Baum-Wealch アルゴリズム [6] を用いて HMM による動作モデルを作成する。動作モデルは動作 k の第 i 主成分の時系列データ O_i^k を Baum-Wealch アルゴリズム [6] を用いて学習させたモデル Λ_i^k とする。

2.4 認識部

認識部では観測データ O が与えられたときに、学習済みの各動作モデル Λ と比較することにより、各動作モデルに対する学習データの尤度 $P(O|\Lambda)$ をそれぞれ計算する。そして $P(O|\Lambda)$ を基に、観測データがどの動作にマッチするか、あるいはどの動作にもマッチしない新規

動作であるかを判定する。

認識部において尤度を計算する場合には、まず観測データ O^R を合成変数へと変換する。ここで、動作モデル Λ_i^k に対する観測データ O_i^R の尤度の算出時には、観測データ O_i^R を学習時に学習データが変換された合成変数へと変換する必要がある。そこで、学習部で算出した重み付き固有ベクトル v^w_i を用いて観測データ O^R を合成変数へと変換し動作データ $O_i^{R'}$ を作成する。 $O_i^{R'}$ と動作モデル Λ_i^k から Viterbi アルゴリズム [7] を使用することにより、尤度 $P(O_i^{R'}|\Lambda_i^k)$ を算出する。

各動作モデルに対して尤度が算出されると、尤度を比較することで観測データを判別する。しかし、ここで算出される尤度は非常に小さい値となるため、アンダーフロー防止のため対数尤度を使用する。また、算出される尤度は動作モデルごとに尺度に差があるため、そのまま数値比較をすることができない。そこで、動作モデルごとに対数尤度を正規化し動作モデル間で数値比較ができる値にする。正規化尤度 $L'(O_i^{R'}|\Lambda_i^k)$ は、学習した全ての動作を動作モデル Λ_i^k を使用して認識して得られた対数尤度の平均値 μ_i^k と分散 σ_i^{k2} を用いて式 (3) のように求められる。

$$L'(O_i^{R'}|\Lambda_i^k) = \frac{\log P(O_i^{R'}|\Lambda_i^k) - \mu_i^k}{\sigma_i^k} . \quad (3)$$

このように計算された各動作モデルに対する正規化尤度を比較することで、観測データがどの動作モデルにマッチするかを判定する。認識部ではヒューリスティックに設定した閾値を持っており、全ての主成分にける正規化尤度が閾値を超えた動作を認識結果とする。ただし、閾値を超える動作が複数存在する場合には、動作間で主成分ごとに算出された正規化尤度の和が最大となる動作を認識結果とする。また、いずれの動作においても正規化尤度が閾値を超えなかった場合は、学習していない新規動作であると認識する。

3 身体動作認識実験

3.1 実験設定

重み付き PCA 法の有効性を検証するために身体動作認識実験を行った。対象とする動作は空手における「突き」の動作とし、異なる 3 箇所の位置を突く動作の識別を行った。突く位置は「上段」「中段」「下段」とし、3 種類の突きの動作 ($K = 3$) を認識した (図 2 は中段を突いた様子)。

実験には Microsoft 社の Kinect を使用して、0.1[sec] ごとの関節角度を取得した。対象とする関節は、右手の肘 (e)、右手の肩の pitch 角 (s_p)、右手の肩の roll 角 (s_r) の 3 つとした ($E = 3$)。このとき、変数変換に使用する固有ベクトルは $v_i = [a_{ei} \ a_{s_p i} \ a_{s_r i}]$ と表される。

これらの動作の時系列データは、各動作につき 20 代男性 10 人から合計 300 データ取得した。そのうち 150




図 2 「突き」の動作 (中段)




図 4 肘関節と肩関節 (roll 角)




図 3 肘関節と肩関節 (pitch 角)

データを学習用データとし ($M = 150$), 残りの 150 データの最初の 100 データを正規化尤度パラメータ ($\mu_i^k, \sigma_i^{k^2}$) を算出するために使用し, 観測データとして 50 データを認識した. 各動作の観測データを, 直接法, 単純 PCA 法, 重み付き PCA 法, を用いて認識率を比較した. また, 全学習データの平均時系列長は約 13.2 であり, HMM の設定パラメータは $F = 10, G = 36$ とした.

3.2 注目部位の設定

本実験では対象とする動作が腕の運動であるため, 注目する部位として手先位置を考え, 式 (4) のように固有ベクトルの要素に対して重み付けを行う.

$$v^w_i = [w_e a_{ei} \ w_{s_p} a_{s_p i} \ w_{s_r} a_{s_r i}] . \quad (4)$$

手先位置を重視できるように, 固有ベクトルの要素に対して重み付けを行うが, 体の中心に近い関節ほど手先位置に大きく影響を与えると考えられるため, 肩関節に対して大きく重みを付ける. 関節 j の重み w_j は, 肘関節を肩関節と同じ方向に同じ角度回転させたときの移動経路長の比から算出した. しかし, 肩関節の回転時には肘関節の角度に依存して移動経路長が変化する. そこで, 本実験で扱ういずれの動作も肘関節を大きく変化させる動作であるため, 肘関節の可動角度の中央値である $\frac{\pi}{2}$ [rad] に肘関節を固定して, 肩関節の重みを計算した.

3.2.1 肘関節と肩関節

図 3 に肘関節と肩関節 (pitch 角) の動作の模式図を示す. 図 3 から分かるように, 肘関節を θ 回転させたときの移動経路長 l_1 と, 肘関節を $\frac{\pi}{2}$ [rad] に固定して肩関節 (pitch 角) を θ 回転させたときの移動経路長 l_2 の比は, 前腕の長さ r_1 と上腕の長さ r_2 を用いて式 (5) のように表

すことができる.

$$l_1 : l_2 = r_1 \theta : \sqrt{r_1^2 + r_2^2} \theta . \quad (5)$$

ここで, 一般的な人体構造から $r_1 \approx r_2$ であるので式 (6) のように定まる.

$$l_1 : l_2 = 1 : \sqrt{2} . \quad (6)$$

図 4 に肘関節と肩関節 (roll 角) の動作の模式図を示す. 図 4 から, 肘関節を ϕ 回転させたときの移動経路長 l_3 と, 肘関節を $\frac{\pi}{2}$ [rad] に固定して肩関節 (roll 角) を ϕ 回転させたときの移動経路長 l_4 の比は式 (7) のように定まる.

$$l_3 : l_4 = 1 : \sqrt{2} . \quad (7)$$

式 (6)(7) より, 各関節の重み w_e, w_{s_p}, w_{s_r} を, 式 (8) で決定する.

$$\begin{cases} w_e = 1 , \\ w_{s_p} = \sqrt{2} , \\ w_{s_r} = \sqrt{2} . \end{cases} \quad (8)$$

3.3 比較手法

本実験における比較手法として, 関節角度の相関関係を考慮せずに各関節を独立に認識する手法 (直接法), ならびに重み付き PCA 法のように特定の部位に注目するのではなく全ての関節を同等に扱う認識手法 (単純 PCA 法) の 2 種類用意した. 直接法では学習時と認識時に与えられた時系列データを合成変数へ変換せずに HMM に対して適用する. 単純 PCA 法では重み付き PCA 法と同様に合成変数への変換を行うが, 固有ベクトルに重み付けを行わない.

3.4 実験結果

3.4.1 相関関係の有効性

表 1 ~ 表 3 に実験結果を示す. まず, 直接法と単純 PCA 法を比較する. 表 1 と表 2 の総合認識率を比較すると, 単純 PCA 法の方が認識率が優れていることが分かる. 表 1 から, 直接法は, 上段と下段をいずれも中段に誤認識しやすいことが分かる. これは, 直接法では各関節を独立で認識していることが原因と考えられる. 本

表 1 直接法での認識

| | | 認識結果 | | | | 認識率 |
|----|----|------|------|-----|-----|-------|
| | | 上段 | 中段 | 下段 | 新規 | |
| 動作 | 上段 | 19 回 | 31 回 | 0 回 | 0 回 | 38% |
| | 中段 | 6 回 | 41 回 | 3 回 | 0 回 | 82% |
| | 下段 | 10 回 | 39 回 | 1 回 | 0 回 | 2% |
| | | | | | | 40.7% |

表 2 単純 PCA 法での認識

| | | 認識結果 | | | | 認識率 |
|----|----|------|------|------|-----|-------|
| | | 上段 | 中段 | 下段 | 新規 | |
| 動作 | 上段 | 29 回 | 5 回 | 16 回 | 0 回 | 58% |
| | 中段 | 7 回 | 37 回 | 6 回 | 0 回 | 74% |
| | 下段 | 6 回 | 25 回 | 19 回 | 0 回 | 38% |
| | | | | | | 56.7% |

表 3 重み付き PCA 法での認識

| | | 認識結果 | | | | 認識率 |
|----|----|------|------|------|-----|-------|
| | | 上段 | 中段 | 下段 | 新規 | |
| 動作 | 上段 | 32 回 | 17 回 | 1 回 | 0 回 | 64% |
| | 中段 | 4 回 | 40 回 | 6 回 | 0 回 | 80% |
| | 下段 | 0 回 | 0 回 | 50 回 | 0 回 | 100% |
| | | | | | | 81.3% |

実験の対象動作は、いずれも突き動作であり、肘関節の変化は各動作で違いがほとんどないため、突く位置の違いは肩関節がどれだけ変化したかに影響する。各関節を独立に認識すると、肘関節を認識した尤度は各動作で差がほとんどなく、肩関節の認識での尤度に依存した認識結果になると考えられるが、中段は上段及び下段と突く位置が近いことから尤度に差が現れにくいと考えられる。しかし、肘関節が変化する際に、肩関節がどの程度変化したかという相関を考慮したことで、単純 PCA 法では総合認識率が向上したと考えられる。これにより、関節の相関関係を考慮した認識手法の有効性が示唆された。

3.4.2 注目部位の有効性

表 3 に関節の相関関係と注目部位の重要度の双方を考慮した重み付き PCA 法を用いて各動作を認識した結果を示す。表 2 と表 3 を比較すると、重み付き PCA 法の方が優れた総合認識率を示していることがわかる。また、単純 PCA 法での誤認識の際の認識結果を見ると、上段を下段と誤認識しやすいことが分かる。本実験で用いた突き動作は、突く位置の違いから、上段と中段および中段と下段の誤認識は上段と下段の誤認識より小さい

と言える。しかし、単純 PCA 法では上段と下段を誤認識する大きな誤りを犯していることがわかるが、重み付き PCA 法ではほとんどが小さい誤りとなっている。以上のことから注目部位の重要度を考慮した認識手法が有効であったことが分かる。

4 おわりに

本稿では、身体動作の認識において、複数関節の相関を考慮し、身体先端部の位置情報を重視した認識手法を提案した。重み付き PCA 法では、与えられた時系列データに対して主成分分析を行うことで関節間の相関を考慮し、合成変数への変換時に重視する関節に重み付けを行うことで、身体先端部の位置を重視した動作認識を行う。提案した手法の有効性を確認するために、空手の「突き」動作を題材にして身体動作認識実験を行った。その結果、観測した時系列データをそのまま認識する手法よりも、主成分分析を行ったデータを認識する手法が優れた認識結果を示し、複数関節の相関を考慮した認識手法の有効性を示した。そして、主成分分析における合成変数への変換時に身体先端部の位置情報を重視できるように重み付けを行った結果、認識結果が向上し手先位置を重視した認識手法の有効性が確認された。

また、本研究では主成分分析を用いているが、主成分分析を計算する過程で各主成分に対する寄与率が求められる。この寄与率を各主成分を認識するときの尤度判定に用いることで、認識率の向上が考えられる。しかし重み付き PCA 法では、固有ベクトルの要素に重みを付与しているため、従来の寄与率の算出方法では適切な寄与率が求められない。そこで今後は、重みを付き固有ベクトルに対する寄与率を算出する方法を考案することで認識率の向上を目指す。

参考文献

- [1] 稲邑 哲也, 中村 仁彦, "ミメシス理論に基づく見まね学習とシンボル発達の統合モデル", 日本神経回路学会誌, vol.12, No.1, pp.74-80, (2005).
- [2] 奥澤 悠樹, 加藤 昇平, 加納 政芳, 伊藤 英則, "運動の知識化に基づく模倣ロボットの運動認識と応用生成", 電気学会論文誌. C, 電子・情報・システム部門誌, vol.131, No.3, pp.655-663, (2011).
- [3] Yuya Hirose, Shohei Kato, "Intuitive Humanoid Robot Operation System Based on Recognition and Variation of Human Body Motion", KES-IIMSS (2012).
- [4] 森 武俊, 瀬川 友史, 下坂 正倫, 佐藤 知正, "隠れマルコフモデルと動作の階層構造の木表現による日常動作認識", 日本ロボット学会誌 23, Vol.8, (2001)
- [5] 原田 達也, 田岡 創, 森武 俊, 佐藤 知正, "人間の動作模倣のための姿勢類似度評価手法", 日本機械学会ロボティクス・メカトロニクス講演会講演論文集, IA1-H-61, (2004).
- [6] Dempster, A. P., Laird, N. M., and Rubin, D. B., "Maximum likelihood from incomplete data via the EM algorithm", The Journal of the Royal Statistical Society B, Vol.39, pp.1-38, (1977)
- [7] Forney, G. D., "The Viterbi algorithm", Proc. IEEE 61, Vol.3, pp.268-278, (1973)