

特集 「時系列データの認識—HMMを越えて」

# 動作認識のための状態遷移モデル

—HMMの高度化と非HMM手法の成長—

## State Transition Models for Motion Recognition —Augmentation of HMMs and Progress in Non-HMM Methods—

大和 淳司  
Junji Yamato

日本電信電話(株)第三部門  
Nippon Telegraph and Telephone Corporation, Department 3.  
yamato@computer.org, <http://alum.mit.edu/www/yamato>

上田 修功  
Naonori Ueda

日本電信電話(株)NTTコミュニケーション科学基礎研究所  
NTT Communication Science Laboratories, Nippon Telegraph and Telephone Corporation.  
ueda@cslab.kecl.ntt.co.jp, <http://www.kecl.ntt.co.jp/icl/as/members/ueda/index-j.html>

和田 俊和  
Toshikazu Wada

京都大学大学院情報学研究科知能情報学専攻  
Department of Intelligence Science and Technology, Graduate School of Informatics, Kyoto University.  
twada@i.kyoto-u.ac.jp, <http://vision.kuee.kyoto-u.ac.jp/cgi-bin/escape/~twada/index.html>

**Keywords:** motion recognition, hidden Markov model, generation models, acceptance models, support vector machine, state transition models.

### 1. はじめに

時系列データの認識に広く用いられている隠れマルコフモデル (Hidden Markov Model: HMM) は音声認識で大きな成功をおさめ、動画像からの動作認識においても人物ジェスチャの認識を中心に一般的な手法の一つとなっている。

動画像を用いた動作認識を、音声認識の問題と比較してみると、以下のような特殊性があるため、単純にHMMを適用するだけで認識ができる動作クラスは限定されたものになる。

- 手話などを除けば、音声認識における言語的知識のように上位の構造に関する知識が整理されておらず、これを用いることが困難である。
- 無音部やホルマント移動などセグメンテーションに利用可能な情報が少なく、連続動作を認識することが困難である。
- 動画像は時系列としての側面だけではなく、空間的な広がりももつため、以下のような問題が生じる。
  - 人間のような多関節物体の場合には、左右の手や足、顔、胴体などの各部分がある程度独立に動作でき、同じ動作を行ったつもりでも、各部分の動きに時間的な差が生じてしまうため、各時刻の画像には大きなずれが生じる。
  - 3次元から2次元への変換を経て画像が撮影されるため、カメラと対象の位置関係が変化すれば、同

じ動作を行っても、全く異なる動画像が観測される。

- 人間の指さし動作で表現される方位など、定量的な情報を動作によって表現する際には、同じクラスに属する動作パターンの間にも大きな変動が現れてしまう。

これらの問題を度外視することは、「カメラに対する動作対象の位置姿勢が決まっており」、「動作の始まりと終りが何らかの方法で指定され」、「複数の部位の動作のタイミングにずれがない」などが保証された環境下で、「方位などの定量的情報を含まない」動作の認識を行うということになる。つまり、上述の問題が解決できない限り、とうてい現実的な場面での動作認識は行えないということである。

HMMによって上記すべての問題を解決することは、明らかに筋違いの話であるが、これらの問題をなんらかの手法によって解決する際に、HMMを用いることが妥当か否かを検討することはむだではないはずである。この観点から、HMMを吟味すると同時に、近年のHMM研究の本質的な部分での進展を概観することによって、今後の研究を展望することが本稿の趣旨である。

#### 1.1 HMMとは

本題に入る前に、まずHMMとは何であるのかについて以下に整理しておく。

本来、HMMは確率的に状態遷移を起こし、各状態において確率的に記号を出力する、一種の確率オートマトンである。状態間の遷移確率やある状態においてある記

号が出力される確率は、事前に学習される。音声認識や動作認識では特徴ベクトルの時系列が出力記号列に相当し、状態遷移は明示的には観測されない。このように、状態遷移が見えないことが、「隠れ」マルコフモデルと呼ばれる理由である。換言すると、通常のオートマトンが、系列データの「受理モデル」であるのに対して、HMMは「生成モデル」とみなすことができる。

HMMが生成モデルである以上、出力系列に対応する状態遷移を推定することが必要になる。このための計算は、有限長の出力記号列を与え、それを出力する状態遷移と記号出力の系列のうち、最も尤度が高いものを求めることであり、結果として得られる状態遷移から、系列の識別が行われる。

HMMが適用できる対象は、状態遷移が直前の状態のみによって決まるマルコフ性を有する場合に限定される。このため、過去の状態遷移の履歴によって次の状態への遷移確率が決まる場合には、(厳密に言えば)適用することはできない。ただし、ある状態遷移モデルを構成する状態の部分集合を新たな状態と定義して、別の状態遷移モデルを構成すれば、ある程度この制約を緩和することができる。

HMMを音声や動作の認識に用いる場合、記号列ではなく時間的に変化する特徴ベクトルを扱わなければならない。この場合、ベクトル量子化によって得られる代表ベクトルを出力記号とみなす「離散HMM」、各状態に特徴ベクトルの確率密度分布をもたせておく「連続HMM」、これらの中間の特性をもつ「半連続HMM」などが用いられる。

## 2. 画像理解におけるHMMの利用

### 2.1 静止画像の認識

HMMは基本的にパターン系列の学習・認識の枠組みを提供する。しかし、学習・認識しようとするパターン系列が時系列かどうかは問題ではない。なんらかの方法で、あるパターン系列を得ることができれば、HMMで学習・認識を行うことは可能である。実際、画像理解において最初にHMMが適用されたのは、以下に述べる静止画像の認識問題である。

静止画像の認識にHMMを適用した例としては、2次




図1 HMMを用いた顔画像認識

元平面図形の認識 [He 91] や手書き文字認識 [Chen 92]、顔画像の認識 [Samaria 93a, Samaria 93b] などがあげられる。例えば、顔画像の認識では、図1に示すように画像上でウィンドウを動かし、その領域内の画素値を特徴ベクトルをHMMの出力系列としている。これらは本質的に時系列パターンではないものにHMMを適用した例であるが、いずれもそれなりの性能が得られている。

### 2.2 動画からの動作認識

動作認識の問題に対して、最初にHMMを用いたのは大和 [Yamato 92] である。この大まかな流れを図2に示すが、基本的には動作画像の各フレームをベクトル量子化でシンボルに変換し、離散HMMで認識するというシンプルなものであった。

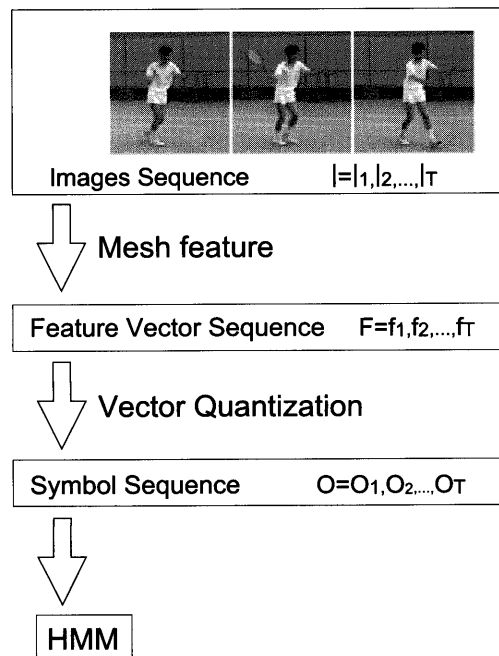


図2 HMMを用いた動作認識の処理フロー

その後、多くの研究グループが動作認識の問題に取り組み、主に連続HMMの枠組みの中でさまざまな拡張や改良が行われてきた。

### 2.3 人物動作認識のためのHMMの拡張、改良

Bobickは人間の動作を細かい順に、Movement, Activity, Actionの三つのレベルに分類した [Bobick 97a]。Movementは特に知識を必要とせずに認識が可能なプリミティブである。Activityは、Movementの系列であり、この系列の統計的な性質によって記述できるレベルとした。それに対してさらに大きなスケールであるActionは、外部との相互作用や因果関係などに関する知識がなければ正しく認識することができないレベルである。HMMが無理なく適用できる動作認識問題は、Activityのレベルであり、HMMの各状態をMovement

に対応させられるような画像特徴を用いたモデル化を行うのが筋の良いやり方ということになる。Action のレベルに HMM を適用することは、マルコフ性がないものに HMM を適用するという例であり、高い認識性能は期待できない。

Movement レベルでは、物体には慣性があり、ある動作クラスに属するパターンが引き起こす状態遷移には同じ状態に滞留する時間に偏りがあることから、状態遷移に加えて時間の経過も考慮した HMM [Wilson 95] が提案されている。また、動画像という大量のデータを扱うための高速化手法などが提案されている。

Activity レベルでは、指さし動作などの定量的な情報を含む動作や、パターンの変動を吸収するために、観測された動画像から状態遷移を推定すると同時に、指さしの方角や、パターンの組織的変動を表すパラメータを推定する PHMM [Wilson 98] が提案されている。

Action レベルに対しては、統計的な学習で得られる以外の情報を用いる必要がある。特定の Movement や Activity によってコンテキストに関する知識をシナリオとして記述して蓄えておきこれを参照する。下位の Movement や Activity の認識がある程度うまくいけば、このやり方で Action の認識が可能になるが、各階層での学習やチューニングは容易ではない。Bobick は Activity レベルの動作認識に対して、特徴空間中のトラジェクトリを状態遷移モデルで記述する手法を提案している [Bobick 97b]。HMM と比べると、プロトタイプ概念があるため、学習データが少数であってもプロトタイプに基づくモデルが構成できるのが利点である。

Action レベルの動作認識を目指した別のアプローチとして、高次のマルコフモデルを用いたものがあげられる。具体的には、Jordan らによる factorial HMM, Linked HMM などである。Brand らは、複数の状態系列を因果的なリンクの相互作用で結合した Coupled HMM (CHMM) [Brand 96, Brand 97] を複雑な動作の認識に適したものとして提案した。coupled HMM は、単一の HMM はもとより、複数の HMM を対称に結合した Linked HMM (LHMM) よりも識別性能が良い。これは、CHMM では時空間的な相互作用のある時系列パターンの記述ができるためであり、特に手足や顔などの動きに時間差が現れやすい人物動作の識別に向いている。太極拳の動作を例とした CHMM の実験では、HMM, LHMM と比較して高い認識性能が得られている。ただし、このアプローチで扱うことができているのは、上述のように、Action というよりも Activity レベルの動作認識に近いのが現状である。

### 3. HMM 自体の進展

近年の動向を見てみると、応用面だけでなく、HMM に関連する理論研究においても、いくつかの進展が見ら

れる。ここでは学習法の改良と、HMM を特徴抽出器として用いる研究の二つを簡単に紹介する。

#### 3.1 HMM の学習法の改良

HMM の学習における実用上の問題として、局所最適性の問題と少数サンプルの問題がある。前者の問題とは、HMM の学習が山登りの探索アルゴリズムゆえ、パラメータの初期値に依存して低品質の局所解に陥る問題である。後者の問題とは、パラメータ次元に比べ学習データが少数の場合汎化性能（未学習データに対する識別性能）が低下する問題である。

前者の問題に対し、HMM の状態と混合分布の併合分割を学習の途上で繰り返す学習法が提案され、ジェスチャ（手話データ）を用いてその有効性が示されている [富田 00]。なお、これは混合モデルのための局所最適性の一般解法（SMEM アルゴリズム）[Ueda 00] の HMM への応用である。HMM のパラメータ推定において、併合分割という考え方はすでに存在していた [鷹見 95] が、そこでは局所解からの脱出を図るものではなく、モデルの構造探索手法である。一方、[富田 00] の手法は、モデルの複雑さを固定してそのモデルのもつ能力を十分発揮させるための最良パラメータ推定法という点で [鷹見 95] と異なる。

また、後者の問題解決法として、入手が容易なクラスラベルなしデータをクラスラベルありデータに大量に混在させて汎化性能を向上させるための学習法が提案されている [Inoue 01]。以下これについて概説する。

クラスラベルありなし混在データを取り扱う HMM モデルを図 3 に示す。通常の HMM は各クラスごとにその帰属データのみを用いて学習するため、特徴空間は各クラスの HMM ごとに独立している。これに対し文献 [Inoue 01] では、図 3 に示すように、クラスラベルなしデータを学習に用いるために単一の特徴空間を全クラスの HMM に共有させている。したがって、通常の HMM における状態遷移パラメータ  $\{a_{ij}\}$ 、 $K$  個の正規分布のパラメータに加え、混合比のパラメータ  $\{c_{j,k}^y\}$  も学習する。直観的には、図 3 に示す HMM は HMM の混合モデルと見ることができる。

なお、この共有モデル構造は 3 連続音素モデルの音声認識システムで用いられる結合混合 HMM (tied mix-




図 3 クラスラベルありなし混在データのための HMM

ture HMMs) と本質的に同じである。しかしながら、[Inoue 01] では、ラベルありなし混在データを同時に学習する学習アルゴリズムの導出という点で異なる。詳細は、[Inoue 01] を参照されたい。

### 3.2 特徴抽出器としてのHMM

前述したように、HMMはクラスの生成モデル(確率分布)として用いられる。すなわち、クラス $\omega_i$ のクラスに帰属する学習データを用いてクラスのデータ生成モデルを確率分布として推定し、ベイズ識別則により新たなデータのクラス識別を行う。一般に、確率モデルに基づくパターン認識手法(以下、便宜上、確率モデルアプローチと呼ぶこととする)は、分布が正しく推定されれば最適な識別となるが、現実には十分な学習データがないという学習できないという問題がある。

一方、近年、サポートベクトルマシン(SVM)[Vapnik 95]に代表されるカーネル法がパターン識別器として注目されている。カーネル法は2クラス問題を対象に定式化される。多クラス問題については2クラス問題の組合せとして考える。今、学習データ集合を $\{(x_i, y_i) | i = 1, \dots, N\}$ とする。ただし、 $x_i$ は第*i*番目の特徴ベクトル、 $y_i$ はそのクラスラベル(-1か+1の二者択一)とする。このとき、カーネル法による入力 $x$ のクラス $y$ は

$$y = \text{sign} \left( \sum_{i=1}^N y_i \lambda_i K(x_i, x) \right) \quad (1)$$

で決定される。ここに、 $\lambda_i$ は係数パラメータ、 $K(\cdot)$ はカーネル関数とする。

つまり、入力 $x$ のクラスは学習データとのカーネル関数値と係数パラメータとを重みとして、各データのクラスラベルの重みつき平均としている。カーネル関数は、通常、 $x$ からより高次元のベクトル $\phi_x$ への写像： $x \rightarrow \phi_x$ を用いて

$$K(x, x_i) = \phi_x^T \phi_{x_i} \quad (2)$$

なる内積(一般的には2次形式)の形が一般的である。 $T$ は転置を表す。

カーネル法の場合、特徴次元数に比べて学習データ数が少ない場合でも良好な識別器が構成できるという点で確率モデルアプローチよりも優れている。しかしながら、カーネル法ではジェスチャデータのような系列長の異なる時系列データにそのまま適用できないという問題がある。このような背景のもとに提案されたのが、フィッシャーカーネルと呼ばれるカーネル設計法である[Jaakkola 00]。以下これについて簡単に説明する。

フィッシャーカーネルは、HMMとカーネル法の橋渡的な役割をする。つまり、系列長の異なるデータをHMMを介して確率分布 $p(x; \theta)$ として表現し、その確率分布からフィッシャースコアと呼ばれる $p$ 次元ベクトル：

$$U_x = \left( \frac{\partial \log p(x; \theta)}{\partial \theta_1}, \dots, \frac{\partial \log p(x; \theta)}{\partial \theta_p} \right)^T \quad (3)$$

を構成する。 $p$ はパラメータ $\theta$ の次元数である。このとき、フィッシャーカーネルは次式で定義される。

$$K(x, x_i) = U_x^T I^{-1} U_{x_i} \quad (4)$$

ここに、 $I$ はフィッシャー情報行列： $I = E_x[U_x U_x^T]$ を表す。 $E_x$ は $x$ の分布による期待値を表す。

上記、確率分布からフィッシャースコアへの変換は、直観的には、確率分布に基づいて、対数尤度関数の各パラメータ成分に関する偏微分値から成る特徴空間への写像である。つまり、HMMを識別器ではなく特徴抽出器として用いており、HMMの新たな取扱い方と言える。Jaakkolaらは、上記、HMMとカーネル法との組合せ手法が、HMMのみによる識別よりも識別性能が向上することをDNAの識別実験を用いて実証している[Jaakkola 00]。

## 4. HMMを用いない動作認識

時系列データの生成モデルではなく、受理モデルを考えるとという立場に立つと、字句解析に用いられるオートマトンのように、パターン系列をセグメンテーションしつつ分類することができるはずである。

和田ら[Wada 98]は、NFAとその状態遷移に応じて特徴抽出を行う「注目領域」を切り替える機構を組み合わせた動作認識手法を提案している(図4)。これは、例えばドアが閉じた部屋から出る際には、人はドアノブに触わり、次にドアが開き、...というように、動作段階に応じて必ず変化が起きる画像上の領域(注目領域)が存在することに着目した手法である。この手法では、注目領域内での画像の変化が起きると、次の状態に遷移すると同時に注目領域を切り替えるという動作を繰り返す

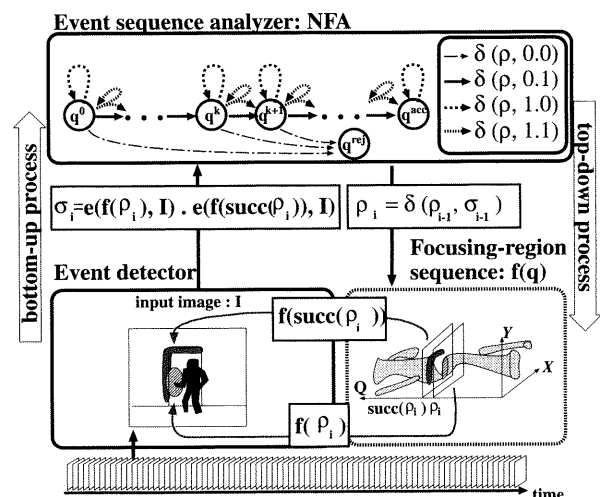


図4 選択的注視のメカニズム

て、最終状態に到達した際に認識結果が得られる。このような方法を、パターンの変動が大きい画像データに適用した場合、動作が不安定になりがちだが、この手法では入力によって遷移可能なすべての状態へ同時に遷移することによって、ロバストな認識を実現している。さらに、複数の状態への遷移を行う副次的効果として、複数の対象が動作をしている場面を撮影した場合でも、それぞれの動作を識別できるというメリットもある。この手法には多くの欠点があるが、重要な点は系列データの受理モデルによって動作の認識が行えることを示した点にある。

連続 DP マッチングも動作認識の分野ではしばしば用いられている [高橋 94]。これは、動作認識の問題では動作間に関連がないことが多く、状態を介したトップダウン処理を考えなければ、時間の伸縮によって入力データと標準パターンのマッチングを行うだけでよいと考えれば十分妥当な方式である。これも明らかに受理モデルである。

また、音声認識の分野で提案された時間遅れ神経回路網 (Time-Delay Neural Network: TDNN) は動作認識の分野でも用いられるようになってきている [Yang 98]。TDNN は短い区間の時間窓から入力された信号によってドライブされる層状の神経回路網によって時系列データを識別する手法であり、多段のパターンマッチングを行っていることと等価とみなせる。したがって、これも受理モデルに分類され、特別な時間的セグメンテーションを行わずに、系列データの解析が行える。

上述のように、HMM 以外の時系列データの認識モデルは、ほとんどが受理モデルであり、特別なものでない限り時間的なセグメンテーションは必要としない。このことは、セグメンテーションに利用可能な信号レベルの情報に乏しく、系列間に存在する制約に基づくトップダウン処理が行いにくい動作認識問題においては、特に重要な点である。しかし、これらの手法には明示的な状態をもたないものも含まれている。画像の空間的な解析を行うためには、動作段階に応じた何らかのトップダウン処理を埋め込むための柔軟性が要求され、この意味で動作段階に対応する状態をもたないモデルの場合、拡張性をもたせるための工夫が必要になるものと考えられる。

## 5. む す び

音声などの分野では、状態を介して音韻と言語を統一的に扱うことができ、かつ統計的な意味での最適性が保証できる生成モデルベースの研究が主体である。このため、HMM が自然と受け入れられたのではないかと思われる。これに対して、動作認識の問題は上位知識が利用できる場面がかなり制限されており、むしろ時間的、空間的なセグメンテーションや、動作パターンを特徴付ける動作部位の特定や検出など、動作の段階に応じた処理

手法が求められるため、必ずしも HMM が最適な枠組みとは思えない面もある。それにもかかわらず、HMM が利用され続ける背景には、音声認識における成功事例があることや、統計的理論の裏付けがあること、また、正しくセグメンテーションされた単純な動作パターンに対する認識精度が高いことがあると言える。

これに対して、受理モデルを用いた方法には、しっかりとした統計的裏付けが与えられたものがほとんどなく、また明示的な状態をもたないものもあるため、一般的な動作認識の手法としてはいまだに少数派である。しかし、本文中で述べたように、受理モデルにはさまざまな利点があり、今後の発展が期待できると言えよう。

HMM それ自体は、本文中で述べたようにさまざまな拡張が施され、古典的統計理論に基づく手法から、SVM に代表される近代的な識別理論の枠組みの中で捉え直されつつある。このことは、HMM の根幹にかかわる問題であり、もはや HMM とは呼べない代物へと変容しつつある。こういった点でも今後の進展が大いに期待できる。

上述のように、「HMM を越える」ための萌芽はすでに存在するが、HMM は理論面だけでなくツールとしても完成度が高く、当面は「使える」手法であり続けると思われる。ただし、動作認識の分野ではこういった HMM の特長が必ずしも生かしきれているとは言い難い。今後、動作認識の研究の中から、HMM を真の意味で越える手法が誕生することを期待したい。

## ◇ 参 考 文 献 ◇

- [Bobick 97a] Bobick, A.: Movement, Activity, and Action: The Role of Knowledge in the Perception of Motion, in *Proceedings of the Royal Society Workshop on Knowledge-based Vision in Man and Machine* (1997)
- [Bobick 97b] Bobick, A. and Wilson, A.: A State-based Approach to the Representation and Recognition of Gesture, *IEEE Transaction on Pattern Analysis and Machine Intelligence* (1997)
- [Brand 96] Brand, M.: Coupled Hidden Markov Models for Modeling Interacting Processes, Technical report, MIT Media Lab. (1996)
- [Brand 97] Brand, M.: Coupled Hidden Markov Models for complex action recognition, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (1997)
- [Chen 92] Chen, M., Kundu, A. and Zhou, J.: Off-Line Handwritten Word Recognition (HWR) using a Single Contextual Hidden Markov Model, in *Proc. CVPR'92*, pp. 669-672 (1992)
- [He 91] He, Y. and Kundu, A.: Planar Shape Classification using Hidden Markov Model, in *Proc. CVPR'91*, pp. 10-15 (1991)
- [Inoue 01] Inoue, M. and Ueda, N.: HMMs for both labeled and unlabeled time series data, in *Proceedings of Neural Networks for Signal Processing (NNSP2001)*, pp. 93-102 (2001)
- [Jaakkola 00] Jaakkola, T., Diekhans, M. and Haussler, D.: A discriminative framework for detecting remote protein homologies, *Journal of Computational Biology*, Vol. 7, No. 12, pp. 95-114 (2000)
- [Samaria 93a] Samaria, F.: Face Segmentation for Identification using Hidden Markov Models, in *Proceedings of 4th British*

*Machine Vision Conference* (1993)

- [Samaria 93b] Samaria, F. and Fallside, F.: Automated Face Identification using Hidden Markov Models, in *Proceedings of the International Conference on Advanced Mechatronics* (1993)
- [高橋 94] 高橋勝彦, 関進, 小島浩, 岡隆一: ジェスチャー動画のスポットニング認識, 信学論 D-II, (1994)
- [鷹見 95] 鷹見淳一: 状態分割融合法による効率的な隠れマルコフ網の自動生成, 信学論 (D-II), Vol. J78-DII, No. 1, pp. 10-18 (1995)
- [富田 00] 富田仁志, 上田修功: 隠れマルコフモデルの最良パラメータ推定, 信学技報, 第 NC99 巻, pp. 105-112 (2000)
- [Ueda 00] Ueda, N., Nakano, R., Ghahramani, Z. and Hinton, G. E.: SMEM Algorithm for Mixture Models, *Neural Computation*, Vol. 12, No. 9, pp. 2109-2128 (2000)
- [Vapnik 95] Vapnik, V.: *The Nature of Statistical Learning Theory*, Springer-Verlag (1995)
- [Wada 98] Wada, T. and Matsuyama, T.: Appearance Based Behavior Recognition by Event Driven Selective Attention, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (1998)
- [Wilson 95] Wilson, A. and Bobick, A.: Learning Visual Behavior for Gesture Analysis, in *Proceedings of the IEEE Symposium on Computer Vision* (1995)
- [Wilson 98] Wilson, A. and Bobick, A.: Nonlinear PHMMs for the Interpretation of Parameterized Gesture, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (1998)
- [Yamato 92] Yamato, J., Ohya, J. and Ishii, K.: Recognizing Human Action in Time-Sequential Images using Hidden Markov Models, in *Proc. CVPR'92*, pp. 379-387 (1992)
- [Yang 98] Yang, M. -H. and Ahuja, N.: Extraction and Classification of Visual Motion Patterns for Hand Gesture Recognition, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (1998)

2001年11月15日 受理

## 著者紹介



大和 淳司

1990年東京大学工学部精密機械工学科修士課程修了。同年よりNTTヒューマンインタフェース研究所視覚情報研究部にて動画像認識の研究などに従事。1996～98年MITAI labにてロボットビジョンの研究に従事。98年MIT電気工学及びコンピュータ科学科修士了。98年NTTコミュニケーション科学基礎研究所主任研究員。人間とロボットのコミュニケーション評価の研究などに従事。2001年よりNTT第三部門R&Dビジョン担当課長。IEEE, 電子情報通信学会各会員。博士(工学)。



上田 修功

1984年大阪大学工学部通信工学専攻修士課程了。同年NTT電気通信研究所入所。パターン認識, ニューラルネットワーク, 統計的学習理論の研究に従事。現在, NTTコミュニケーション科学基礎研究所知能情報研究部, 創発学習研究グループリーダー主幹研究員(特別研究員), 奈良先端科学技術大学院大学客員助教授。工学博士。1993～94年米国Purdue大学客員研究員。1992年日本神経回路学会研究奨励賞, 97年電気通信普及財団賞(テレコムシステム技術賞), 2000年電子情報通信学会論文賞各受賞, 電子情報通信学会, 日本神経回路学会, 日本統計学会, IEEE各会員。



和田 俊和 (正会員)

1990年東京工業大学大学院博士課程修了。同年岡山大学工学部助手。1997年京都大学大学院工学研究科助教授。工学博士。画像理解, パターン認識の研究に従事。1995年David Marr賞。97年情報処理学会山下記念研究賞。99年電子情報通信学会論文賞各受賞。