

動的システムに基づく時系列パターンの表現と認識

藤江 喬士[†], 川嶋 宏彰[†], 松山 隆司[†]

[†] 京都大学大学院情報学研究科知能情報学専攻

概要 ジェスチャーや音声といった動的に変化する事象の表現・認識手法としては、HMM やオートマトンなどの状態遷移による手法が提案され利用されている。しかし、これらの手法では状態の扱い方が離散的であるため、元の時系列パターンを持つダイナミクスを十分表現することができず、人間とインタラクションを行うシステムのように、入力に対する応答のタイミングを詳細にモデル化する場合には不向きである。そこで本報告では、動的システムに文脈空間を加えることによって拡張した新たな時系列パターンの表現・認識モデルを提案する。従来の動的システムは、パターン内の比較的短期的な状態しか表現することができないという問題があるが、本手法は繰り返しを持つような複雑なパターンを表現することを可能にする。本手法の有効性をシミュレーションを用いて評価を行った。

Dynamical System based Time-varying Pattern Representation and Recognition

Takashi FUJIE[†], Hiroaki KAWASHIMA[†],
and Takashi MATSUYAMA[†]

[†]Department of Intelligence Science and Technology,
Graduate School of Informatics, Kyoto Univ.

Abstract We propose a new time-varying pattern representation and recognition method based on a dynamical system. For dynamic event representation, such gestures and utterance, HMM and automaton are widely used. While these methods shows effectiveness for time-varying pattern classification, it is insufficient to apply for interactive systems, since they are basically event driven models. In this report, we introduce context space to the dynamical system and associate the space with state space during the learning phase. Since the state space is constrained by the associated space, the model represent complex time-varying patterns with intersections and loops in the sequence.

1 はじめに

ジェスチャーや音声などの動的に変化するような事象を表現・認識するために、従来より HMM やオートマトンなどの状態遷移に基づく手法が提案され利用されている。しかし、これらの手法は状態が離散的であり、さらに、入力される記号的なイベントによって駆動されるモデルである。そのため、入力系列をあらかじめどのようにイベントに対応させるかという問題があり、動的な事象の持つダイナミクスを十分表現できるモデルとはいえない。今後、家庭用ロボットのように人間に対してインタラクティブに働きかけるようなシステムを設計する上では、相手の動きや発話の持つコンテキストに即

して、自律的かつ自然なタイミングで反応することが望ましい。そのためには、動的な事象の時系列パターン情報をより詳細かつ自然に表現するモデルが必要となる。

そこで本報告では、動的に変化する事象を表現するモデルとして、動的システムを拡張したモデルを提案する。このモデルは、状態が連続量（実ベクトル）であり、状態空間の距離が

1. 特徴ベクトル間の類似性
2. 特徴ベクトル間の時間的関連性

を表現するという特徴を持つ。従来の HMM やオートマトンがイベント駆動であるのに対し、動的システムは時間的な変化の情報を状態空間におけるダイ

ナミクスによって詳細に表現する．さらに，次の時刻の入力を予測できるという意味で，特徴抽出レベルへのフィードバックによって，不完全な観測データに対応した安定な認識や，系列の時間的なセグメンテーションなどを実現できるなどの利点が考えられる．

動的システムにおける時系列パターンの表現は，与えられた特徴量のパターン系列をうまく生成できるように，システムのパラメータを学習することで行われる．しかし，従来の動的システムでは，与えられたパターン系列のみから状態空間を構成するため，系列内に繰り返しがあるような場合には，その繰り返しの1度目と2度目が同じ状態に対応付けられてしまうなど，複雑なパターンが表現できないといった問題がある．これは，本来動的システムが比較的短期的なダイナミクスを表現するモデルであるためである．従って，発話における単語やジェスチャーなど，始まりと終わりを持つような時系列パターンを表現するには，文脈情報を保持するためのモデルの拡張が必要となる．

このようなパターン系列を実現する方法としては，大きく分けて次の2つの方法が考えられる．

- 動的システムと離散的な状態モデルの混合モデルを用いる [1, 2]
- 動的システムの学習時に，特徴パターン系列以外の文脈情報を付加する [3]

1の方法は，単純なモデル（線形動的システム）と離散的な状態モデルを組み合わせ，複雑な時系列パターンをいくつかの単純なダイナミクスに分割して表現するモデルである．2の方法は，学習を行う際に学習させる特徴系列に加えて，その系列の進み具合やクラスといった付加的な情報を与えることによって，特徴系列のみでは学習できないような，重なりやループをもった系列を学習することが可能となる．本研究では最終的には離散的な状態遷移も連続的な状態空間をセグメンテーションすることによって求めることを考え，特に2の手法について検討を行った．

ここで問題となるのが，学習時に与えるどのような付加情報をどのようにして与えるのかである．本稿では，始まりと終わりを持つような時系列パターンを学習し，そのパターンが入力されたときには，現在，系列の全体のどの割合まで入力されたかとい

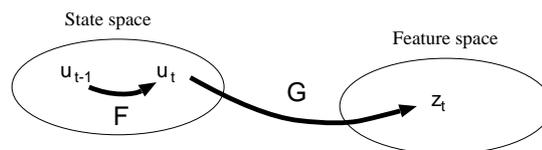


図 1: 動的システム

う進捗状況を認識する問題を考えるものとする．そこで，まず特徴空間とは別に文脈空間を導入し状態空間と関係付ける．そして，学習時に文脈空間において文脈情報を与えておくことによって状態空間を制約付け，特徴ベクトルの時間的・空間的な類似性を表現するような状態空間を学習することにより，長期的な文脈を持つ時系列パターン系列の表現・認識を実現する．

以下，2章において提案モデルの説明を行い，続く3章で最尤推定によるモデルの学習方法とEMアルゴリズムによる最適化手法について述べる．4章ではシミュレーションを用いて提案手法の検証・考察を行う．5章では，提案手法を多クラスの識別モデルに発展させる際にどのような拡張が必要であるかについて考察を行う．

2 動的モデルへの文脈情報の導入

2.1 動的システムによるモデル化

時系列パターンを表現するモデルとして離散時間線形動的システムを用いる [4]．このモデルは，以下のシステム方程式で表され，これを図を用いて表したものが図1である．

$$\mathbf{u}_t = F\mathbf{u}_{t-1} + \zeta_t \quad (1)$$

$$\mathbf{z}_t = G\mathbf{u}_t + \eta_t \quad (2)$$

ここで， \mathbf{z}_t は時刻 t においてシステムが出力する特徴ベクトル， \mathbf{u}_t は状態ベクトルを表す．状態ベクトルと特徴ベクトルは観測行列 G によって，その対応付けが決定される．また，遷移行列 F は状態ベクトルの遷移を定義し，一時刻前の状態から次状態を推定できる．つまり単純マルコフ性を仮定している． ζ_t, η_t はそれぞれ共分散を P, R とするノイズであり，これらの存在によって，式 (1) において完全な次状態の予測は行えず，また式 (2) では正確な状態ベクトルを観測することができない．このた

め、一時刻前の状態ベクトルと、特徴ベクトルから ζ_t, η_t の分散を考慮に入れた上で、現時刻の状態ベクトルの推定を行うことになる。なお、 ζ_t, η_t は平均をゼロとする白色ガウス雑音であると仮定している。

ある時系列パターンを与えたときに、このモデルがその系列を高い確率で生成できるようにモデルのパラメータを学習できれば、このモデルが与えた時系列パターンを表現できると考える。

2.2 文脈空間の付加

前節では、動的システムによるモデル化を提示した。しかし、式 (1),(2) のみでは、1 章で述べたように、文脈という観点が必要な時系列パターン、例えば、パターン内に繰り返しを含み、その回数が意味を持つような系列を扱う際には問題が生じてしまう。

まず状態の次元数が特徴空間に比べて低い場合は、式 (2) によって、状態空間が特徴空間の部分空間となる。そのため同一の特徴ベクトルに対して必ず同一の状態ベクトルが対応付けられる。

一方、状態の次元数が特徴空間に比べて高い場合を考え、一定期間の特徴ベクトルをつなげて状態ベクトルとする方法も考えられるが、ループを持つような系列はかなり長期間の特徴ベクトルをまとめるが必要であり、入力系列の時間的伸縮に対応できないなどの問題がある。すなわち、従来の動的システムは、比較的短期的な状態の表現は可能であるが、繰り返しがあるような複雑なパターンにおいて、その繰り返し回数を記憶するなどの長期的な文脈を保持することは困難である。

この問題を解決するために、次に述べるようなモデルの拡張を行った。2.1 において示したモデルに、学習させるパターンの進捗状況という情報を与えるための空間を設け、系列 r_1, \dots, r_T を追加する。この空間を文脈空間と呼ぶことにする。また、この系列を文脈ベクトル系列と呼ぶ。すると、システム方程式は次のように表される。これを図であらわすと図 2 のようになる。

$$u_t = Fu_{t-1} + \zeta_t \quad (3)$$

$$z_t = Gu_t + \eta_t \quad (4)$$

$$r_t = Hu_t + \xi_t \quad (5)$$

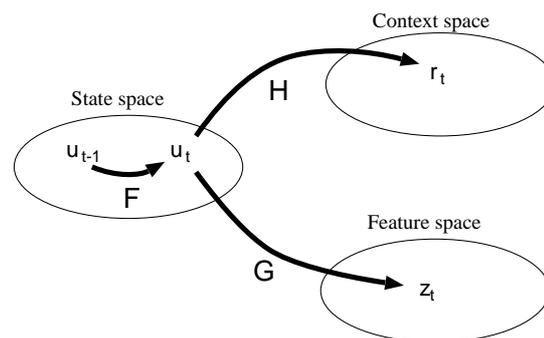


図 2: 文脈空間の追加

ここで、 ξ_t は共分散行列を Q とする平均ゼロの白色ガウス雑音であると仮定する。

このような文脈空間を状態空間と関係付けることにより、状態空間における状態ベクトルのとりうる範囲に制約を設け、長期的な文脈情報を状態空間に埋め込むことができると考えられる。

2.3 動作の進捗についての情報

本節では、前節で述べた文脈ベクトル系列として具体的にどのような系列を与えれば良いのかを議論する。

まず考えられるのが、一時刻毎に単調に増加するような系列を与えるというものである。これは系列に対し、時間的なタグをつけることに相当する。これにより、たとえ特徴空間で同一の点であっても、時間的に離れていれば状態空間でも離れた点となることが期待される。

多数のサンプルを用いて学習を行う場合では、サンプル間での系列長の違いや、時間方向の揺らぎを考慮する必要がある。たとえば、時刻毎に単調に増加するような系列を与える場合、この値として単に系列長に比例するような値を与えてしまうと、系列長によって系列の終点が異なった位置になってしまう。そこで、始点、終点は固定とし、その区間内で等間隔に補間した値を与えるといった対策が必要になる。

3 学習アルゴリズム

3.1 状態空間およびダイナミクスの学習

前節において示したモデルにおける学習とは、対象とする時系列パターンを最適に表現する状態空間とそのダイナミクスを決定することである。これは、式 (3) で示される状態遷移によって得られた状態系列を、式 (4),(5) を用いて特徴・文脈空間に写像したときに得られる系列と、学習時に与えられたサンプル系列との誤差が最小になるようにパラメータを決定するという意味である。前述のシステム方程式においては、状態空間の次元、行列 F, G, H 、誤差系列の共分散、そして状態系列の初期値での平均 π_1 と共分散 V_1 の最適値を推定することになる。

本稿では、この推定法として、一般性・計算の容易さという観点から最尤推定法を用いることとした。このとき、評価関数となるのは次式で示される尤度であり、これを最大化するようなパラメータ $\theta = [F, G, H, P, Q, R, \pi_1, V_1]$ を推定する。

$$p(z_1, \dots, z_T, r_1, \dots, r_T; \theta)$$

学習時に与えられるデータは特徴ベクトル系列と、文脈ベクトル系列のみである。これらの系列長を T とすると、

$$\mathcal{Z} = [z_1, \dots, z_T], \quad \mathcal{R} = [r_1, \dots, r_T]$$

のみが既知であり、これ以外の状態ベクトル系列、各種パラメータは完全に未知である。この状況でパラメータの決定を行うためには、状態ベクトル系列を何らかの方法で定める必要があるが、その自由度は非常に高くまたその定め方に対する一般的な指針も存在しない。そのため、パラメータだけではなく状態系列の推定も含めた、統一的な最適化を行う必要がある。このような観測できない変数を含んだモデルの最尤推定法として EM アルゴリズム [5] があり、反復計算によってその局所最適解を求めることが可能である。

3.2 EM アルゴリズムによる学習

EM アルゴリズムは、観測できない隠れたパラメータが存在する時に最尤推定を行うための汎用手法であり、混合分布や隠れマルコフモデルの学習に応用されている。また、EM アルゴリズムは Newton

法や勾配法と同様、反復法によって局所最適解を求めるアルゴリズムである。つまり、大域的な収束は保証されない。そのため、初期値の選び方が重要となる。また、状態空間の次元数についても予め決定しておく必要がある。この初期値および次元の決定については 3.3 節で議論する。

このモデルの学習においては、EM アルゴリズムにおける隠れ変数として、状態系列 u_1, \dots, u_T を考える。その上で、尤度 $p(z_1, \dots, z_T, r_1, \dots, r_T; \theta)$ を最大化するようなパラメータ θ の推定を行う [6, 7]。

まず、このモデルにおいて、尤度を表す式を導出する。 ζ_t, η_t, ξ_t の共分散行列をそれぞれ P, R, Q とおくと、式 (3),(4),(5) の条件付き確率密度は次のように表せる。 $(X'$ は転置を表す) ただし、前に述べたように誤差ベクトルは平均をゼロとする白色ガウス雑音であると仮定する。

$$\begin{aligned} p(z_t | u_t) = & \exp \left\{ -\frac{1}{2} [z_t - Gu_t]' R^{-1} [z_t - Gu_t] \right\} \\ & \times (2\pi)^{-s/2} |R|^{-1/2} \end{aligned} \quad (6)$$

$$\begin{aligned} p(u_t | u_{t-1}) = & \exp \left\{ -\frac{1}{2} [u_t - Fu_{t-1}]' P^{-1} [u_t - Fu_{t-1}] \right\} \\ & \times (2\pi)^{-k/2} |P|^{-1/2} \end{aligned} \quad (7)$$

$$\begin{aligned} p(r_t | u_t) = & \exp \left\{ -\frac{1}{2} [r_t - Hu_t]' Q^{-1} [r_t - Hu_t] \right\} \\ & \times (2\pi)^{-h/2} |Q|^{-1/2} \end{aligned} \quad (8)$$

ここで、 s, k, h はそれぞれ z_t, u_t, r_t の次元数である。また、初期状態は次式で与えられる。ここで π_1 は、状態ベクトルの初期値での平均、 V_1 は同じく共分散行列を表す。

$$\begin{aligned} p(u_1) = & \exp \left\{ -\frac{1}{2} [u_1 - \pi_1]' V_1^{-1} [u_1 - \pi_1] \right\} \\ & \times (2\pi)^{-k/2} |V_1|^{-1/2} \end{aligned} \quad (9)$$

ところで、このモデルは単純マルコフ性を仮定しているから、尤度は次式で表すことができる。ここで、 $\mathcal{U} = [u_1, \dots, u_T]$ とする。

$$p(\mathcal{U}, \mathcal{Z}, \mathcal{R}) = p(u_1) \prod_{t=2}^T p(u_t | u_{t-1})$$

$$\times \prod_{t=1}^T p(z_t | \mathbf{u}_t) \prod_{t=1}^T p(\mathbf{r}_t | \mathbf{u}_t) \quad (10)$$

よって、この尤度を EM アルゴリズムを用いて次のように最大化すればよいことになる。

E step 現在のパラメータの値を用いて次の対数尤度の条件付き期待値を計算する

$$Q = E[\log p(\mathbf{U}, \mathcal{Z}, \mathcal{R}) | \mathcal{Z}, \mathcal{R}] \quad (11)$$

M step E ステップで求めた対数尤度の条件付き期待値 Q を最大化するようにパラメータ θ を更新する

以上を繰り返すことで、式 (10) の局所的最大値を与えるパラメータを得ることができる。

ここでの議論は、多サンプルによる学習にも同様に適用することができる。このときの尤度は各サンプルにおける尤度の積として得られる。また、判別ベクトル系列の与え方については 2.3 節で述べた通りである。この結果、3.1 節で述べた意味で最適なパラメータ学習が行える。

3.3 初期値および次元の決定

前に述べたように、この学習アルゴリズムを実際に適用する場合、初期値の決定が重要な課題となる。本モデルの学習においては、パラメータの自由度が高いためにその局所最適解は多数存在すると考えられ、その初期値の与え方によって結果が大きく左右されてしまう。

しかしながら、この初期値依存性の問題は、それ自身難しい問題なので、この点を詳しく追求することはしない。その代わりに、本稿では、パラメータの大域的な最適解を得ることを目標とはせずに、決定すべき初期値の数をなるべく少なくする（初期値の自由度を小さくする）、初期値の妥当性を高める、という観点から初期値を設定することとし、次のような手法を用いて決定する。なお、ここでは特徴ベクトルの次元数が状態の次元数に比べて高いものとする。

1. 特徴系列に対して主成分分析を行う

式 (3),(4),(5) において、 ζ の分散を $P = I$ と固定し、対象とする特徴系列 \mathcal{Z} および \mathcal{R} に対して学習を行う。このとき必要とされる初期値

は G, H および η の分散 R, ξ の分散 Q であり、適当に初期化しておく。

2. 1 の結果を用いて初期値を決定する

1 の結果、パラメータ θ と状態系列 \mathbf{U} が求まる。残るパラメータは遷移行列 F および、状態の初期パラメータ π_1, V_1 である。 π_1 については $\pi_1 = \mathbf{u}_1$ と定め、 V_1 には \mathbf{U} の共分散行列を設定する。 F は次の式

$$[\mathbf{u}_2 \mathbf{u}_3 \cdots \mathbf{u}_T] = F[\mathbf{u}_1 \mathbf{u}_2 \cdots \mathbf{u}_{T-1}]$$

を解くことにより求める。

上記の手順によって得られたパラメータを初期値パラメータとして、E ステップから繰り返し計算を開始する。

主成分分析という前処理を行っている¹理由は、この処理の初期値依存性が比較的低いと考えられるためである。なぜなら、主成分分析の最適解は、ほぼ一意に決定され、パラメータも同様に一意に収束すると考えられる。

次に状態空間の次元数の決定について述べる。このモデルにおいて学習を行う場合、状態空間の次元数は任意に設定でき、これを予め決めておかなければならない。次元数は 2 つの観点から決定する必要がある。一つは、主成分分析と同様に表現のための次元圧縮を行っているという点、もう一つは、状態の遷移を表現しうる空間が必要という点である。これはそれぞれ、式 (4), (3) に対応している。本稿ではまずは前者を考慮し、特徴ベクトル系列の固有次元を状態の次元数と考える。次に後者を考慮し、学習の様子を見ながら次元を増やしてゆくような操作を行うものとする。

4 実験による検証

2.2 節で文脈を持つような特徴系列を表現できるように動的モデルの拡張を行った。ここでは、この拡張が有効であるかどうかを検証するため、通常の動的システムモデルによる学習結果と 2.2 節で提案した手法での学習結果を比較し考察を行う。

ここでは、比較を行うために、ループを持ち、系列が交わっているような特徴系列を与える。このと

¹手順 1 では、正確には主成分分析ではなく因子分析を行っていることになる [8]

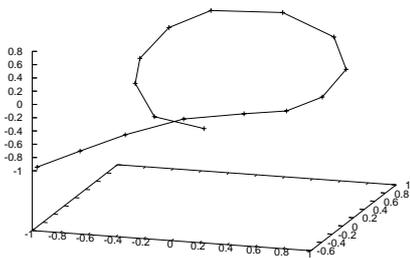


図 3: 学習に用いた特徴系列

き学習結果である状態空間において、交差が分離され、一本の重なりのない状態系列が得られれば提案手法の有効性を示すことができる。

本実験では、入力として3次元の特徴系列を用いる。状態空間の次元は2次元とした²。文脈系列としては、0から1へと単調に増加する1次元の系列を与えた。初期値については、3.3節で述べた方法により決定した。また、EMステップの繰り返し回数は600回とした。これは、尤度の上昇が600回程度の反復回数で横ばいになっていることから定めた(図4)。

学習に用いた特徴系列を図3に示す。各軸ともに $[1, -1]$ の区間に点を含み、平均が0となるように正規化されている。

まず、学習が行えていることを確かめるために、繰り返し計算の過程で尤度が単調に増加していることを示す(図4)。図より、尤度が単調に増加していることが確認でき、EMアルゴリズムによる最適化が期待通りに行われていることが分かる。状態の進捗の情報を付け加えたモデルの方で、尤度が低くなっているが、これは文脈空間が追加され、そこからの制約が加わったため、モデル化の誤差が増加したものと考えられる。

次に、通常の動的モデルによって学習された状態系列(図5)と、提案手法による状態系列(図6)を示す。通常の動的モデルを用いた学習では、特徴空間中の交差は、状態空間中でもそのまま現れている。一方、提案したモデルによって学習された状態系列では、交点がなくなり、また、始点と終点の距離を遠くすることにも成功している。

²可視化を意識してこのように決定した

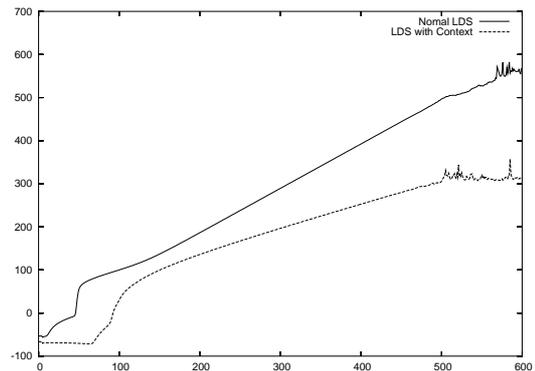


図 4: 尤度(縦軸:対数尤度,横軸:繰り返し回数,実線:通常の動的システム,点線:提案手法での)

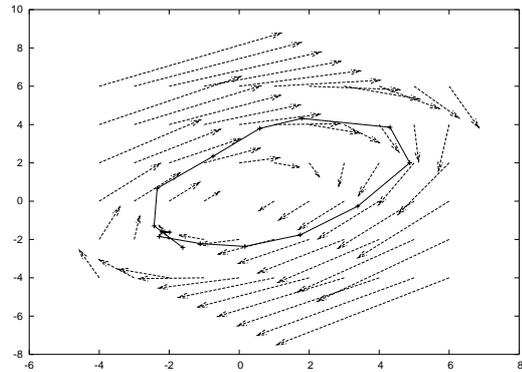


図 5: 通常の動的モデルによる状態系列(矢印:学習されたダイナミクスフロー)

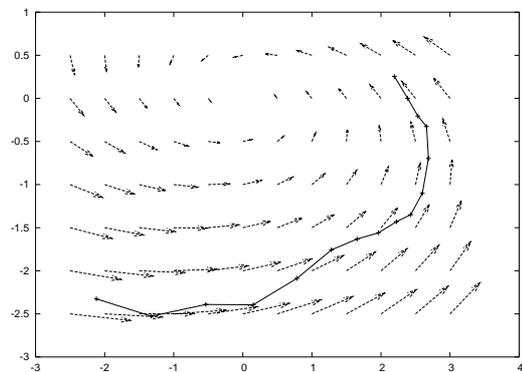


図 6: 提案手法による状態系列(矢印:学習されたダイナミクスフロー)

以上の結果から，特徴空間上で交差していた系列が，提案手法での学習により，状態空間では交差のない系列として確かに表現できることが確認できた．これによって，状態の進捗情報を学習時に追加するという手法が，繰り返しや交わりを持ったパターンの学習・表現において有効であることが示せた．

5 多クラス識別への拡張

ここでは，これまでに述べた提案手法を多クラスの時系列パターンを識別する際には，どのような拡張が必要であるかについて考察を行う．

5.1 多クラス識別を行うモデル

本手法を多クラスの識別へ拡張する際には，次の2つのモデルが考えられる．

モデル A 一つのクラスに対して一つの状態空間を対応させる

モデル B 対象とする全てのクラスを単一の状態空間で表現する

モデル A は一つのクラスごとに個別のパラメータの組を学習させるというものである．このモデルでは学習を各クラスで別々に行うので，学習時におけるクラス間の干渉が発生しない．このため，学習された状態空間はそれぞれのクラスに対して最適になっているという利点がある．その一方で，状態空間はクラス間で完全に独立しているため，それぞれの内部の状態系列を直接比較するような処理には工夫が必要となる．一方モデル B は，パラメータのうち状態空間の構成に関わる部分，すなわち特徴空間と状態空間を結びつける式 (4) の G と η_t の分散行列 R ，および，文脈空間と状態空間を結びつける式 (5) の H と ξ_t の分散行列 Q を全てのクラスで共有するというものである．

ここでは比較的単純なモデル A について考察を行う．

5.2 多クラス識別モデルの学習法

前提として， C 個のクラスを考える．説明を簡単にするため，ここでは，ある一つのクラス c ($c = 1, \dots, C$) につき一つの学習サンプル系列のみが与え

られるものとする．この場合，クラス c の特徴ベクトルの系列長を $T^{(c)}$ とすると，次に示すような特徴ベクトル系列と文脈ベクトル系列の組が C 組与えられることになる．

$$\mathcal{Z}^{(c)} = [z_1^{(c)}, \dots, z_{T^{(c)}}^{(c)}] \quad (12)$$

$$\mathcal{R}^{(c)} = [r_1^{(c)}, \dots, r_{T^{(c)}}^{(c)}] \quad (13)$$

このときの状態ベクトル系列は次のように表されるとする．

$$\mathcal{U}^{(c)} = [u_1^{(c)}, \dots, u_{T^{(c)}}^{(c)}] \quad (14)$$

各クラスが個別の状態空間を持つため，このモデルの学習アルゴリズムは，それぞれのクラス別に，3.2 節で述べた学習を行うことに等しい．多サンプル学習についても同様である．すなわち，このモデルにおいて，あるクラス c におけるモデルを学習する際には，このモデルから系列 $\mathcal{Z}^{(c)}$ および系列 $\mathcal{R}^{(c)}$ が同時に生成される確率 $p(\mathcal{Z}^{(c)}, \mathcal{R}^{(c)}|c)$ を最大化するように最尤推定を行えばよい．

5.3 識別時の評価基準

学習された多クラス識別モデルに，識別対象となる特徴ベクトル系列を与えた際，クラスを識別する基準が必要となる．ここではその基準として，あるクラス c において特徴系列 \mathcal{Z} が生成される対数事後確率を用いることを考える．

$$\log p(\mathcal{Z}|c) = \log \prod_{t=1}^T p(z_t|z_1, \dots, z_{t-1}, c) \quad (15)$$

$$= \sum_{t=1}^T \log p(z_t|z_1, \dots, z_{t-1}, c) \quad (16)$$

そして，識別の対象となる特徴系列を入力した時に，クラス毎に求まる対数事後確率を比較し，最も高い値を持つクラスを識別結果とする．

$$c^* = \arg \max_c \log p(\mathcal{Z}|c) \quad (17)$$

なお，時刻 $t-1$ までの入力から時刻 t における入力の予測値 GFu_t と，実際の時刻 t における入力 z_t のマハラノビス距離を $D_t = (z_t - GFu_t)' \Sigma_t^{-1} (z_t - GFu_t)$ とすれば，式 (16) における総和の内部は次のようになる．

$$\log p(z_t|z_1, \dots, z_{t-1}, c) = -\frac{1}{2} D_t - \log |\Sigma_t| - s \log 2\pi \quad (18)$$

従って、予測値の分散 Σ_t を一定と考えた場合には、各クラスの評価基準は、ちょうど各クラスのモデルによって累積予測誤差を計算し、そのうち最小のものを識別結果とすることになる。

6 おわりに

本報告では、時系列パターンを表現・認識する方法として、動的システムモデルに文脈を表現する空間を関係付けるモデルおよびその学習アルゴリズムを提案した。これによって、状態空間は特徴ベクトルの時間的・空間的な類似度を表現することになり、繰り返しを持つような時系列パターンを表現・認識可能となる。

今後の課題としては、次のようなものが挙げられる。

- 動作の進捗の情報として与える系列について、さらに考察と実験を行い、広く様々な時系列パターンに対して有効な手法を考案する
- 映像などの実データを用いて、本稿で提案したモデルが、実世界でどれだけ適用可能であるかを、大量のサンプルデータから統計的に評価する

謝辞

本研究は科学研究費補助金特定領域研究 13224051 の補助を受けて行った。

参考文献

- [1] Z. Ghahramani and G. E. Hinton, Switching state-space models, *Technical Report CRG-TR-96-3, Dept. of Computer Science, University of Toronto*, (1996).
- [2] B. N. A. Blake, M. Isard, and J. Rittscher, Learning and classification of complex dynamics, Vol. 22, No. 9, (2000), pp. 1016–1034.
- [3] 森田昌彦, 村上聡, 非単調神経回路網による時系列パターンの認識, Vol. J81-D-II, No. 7, (1998), pp. 1679–1688.

- [4] 加藤寛一郎, 最適制御入門, レギュレータとカルマンフィルタ, (東京大学出版会, 1987).
- [5] 栗田多喜夫, 赤穂昭太郎, 画像理解における統計的手法, コンピュータビジョン: 技術評論と将来展望 (松山隆司, 久野義徳, 井宮淳 (編)), (新技術コミュニケーションズ, 1998), 第 13 章.
- [6] R. H. Shumway and D. S. Stoffer, An approach to time series smoothing and forecasting using em algorithm, *Journal of Time Series Analysis*, Vol. 3, No. 4, (1982), pp. 253–256.
- [7] Zoubin Ghahramani and Geoffrey E. Hinton, Parameter estimation for linear dynamical systems, Technical report, (Dept. of Computer Science, University of Toronto, 1996).
- [8] Sam Roweis and Zoubin Ghahramani, A unifying review of linear gaussian models, *Neural Computation*, Vol. 11, No. 2, (1999).