

逐次FLDAに基づく尤度判別空間を用いた身体動作認識

加藤 拓也^{1,a)} 加藤 昇平^{1,b)}

概要：近年身体動作の認識に関する研究が盛んであり、隠れマルコフモデル (HMM) による認識手法は高い認識率を示す。しかし既存研究では複数の身体情報を独立に扱い認識しているが、人間の身体動作ではそれらは相関を持つ。そこで本研究では、身体情報の時系列データを正準判別分析による動作認識空間を用いることで身体情報間の相関を考慮した時系列データに射影し認識を行う。また、既存研究では HMM による認識で算出される尤度を単純に比較して認識結果を決定しているが、尤度に対して判別分析を用いることで、その HMM の学習に用いた動作であったかどうかをより正確に判定できるのではないかと考える。そこで本研究ではフィッシャーの線形判別分析 (FLDA) を逐次的に繰り返し行う逐次 FLDA によって尤度判別空間を生成し、尤度の判定を行う。提案手法の有効性を確認するために 2 種類の動作認識実験を行い、比較手法との認識率を比較したところ、各実験において提案手法の有効性が示された。

1. はじめに

近年、Microsoft の Kinect や任天堂の Wii といった人間の身体動作を入力とするインターフェースの普及が目覚ましい。これらの普及に伴い、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、ユーザの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の一つに稲邑ら [1] による隠れマルコフモデル (HMM) を用いた手法が存在する。この認識手法では、HMM を用いて動作の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。このため身体情報の相関を考慮して動作を認識することは有効であると考えられる。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動作認識空間を生成する。本稿では、動作の観測データすなわち、関節軌道や身体部位の軌跡などの多次元時系列データを身体情報系列と呼ぶ。

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。そこで我々は、学習する身体情報系列から CDA を用いて動作認識空間を生成する手法 (HMM^{CDA} 法) を提案した [5]。本研究ではこの動作認識空間内に射影した身体情報系列を用いて HMM を学習し、動作を認識する。

HMM を用いた既存の身体動作認識手法では、算出される尤度を単純に比較することで認識結果を決定している。しかし、学習段階で算出された尤度を用いて判別分析を行うことによって、HMM を学習した動作か否かをより正確に判別できると考える。そこで本稿では、尤度に対して判別分析を行うことで尤度判別空間を生成し、尤度判別空間を用いた動作認識手法「 HMM_{LDsp}^{CDA} 法」を提案する。本稿ではここでの判別分析として、フィッシャーの線形判別分析 (FLDA) を採用する。FLDA は 2 クラスの判別が容易になるように多次元のデータを一次元に射影する。本稿では FLDA を逐次的に繰り返すことで多次元のデータを多次元に射影できるように拡張した「逐次 FLDA 法」を提案する。逐次 FLDA を用いて生成した尤度判別空間によって、HMM で算出された尤度から認識結果を決定する。

2. 身体動作認識システム

図 1 に HMM_{LDsp}^{CDA} 法の概要を示す。 HMM_{LDsp}^{CDA} 法は、「動作認識空間生成部」「学習部」「認識部」「尤度判別空間生成部」「評価部」から構成されている。

HMM_{LDsp}^{CDA} 法は、観測された身体情報系列から特定の動作を認識する。身体動作においていくつかの身体情報は相関関係を持つため、身体情報系列を相関が考慮された系列に変換する必要がある。そのため、学習動作の身体情報系列から CDA を用いて動作認識空間を生成し、動作認識

¹ 名古屋工業大学

Nagoya Institute of Technology, Dept. of Computer Science and Engineering, Graduate School of Engineering, Gokiso-cho, Showa-ku, Nagoya-si 466-8555, Japan

^{a)} tkykato@katolab.nitech.ac.jp

^{b)} shohey@katolab.nitech.ac.jp




図1 HMM^{CDA}_{LDsp} 法の概要

空間内に射影した身体情報系列を HMM を用いて学習し動作モデルを作成する。

観測された未知の動作に対して動作モデルの HMM で算出された尤度に対して、逐次 FLDA を行い生成した尤度判別空間を用いて各動作モデルに対する評価値を求め、認識結果を決定する。

2.1 動作認識空間生成部

図2に動作認識空間生成部の流れを示す。動作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動作認識空間の基底ベクトルを求める。

E 次元の変数からなる K 種類の動作 ($motion_1, motion_2, \dots, motion_K$) の学習データが各 N_k 個ずつ ($1 \leq k \leq K$) と与えられ、 $motion_k$ の n 個目の学習データが時間長 T_{k_n} の時系列データとして与えられる。図2～図6中では簡単のため、 $K=3$ とした。

学習動作である $motion_{k_1}, motion_{k_2}$ を任意に選択し ($1 \leq k_1 \leq K, 1 \leq k_2 \leq K$)、CDA を施すことで動作認識空間 $MRsp_{k_1 k_2}$ を生成する。本研究では、動作認識空間生成時においては時間情報を無視して、 $motion_k$ が $\sum_{n=1}^{N_k} T_{k_n}$ 個のデータ点であるとみなして CDA を実行し、基底ベクトルを求める。

この動作認識空間の生成を $_K C_2$ 回行い、2種類の動作を選択する全ての組合せ数の動作認識空間を生成する。

2.1.1 正準判別分析 (CDA)

正準判別分析は多変量解析手法の一つで、多変量の変数から成るデータの変数に対して重みをつけて合成し総合指標となる変数を生成する手法である [6]。CDA は、多変量解析の中でも判別分析の一つである。判別分析は事前に暮らすラベル付きのデータを分析することにより、未知データがどのクラスに分類されるかを判別する関数 (判別関数)




図2 動作認識空間生成部の流れ




図3 学習部の流れ

を得るための重みとなる固有ベクトルを求める。CDA では、各クラス内の平方和を小さく、かつ全クラスでの平方和が大きくなるように固有ベクトルを決定する。

2.2 学習部

図3に学習部の流れを示す。学習部では、認識対象となる各動作の学習データから、各動作に対する動作モデルをそれぞれ作成する。 HMM^{CDA}_{LDsp} 法では動作モデルを作成する事前に、動作認識空間生成部で生成した動作認識空間内へ動作データを射影する。

$motion_{k_1}$ の動作モデルを作成する流れを記す。まず $motion_{k_1}$ を、 $motion_{k_1}$ 自身を用いて生成した動作認識空間 $MRsp_{k_1 k_2}$ へ射影する。射影する際には、動作認識空間生成部と同様に時間情報を一時的に無視する。射影後のデータに対して、射影前の時間情報を再び付与することで、射影後の時系列データを生成する。そして、射影後の時系列データ $motion_{k_1 k_2}^{k_1 k_2}$ から HMM による学習を行い動作モデル $\Lambda_{k_1 k_2}^{k_1 k_2}$ を作成する。HMM による学習の際には Baum-Welch アルゴリズム [7] を使用した。

この $motion_{k_1}$ の動作モデルの作成を、 $motion_{k_1}$ を用いて生成した $K-1$ 個の動作認識空間において実行する。

2.2.1 隠れマルコフモデル (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




図 4 認識部の流れ

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 認識部

図 4 に認識部の流れを示す。認識部では、観測データ $motion_x$ 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観測データの尤度 $P(motion_x|\Lambda)$ をそれぞれ計算する。

認識部において尤度を計算する場合、まず観測データ $motion_x$ を動作認識空間生成部で生成した各動作認識空間へと射影する。ここでは観測データ $motion_x$ を動作認識空間 $MRsp_{k_1 k_2}$ へ射影した時の認識部の流れを説明する。観測データ $motion_x$ を動作認識空間 $MRsp_{k_1 k_2}$ へ射影し、時系列データ $motion_x^{k_1 k_2}$ へと変換する。時系列データ $motion_x^{k_1 k_2}$ と動作モデル $\Lambda_{k_1}^{k_1 k_2}$ から HMM による認識を行うことにより、尤度 $P(motion_x^{k_1 k_2}|\Lambda_{k_1}^{k_1 k_2})$ を算出する。HMM による認識の際には Viterbi アルゴリズム [8] を使用した。しかし、ここで算出される尤度 $P(motion_x^{k_1 k_2}|\Lambda_{k_1}^{k_1 k_2})$ 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 $L(motion_x^{k_1 k_2}|\Lambda_{k_1}^{k_1 k_2})$ を使用する。なお、これ以降では対数尤度 $L(motion_x^{k_1 k_2}|\Lambda_{k_1}^{k_1 k_2})$ を $L_{k_1}^{k_1 k_2}(x)$ と表記する。各動作モデルに対して対数尤度を算出すると、 $motion_k$ から作成された動作モデルと比較して算出される尤度は $K-1$ 個求まる。これは、 $motion_k$ を用いて生成された動作認識空間の数と同じである。

2.4 尤度判別空間生成部

図 5 に尤度判別空間生成部の流れを示す。尤度判別空間生成部では、認識部で算出される対数尤度がどの動作を示すものを判別する空間の基底ベクトルを求める。尤度判別空間の生成には動作認識空間生成部と学習部で使った学習データを、認識部によって認識し算出された対数尤度を使用する。

N_{k_1} 個の学習データ $motion_{k_1}$ を動作認識空間 $MRsp_{k_1 k_2}$ へ射影した後の時系列データ $motion_{k_1}^{k_1 k_2}$ と、同様に射影した N_{k_2} 個の時系列データ $motion_{k_2}^{k_1 k_2}$ について考える。

動作認識空間 $MRsp_{k_1 k_2}$ に射影した時系列データによって学習された動作モデル $\Lambda_{k_1}^{k_1 k_2}$ と動作モデル $\Lambda_{k_2}^{k_1 k_2}$ を用意する。時系列データ $motion_{k_1}^{k_1 k_2}$ と $motion_{k_2}^{k_1 k_2}$ を動作モデル $\Lambda_{k_1}^{k_1 k_2}$ によってそれぞれ認識して算出された N_{k_1} 個の対数尤度 $L_{k_1}^{k_1 k_2}(k_1)$ と N_{k_2} 個の対数尤度 $L_{k_2}^{k_1 k_2}(k_2)$ を使用して、尤度判別空間 $LDsp_{k_1 or k_2}^{k_1 k_2}$ を生成する。尤度判別空間の生成には逐次 FLDA を使用した。逐次 FLDA は、FLDA を逐次的に繰り返し行い多次元のデータを多次元に射影できるように拡張したものであり、詳細は 3 章で述べる。

同様に、対数尤度 $L_{k_2}^{k_1 k_2}(k_2)$ と $L_{k_1}^{k_1 k_2}(k_1)$ を使用して、尤度判別空間 $LDsp_{k_2 or k_1}^{k_1 k_2}$ を生成する。

このように 1 つの動作認識空間内に対して 2 つの尤度判別空間を生成し、全体では計 $2 \times_K C_2$ 個の尤度判別空間を生成する。

2.5 評価部

図 6 に評価部の流れを示す。評価部では、尤度判別空間生成部で生成された尤度判別空間上に、認識部で算出された対数尤度を射影することによって、観測データ $motion_x$ が学習済みのどの動作を表していたかを決定する。

認識部で観測データ $motion_x$ を動作認識空間 $MRsp_{k_1 k_2}$ へ射影し、動作モデル $\Lambda_{k_1}^{k_1 k_2}$ から HMM による認識を行った時を流れを説明する。この時算出された対数尤度 $L_{k_1}^{k_1 k_2}(x)$ を、尤度判別空間生成部で生成した尤度判別空間 $LDsp_{k_1 or k_2}^{k_1 k_2}$ へ射影することで、逐次 FLDA による評価を行い、評価値 $eval_{k_1}^{k_1 k_2}$ を求める。ここで求めた $eval_{k_1}^{k_1 k_2}$ は、観測データ $motion_x$ が動作認識空間 $MRsp_{k_1 k_2}$ 内において、学習動作 $motion_{k_1}$ とどの程度マッチングしたかを示す指標である。逐次 FLDA による評価の詳細は 3.3 節で述べる。

上記の流れで観測データ $motion_x$ を全ての動作認識空間の各動作モデルで認識し得られた対数尤度から、それぞれの尤度判別空間で逐次 FLDA により評価値を求める。求めた評価値を学習動作ごとに和を算出し、式 (1) のように $eval_{k_1}$ を求める。

$$eval_{k_1} = \sum_{k_2 \in K, k_2 \neq k_1} eval_{k_1}^{k_1 k_2}. \quad (1)$$

この $eval_{k_1}$ を全ての学習動作に対して求めて比較し、最も評価値が高かった学習動作を認識結果とする。

3. 逐次 FLDA

逐次 FLDA は多次元のデータを 1 次元へ射影する FLDA を、逐次的に繰り返し多次元のデータを多次元に射影できるように拡張したものである。逐次 FLDA における基底ベクトルの生成方法を 3.2 節で述べる。また、本稿では未知のデータが得られた場合に、どのクラスに分類されるかを判別するために、逐次 FLDA を用いた判別評価を行うため、評価方法を 3.3 節で述べる。

3.1 フィッシャーの線形判別分析 (FLDA)

フィッシャーの線形判別分析は CDA 同様、多変量解析




図5 尤度判別空間生成部の流れ




図6 評価部の流れ

手法の一つで、多種類の変数から成るデータの変数に対して重みをつけて合成し総合指標となる変数を生成する手法である [6]。FLDA は事前にクラスラベル付きのデータを分析することにより、未知データがどのクラスに分類されるかを判別する関数（判別関数）を得るための手法の一つであり、多次元のデータを 1 次元へ射影するための重みベクトルを求める。FLDA では、射影された各クラスの平均値間の分離度を大きくすると同時に、各クラス内では小さな分散を与える関数を最大化する。

3.2 基底ベクトルの生成

P 次元の変数から成るデータが正例 ($class_A$) と負例 ($class_{\bar{A}}$) の 2 クラスに分類できるとき以下の流れで基底ベクトルを求める。

図 7 に基底ベクトル生成の流れを示す。まず、 $class_A$ と $class_{\bar{A}}$ の全てのデータに対して「未分割」のラベルを付ける。次にラベルが未分割となっているデータを使用して FLDA を行うことで 1 本目 ($p = 1$) の基底ベクトルを生成する。この 1 本目の基底ベクトルへ未分割ラベルのデータを射影し、 $class_A$ と $class_{\bar{A}}$ が射影された領域の重なりを確認する (図 8)。各クラスのデータの中で重なっている領域の外側に射影されたデータを、この基底ベクトル上で分割できたデータとしてラベルを「既分割候補」に更新す




図7 基底ベクトル生成 (逐次 FLDA)

る。このとき、 $class_A$ のデータのうち、既分割候補のラベルが付いたデータ数を $N_A^{div}(1)$ とする。 $N_A^{div}(p)$ は判別評価時に使用する。

次に、クラスごとに未分割データの数を数え、未分割データの数が 2 以上ならば、既分割候補のラベルを「既分割」に更新する。未分割データの数が 1 以下の際には、既分割候補のラベルを未分割に戻す。この時点でラベルが未分割となっているデータを、生成されている基底ベクトルに垂直な平面に射影する。射影したことで次元が削減され $P - 1$ 次元となったデータを用いて再び FLDA を行う。こ




図8 ラベル更新の例

の操作を、基底ベクトルの数が $P-1$ 本になるまで繰り返す。なお FLDA を行う際に、データの分散で除算を行うため、未分割ラベルのデータが 1 以下になると計算不可能になるため、未分割ラベルのデータが 1 以下にならないように既分割候補ラベルの時点で確認を行っている。

FLDA を $P-1$ 回行った時点で、その時点で生成されている基底ベクトルに垂直なベクトルが自動的に定まるため、このベクトルを P 本目の基底ベクトルとして、 $class_A$ の未分割ラベルデータの内この基底ベクトル上で分割できたデータの数を数える。

3.3 判別評価

未知データ ($data_{new}$) が得られた際に、そのデータが正例 ($class_A$) か負例 ($class_{\bar{A}}$) のどちらに属するのかを判別評価し、どの程度の正例らしさであるか判別評価値を与える。

まず、各基底ベクトルに対して判別重みを付与する。基底ベクトル $FLDA_p$ ($1 \leq p \leq P$) の判別重み $FLDA_p^w$ を式 (2) で定義する。

$$FLDA_p^w = \frac{N_A^{div}(p)}{N_A}. \quad (2)$$

ここで N_A は基底ベクトルを生成するときに使用した $class_A$ のデータ数、 $N_A^{div}(p)$ は p 本目の基底ベクトルで既分割候補のラベル付けがされたデータの数である。

図 9 に $data_{new}$ が得られた時の判別評価値を与える流れを示す。 $data_{new}$ を 1 本目の基底ベクトル上へ射影する。ここで、この基底ベクトルの生成に使用した学習データも同基底ベクトル上へ射影し、 $class_c$ ($c = A, \bar{A}$) が射影された領域 $Area_c$ の重なりと、 $data_{new}$ の射影された位置を確認する (図 10)。 $data_{new}$ の射影位置が、各クラスの領域内かつ領域が重なっていない場所ならば判別評価値を与える (図 10 の (a))。 $data_{new}$ の射影位置が、領域が重なっている場所 (図 10 の (b))、もしくはどちらのクラスの領域にも属さない (図 10 の (c)) 場合は、次の基底ベクトルでの判定を行う。この判定を、 $P-1$ 本目の基底ベクトルまで繰り返す。 P 本目の基底ベクトルは、 $P-1$ 本の基底ベクトルを求めることで一意に決定するため、 P 本目の基底ベクトルでの判定は行わない。この判定で与える判別評




図9 判別評価方法 (逐次 FLDA)




図10 射影位置判定

価値 $eval$ は式 3 で定義する。

$$eval = \begin{cases} FLDA_p^w. & (class_A \text{ に判別された場合}) \\ 0. & (class_{\bar{A}} \text{ に判別された場合}) \end{cases} \quad (3)$$

$P-1$ 本目の基底ベクトルまでに判定出来なかった場合には、1 本目の基底ベクトル上でのマハラノビス距離によって判定を行う。1 本目の基底ベクトル上に射影した $data_{new}$ と $class_c$ とのマハラノビス距離 $distance_1(c)$ をそれぞれ求める。

$$distance_1(c) = \sqrt{\frac{(data'_{new} - \mu_c)^2}{\sigma_c^2}}. \quad (4)$$

$data'_{new}$ は $data_{new}$ の 1 本目の基底ベクトル上への射影した点、 μ_c と σ_c^2 はそれぞれ 1 本目の基底ベクトル生成に用いた各クラスのデータの平均と分散である。このマハラノビス距離 $distance_1(c)$ を比較し判別評価値 $eval$ を式 5 で定義する。

$$eval = \begin{cases} FLDA_p^w. & (distance_1(A) < distance_1(\bar{A})) \\ 0. & (distance_1(A) > distance_1(\bar{A})) \end{cases} \quad (5)$$

4. 身体動作認識実験

4.1 実験設定

HMM_{LDsp}^{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。身体動作認識実験は、空手における突きの動作の認識実験と文字を書く動作の認識実験の 2 種類行った。

突き動作認識実験で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




図 11 「突き」の動作（中段）




図 12 文字手書き動作の環境




図 13 文字手書き動作（れ）

の突きの動作 ($K = 3$) を認識した。図 11 は中段を突いた様子である。また、全学習データの平均時系列長は約 13.2 であった。

文字手書き動作認識実験で対象とする動作は、図 12 に示すように被験者の胸の前方に床と水平なキャンパスを想定して、そのキャンパス上に大きく文字を書く時の動作を行った。対象とする文字は、形が似た「ね」「れ」「わ」の 3 種類の文字を書く動作を認識した。図 13 は「れ」を手書きした様子である。また、全学習データの平均時系列長は約 28.6 であった。

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 ($E = 3$)。また、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

表 1 直接法での認識

		認識結果			認識率
		上段	中段	下段	
動作	上段	264 回	21 回	15 回	88.0%
	中段	113 回	164 回	23 回	54.7%
	下段	56 回	10 回	234 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	
動作	上段	240 回	50 回	10 回	80.0%
	中段	33 回	219 回	48 回	73.0%
	下段	7 回	68 回	225 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	
動作	上段	275 回	12 回	13 回	91.7%
	中段	14 回	253 回	33 回	84.3%
	下段	9 回	16 回	275 回	91.7%
					89.2%

表 4 HMM_{LDsp}^{CDA} 法での認識

		認識結果			認識率
		上段	中段	下段	
動作	上段	265 回	25 回	10 回	88.3%
	中段	10 回	274 回	16 回	91.3%
	下段	1 回	19 回	280 回	93.3%
					91.8%

て leave-one-out 交差検定を行った。各被験者に対して 29 データを学習用データとし ($N_k = 29$)、残りの 1 データを観測データとして認識した。各動作の観測データを、直接法、 HMM^{PCA} 法、 HMM^{CDA} 法、 HMM_{LDsp}^{CDA} 法を用いて認識し、認識率を比較した。

4.2 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 [9]。また、尤度判別空間を使用しない手法 (HMM^{CDA} 法) を用意した [5]。いずれの手法も、HMM での認識で算出された尤度を正規化して比較することで、認識結果の決定を行う。

4.3 実験結果

4.3.1 突き動作認識実験

空手における上段突き、中段突き、下段突きの動作の認識実験結果を表 (1) ~ 表 (4) に示す。

4.3.2 文字手書き動作認識実験

3 種類のひらがな（「ね」「れ」「わ」）を空中に手書きする動作の認識実験結果を表 (5) ~ 表 (8) に示す。

表 5 直接法での認識

		認識結果			認識率
		ね	れ	わ	
動作	ね	205 回	52 回	43 回	68.8%
	れ	126 回	136 回	38 回	45.3%
	わ	122 回	14 回	164 回	54.7%
					56.1%

表 6 HMM^{PCA} 法での認識

		認識結果			認識率
		ね	れ	わ	
動作	ね	218 回	41 回	41 回	72.7%
	れ	57 回	192 回	51 回	64.0%
	わ	60 回	31 回	209 回	69.7%
					68.8%

表 7 HMM^{CDA} 法での認識

		認識結果			認識率
		ね	れ	わ	
動作	ね	265 回	8 回	27 回	88.3%
	れ	79 回	202 回	19 回	67.3%
	わ	87 回	32 回	181 回	60.3%
					72.0%

表 8 HMM_{LDsp}^{CDA} 法での認識

		認識結果			認識率
		ね	れ	わ	
動作	ね	262 回	19 回	19 回	87.3%
	れ	15 回	241 回	44 回	80.3%
	わ	13 回	63 回	224 回	74.7%
					80.8%

4.3.3 考察

各動作認識実験における HMM_{LDsp}^{CDA} 法と 3 つの比較手法の総合認識率を比較すると HMM_{LDsp}^{CDA} 法が優れていることが分かる。また、突き動作認識実験における 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多く見られる。これは、 HMM^{PCA} 法では動作認識空間を生成するときに主成分分析を用いたことが原因と考えられる。主成分分析では全ての動作データの分散を最大化するように固有ベクトルを生成するため、全動作を同時に見ることが出来る動作認識空間を生成した反面、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動作認識空間を生成でき、認識率が上昇したと考える。また、 HMM_{LDsp}^{CDA} 法と HMM^{CDA} 法の認識結果を比較すると、逐次 FLDA による尤度判別空間の有効性も確認できる。単純に尤度の大小関係による比較ではなく、動作を動作モデルによって認識したときに算出される尤度の特徴によって認識結果を適切に判別できたと考えられる。

また、文字手書き動作の対象とした文字は「ね」「れ」「わ」であり、文字の書き始めから書き終わりまでの約 $\frac{2}{3}$ が同じ動作である。特に「ね」は他の 2 文字の形を含んで

いるため、「ね」の動作モデルで他の 2 文字を認識した際にも高い尤度を示してしまい直接法では表 (5) の結果になったと考えられる。しかし、提案手法では適切な動作認識空間と尤度判別空間を生成できたことによって、認識が容易になり高い認識率を示した。

5. おわりに

本稿では、身体動作認識手法として HMM_{LDsp}^{CDA} 法を提案した。 HMM_{LDsp}^{CDA} 法では、身体動作の認識において複数の身体情報の相関関係を考慮するために多変量解析を用いて、身体情報の時系列データを同時に考慮できる動作認識空間を生成した。使用する多変量解析手法としてクラス判別に適した正準判別分析を用いることで、動作の判別が容易になる動作認識空間を生成した。また、従来の動作認識手法で多く用いられてきた HMM による尤度を単純に比較する手法を行わずに、尤度を変数として判別空間を生成することで認識率の向上を目指した。尤度判別空間の生成に使用する判別分析として逐次 FLDA を提案し、判別空間の基底となるベクトルを逐次的に求めた。

HMM_{LDsp}^{CDA} 法の有効性を確認するために、空手における突きの動作と、ひらがなの手書き動作の動作認識実験をそれぞれ行った。その結果、各動作認識実験において HMM_{LDsp}^{CDA} 法の高い認識性能が確認され、動作認識空間生成の有効性と尤度判別空間生成の有効性を確認した。

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 (オンライン), DOI: 10.3902/jnns.12.74 (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 = The transactions of the Institute of Electrical Engineers of Japan. C, A publication of Electronics, Information and System Society, Vol. 131, No. 3, pp. 655-663 (オンライン), DOI: 10.1541/ieejieiss.131.655 (2011).
- [3] Hirose, Y. and Kato, S.: Intuitive Humanoid Robot Operationg System Based on Recognition and Variation of Human Body Motion, *KES-IIMSS 2012*, pp. 87-92 (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] 加藤拓也, 加藤昇平: 判別分析に基づく認識空間を用いた身体動作認識, 情報処理学会第 76 回全国大会 (2014).
- [6] C.M. ビショップ, 元田 浩, 栗田多喜夫, 樋口知之, 松本裕治, 村田 昇: パターン認識と機械学習, シュプリンガー・ジャパン株式会社 (2007).
- [7] 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).
- [8] Forney, G. D.: The Viterbi algorithm, *Proc. IEEE* 61, Vol. 3, pp. 268-278 (1973).
- [9] 加藤拓也, 加藤昇平: 関節軌道の相関を相関を考慮した身体動作認識, 第 11 回情報科学技術フォーラム (2012).