1S-7

# 判別分析に基づく認識空間を用いた身体動作認識

加藤拓也 † 加藤昇平 †

† 名古屋工業大学

## 1 はじめに

近年，人間の身体動作を入力とするハードウェアの普及に伴い，身体動作の正確な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．この認識手法は，HMM を用いて時系列な身体情報の認識が可能でありかつ認識性能が優れているため，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]．これらの認識手法では各身体情報は独立と仮定して認識を行っているが，人間の身体動作において関節角や関節位置などの身体情報は多くの場合互いに相関を持って変化する．

そこで本研究では，身体情報に対して多変量解析を用いた重みを付与し，複数の身体情報を同時に考慮できる認識空間を生成する．多変量解析の中でも正準判別分析（CDA）はクラス判別に適した変換を行うことが知られている．そこで本稿では，CDA を用いて変換した動作の身体情報を，HMM を用いて学習 · 認識する手法（$HMM_{CDA}$ 法）を提案する．

## 2 判別に適した認識空間での身体動作認識

図 1 に $HMM_{CDA}$ 法の概要を示す．$HMM_{CDA}$ 法は，認識空間生成部と学習部と認識部から構成されている．$HMM_{CDA}$ 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．学習動作の身体情報における時系列データから CDA を用いて認識空間を生成し，認識空間内に射影した身体情報の時系列データを使用して HMM による学習 · 認識を行う．

### 2.1 認識空間生成部

認識空間生成部では，認識対象となる各動作の学習データを用いて認識空間の基底ベクトルを求める．

$E$ 個の変数からなる $K$ 種類の動作 $(motion_1, motion_2, \ldots, motion_K)$ の学習データが各 $M$ 個ずつ与えられ，$motion_k$ 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．

学習動作である $motion_{k_1}, motion_{k_2}$ を任意選択し，CDA を行うことで認識空間 $_{k_1k_2}$ を生成する．CDA は事前に与えられたデータが異なるグループに分かれている場合，新しいデータが得られた際にどちらのグループに属するのかを判別するための基準となる判別関数を得るための手法の一つであり，データの射影を行うための重みを求める．本研究では，認識空間生成時においては時間情報を無視して，$motion_k$ が $\sum_{i=1}^{M} T_{k_m}$ 個のデータ点であるとみなして CDA を実行する．

*Motion Recognition Using Recognition Space Based on Discriminant Analysis, Takuya KATO†, and Shohei KATO†
†Nagoya Institute of Technology
Gokiso-cho, Showa-ku, Nagoya 466-8555, Japan
{tkykato, shohey}@katolab.nitech.ac.jp

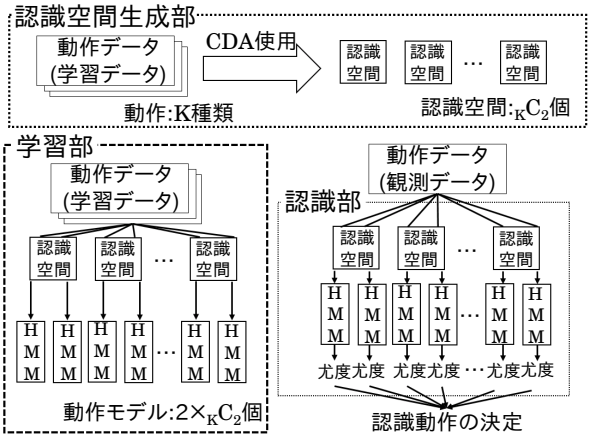


図 1: $HMM_{CDA}$ 法概要

この認識空間の生成を $_KC_2$ 回行い，2 種類の動作を選択する全ての組合せ数の認識空間を生成する．

### 2.2 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．$HMM_{CDA}$ 法では動作モデルを作成する事前に，動作データを認識空間生成部で生成した認識空間内へ射影し，射影後のデータを用いて動作モデルを生成する．

具体的には，$motion_{k_1}$ の動作モデルを生成するために，まず $motion_{k_1}$ を用いて生成した $K-1$ 個の認識空間へ射影し，各認識空間における $motion_{k_1}$ の時系列データを生成する．各認識空間へと変換された時系列データに対して Baum-Wealch アルゴリズムを用いることで HMM による動作モデルを作成する．なお，認識空間 $_{k_1k_2}$ における $motion_{k_1}$ の時系列データ $O_{k_1}^{k_1k_2}$ を Baum-Wealch アルゴリズムを用いて学習させた動作モデルを $\Lambda_{k_1}^{k_1k_2}$ と表す．

### 2.3 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 $\Lambda$ と比較することにより，各動作モデルに対する観測データの尤度 $P(O|\Lambda)$ 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奇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，まず観測データ $O_x$ を認識空間生成部で生成した各認識空間へと変換し時系列データ $O_x^{k_1k_2}$ を生成する．変換後データ $O_x^{k_1k_2}$ と動作モデル $\Lambda_{k_1}^{k_1k_2}$ から Viterbi アルゴリズムを使用することにより，尤度 $P(O_x^{k_1k_2}|\Lambda_{k_1}^{k_1k_2})$ を算出する．各動作モデルに対して尤度を算出すると，$motion_k$ に対する尤度は $K-1$ 個求まる．これは，$motion_k$ を用いて生成された認識空間の数と同じである．この $K-1$ 個の尤度の和を求め，動作の種類ごとに比較すること



Copyright ©2014 Information Processing Society of Japan.
All Rights Reserved.

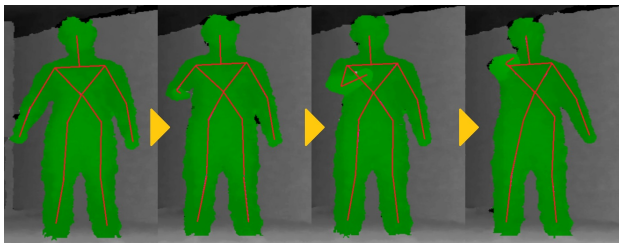

図 2: 「突き」の動作（中段）

で観測データを判別する．ただし，比較には尤度の対数を正規化した正規化尤度 $L'(O_x^{k_1k_2}|\Lambda_{k_1}^{k_1k_2})$ を使用する．正規化尤度は，$motion_{k_1}$ の学習データを動作モデル $\Lambda_{k_1}^{k_1k_2}$ を使用した認識により得られた対数尤度の平均値 $\mu_{k_1}^{k_1k_2}$ と分散 ${\sigma_{k_1}^{k_1k_2}}^2$ を用いて求める．

以上のように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．認識部はヒューリスティックに設定した閾値を持ち，$motion_k$ を用いて生成された認識空間全てにおける $motion_k$ の動作モデルに対する正規化尤度の和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，動作間で正規化尤度の和を比較し，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，学習していない新奇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

$HMM_{CDA}$ 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．実験には Microsoft 社の Kinect を使用し，認識に用いる身体情報として 0.1[sec] ごとに関節角度を取得した．対象とする関節は，右の肘，右の肩の pitch 角，右の肩の roll 角の 3 つとした（$E = 3$）．

対象とする動作は空手における「突き」の動作（図 2）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である．

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 名から 1 人あたり 30 データ取得した．これらの動作データを用いて，各被験者に対して leave-one-out 交差検定を行い，認識を計 300 回実行した．各被験者に対して 29 データを学習用データとし（$M = 29$），学習用の 29 データを認識した尤度を用いて正規化パラメータ（$\mu$，$\sigma^2$）を算出し，残りの 1 データを観測データとして認識した．また，全学習データの平均時系列長は約 13.2 であり，使用する HMM 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 とした．

### 3.2 比較手法

本実験における比較手法として，認識空間への射影を行わずに直接動作データを学習 · 認識する手法（直接法）と，認識空間の生成に主成分分析を使用する手法（$HMM_{PCA}$ 法）を用意した [3]．$HMM_{PCA}$ 法では，認識空間生成時に全ての学習データを使用して求めた分散共分散行列から基底ベクトルを算出する．

表 1: 直接法での認識

| | | 認識結果 | | | | 認識率 |
|---|---|---|---|---|---|---|
| | | 上段 | 中段 | 下段 | 新奇 | |
| 動作 | 上段 | 264 回 | 21 回 | 14 回 | 1 回 | 88.0% |
| | 中段 | 113 回 | 164 回 | 22 回 | 1 回 | 54.7% |
| | 下段 | 56 回 | 10 回 | 234 回 | 0 回 | 78.0% |
| | | | | | | 73.6% |

表 2: $HMM_{PCA}$ 法での認識

| | | 認識結果 | | | | 認識率 |
|---|---|---|---|---|---|---|
| | | 上段 | 中段 | 下段 | 新奇 | |
| 動作 | 上段 | 240 回 | 50 回 | 10 回 | 0 回 | 80.0% |
| | 中段 | 33 回 | 219 回 | 48 回 | 0 回 | 73.0% |
| | 下段 | 7 回 | 68 回 | 225 回 | 0 回 | 75.0% |
| | | | | | | 76.0% |

表 3: $HMM_{CDA}$ 法での認識

| | | 認識結果 | | | | 認識率 |
|---|---|---|---|---|---|---|
| | | 上段 | 中段 | 下段 | 新奇 | |
| 動作 | 上段 | 275 回 | 12 回 | 13 回 | 0 回 | 91.7% |
| | 中段 | 14 回 | 253 回 | 33 回 | 0 回 | 84.3% |
| | 下段 | 9 回 | 16 回 | 275 回 | 0 回 | 91.7% |
| | | | | | | 89.2% |

### 3.3 実験結果

表 1 ～ 表 3 に実験結果を示す．$HMM_{CDA}$ 法と 2 つの比較手法を比較すると，動作ごとの認識率と総合認識率の全てにおいて $HMM_{CDA}$ 法の認識結果が優れていることが分かる．また，$HMM_{PCA}$ 法の認識結果を直接法の認識結果と比較すると，総合認識率は上昇しているものの動作ごとの認識率において減少している部分が見られる．これは，$HMM_{PCA}$ 法では全ての動作データの分散を最大化するように変換することで，全動作を同時に見ることができる反面，動作種毎の特徴が部分的に隠れてしまい認識が困難になったためと考える．しかし，$HMM_{CDA}$ 法では 2 動作ごとに認識空間を生成することで，その 2 動作の認識に適した認識空間を生成でき，認識率が上昇したと考える．

## 4 おわりに

本稿では，各動作の認識が容易になる認識空間を生成する身体動作認識手法（$HMM_{CDA}$ 法）を提案した．$HMM_{CDA}$ 法では与えられた時系列データを 2 動作ずつ選択して正準判別分析を行うことで 2 動作ごとに認識に適した認識空間を生成し，動作認識を行う．提案手法の有効性を確認するために，空手の「突き」動作を題材にした身体動作認識実験を行った．その結果，時系列データを直接認識する手法や，他の多変量解析手法である主成分分析を用いて認識空間を生成する手法よりも，優れた認識結果を示し提案手法の有効性を示した．

## 参考文献

[1] 稲邑 哲也，他：” 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，他：” 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，vol.131，No.3，pp.655-663，2011.

[3] 加藤 拓也，他：” 関節軌道の相関を考慮した身体動作認識”，情報科学技術フォーラム，pp.H-11，2012.



Copyright ©2014 Information Processing Society of Japan.
All Rights Reserved.