

# 自己増殖型ニューラルネットワークとDTWを用いた 頑健な時系列パターンの認識

Robust Model for Time-series patterns Based on  
Self-organizing Incremental Neural Network and DTW

岡田将吾\*1  
Shogo Okada

阿部 冬馬\*1  
Toma Abe

吉野 弘規\*1  
Hiroki Yoshino

長谷川修\*1  
Osamu Hasegawa

\*1東京工業大学

Tokyo Institute of Technology

This paper presents a mechanism (SOINN-DTW) for recognition of time-series data that is based on Self-Organizing Incremental Neural Network (SOINN) and Dynamic Time Warping. Using SOINN's function that represents topological structure of input data, Proposed method approximates output distribution of each state and is able to construct robust model for time-series data. Proposed method is the novel method that enhanced Stochastic DTW Method (Nakagawa,1987). To confirm the effectiveness of proposed method, we present an extensive set of experiments that show how our method outperforms HMM and Stochastic Dynamic Time Warping Method in classifying phone data.

## 1. まえがき

時系列データの認識・モデル化は動画像処理や音声情報処理などの分野において重要な基盤技術である。この分野では、あらかじめ状態遷移に基づくモデルを持つことで、時系列データの認識を行う手法が頻りに用いられて来た。

これらの手法の中で HMM (Hidden Markov Model) は、音声情報処理全般における標準的手法となっている [Rabiner 89]。この音声情報処理における成功事例や、統計的理論の裏づけがあることから、HMM は動画像および動作の認識にも多く用いられてきた。音声認識や動画像認識における手法としては離散 HMM (Discrete HMM) [Yamato 92] を用いるものや、連続分布 HMM (Continuous HMM) [Wilson 95] を用いるものがある。通常 HMM では、パラメータの推定の容易性の理由で、音声データで言えば一音韻に対して 3~5 状態のマルコフモデルを用いる場合が多い。しかしこのような少数の状態では、過度的な時系列パターンを正確にモデル化できない可能性がある。

これに対し動的計画法の一種である DP マッチング法は、短時間の特徴パラメータ (各フレーム) 同士の局所距離に基づいて、過度的な時系列データ間の距離を算出することが可能である。しかし一般的な DP マッチング法では、時系列データの特徴空間内での変動を吸収出来ない。

これらの背景から、DP マッチングの利点と HMM の頑健性の両方を活かしたストキャスティック DP 法 [中川 87] が中川によって提案されている。ストキャスティック DP 法はテンプレートパターンの 1 フレームを 1 状態に対応させており、状態数を多くした HMM の連続出力分布を持つ left-to-right モデルに相当する。各状態の出力分布には単一の多次元正規分布が用いられている。しかし特徴量の次元数が大きかったり、特徴量の分散が大きい場合には、各状態の出力分布を単一の多次元正規分布で近似できない可能性がある。この問題に対し、本研究では各状態の出力分布を特徴量に応じて自己組織的に決定することで、各状態の出力分布を詳細に近似可能な手法を提案する。

提案手法ではテンプレートパターンにおける各状態の出力分布を Self-Organizing Incremental Neural Network (SOINN)

により詳細に近似する。Self-Organizing Incremental Neural Network (SOINN) [Shen 06] は Shen と Hasegawa によって提案されたオンライン教師なし学習手法である。SOINN の機能を用いることで、各状態の出力分布は複雑さに応じて自己組織的に近似される。提案手法において、状態数はテンプレートパターンのフレーム数に対応し、各状態の出力分布は SOINN によって自動的に近似される。したがって、提案手法では HMM のように最適な状態数および連続分布の混合数を事前に決定する必要がない。総じて、本研究ではストキャスティック DP 法を拡張し、各状態の出力分布を SOINN により自己組織的に近似することで、時系列データを頑健に学習・認識可能な手法を提案する。

## 2. 提案手法

### 2.1 SOINN

SOINN [Shen 06] (Self-Organizing Incremental Neural Network) は非定常的な入力を学習可能であり、分布に複雑な形状を持つクラスに対してもノイズを除去し、適切なクラス数及び位相構造を出力できる。SOINN のアルゴリズムの詳細については [Shen 06] に記載されている。

提案手法は、時系列モデルにおける各状態の特徴空間上の分布を近似するために SOINN を用いる。SOINN は入力データに含まれるノイズを除去し、教師ラベルのない入力ベクトルの位相構造を表現することが可能である。この機能を用いることで、各状態のベクトル群の位相構造が表現され、この位相構造を出力分布に用いる。

### 2.2 SOINN-DP 法

SOINN-DP 法は、訓練パターン間において DP マッチングを行うことでテンプレートモデルを生成する。また、各クラスの訓練パターンから構成されたテンプレートモデルと入力パターンを DP マッチングすることで、入力パターンの認識を行う。

以下では、クラス  $C$  に属する  $N$  個の訓練パターンが与えられたとし、この  $N$  個の訓練パターンからテンプレートモデルを生成する手順を説明する。

[STEP 1: 標準パターンの決定]

訓練パターン群から、テンプレートモデルの中心となる標準パターンを決定する。以下の式を用いて、各訓練パターン間の累積距離の和が最も小さい訓練パターンを、テンプレートモデルの中心となる標準パターン  $P^*$  と決定する。

$$P^* = \arg \min_{P_m} \left\{ \sum_{n=1}^N D(P_m, P_n) \right\} \quad (\{P_n, P_m\} \in C) \quad (1)$$

$P_m, P_n$  はクラス  $C$  内に含まれる訓練パターンを示す。DP マッチングにおける累積距離  $D(P_m, P_n)$  は、基本的な対称型漸化式を用いて算出した。標準パターン  $P^*$  のフレーム数  $T^*$  をテンプレートモデルの時系列長とする。

[STEP 2 : パターンを各状態に分配]

標準パターン  $P^*$  の第  $j$  番目の要素を  $p_j^*$ 、訓練パターン  $P_n (n \in C)$  の第  $i$  番目 (フレーム目) の要素を  $p_i^n$  とし、この  $p_j^*$  と  $p_i^n$  との (DP マッチング後に得られる) 最適な対応付け  $w^n$  を  $i = w_j^n (j = 1, 2, \dots, T^*)$  と定義する。この  $w^n$  に従い、訓練パターンの  $i$  番目の要素を  $j$  番目の状態 (SOINN 空間) に分配する。

上記の操作を標準パターンと、その他  $N-1$  個の訓練パターンとの間で行った後に、 $N-1$  個の最適経路  $w^n (n = 1, \dots, N-1)$  が得られる。この最適経路に従い、各状態に訓練パターンの各要素を分配する。ここで  $j$  番目の状態に分配された要素集合を  $Z_j$  と定義する

SOINN-DP 法では 1 フレームを 1 状態に対応させているため、1 つの状態に分配されるデータ (要素) は少量となる。このため  $Z_j$  から  $Z_{j+L-1}$  までの要素集合を、 $j$  番目の状態 (SOINN) に入力する。この  $j$  番目の SOINN 空間に入力する要素集合を  $Z_j^*$  と定義し  $Z_j^* = \{Z_j, Z_{j+1}, \dots, Z_{j+L-1}\}$  と表す。ここで  $L$  は SOINN-DP のパラメータであり、このパラメータを Segment 数と定義する。このパラメータの設定方法は 3.22 節で述べる。またテンプレートモデルの状態数は  $T^* - L - 1$  と決定される。STEP2. の処理過程を図 1 に示す。

[STEP 3 : SOINN の学習]

各状態  $j$  において、要素群  $Z_j^*$  を SOINN によって学習した後、複数の代表的ノード集合 (クラスタ) が形成される。ここで形成された複数の代表的ノード集合から、状態の出力分布を 2.31 節の手法に従い推定する。

2.3 入力パターンの認識

クラス  $c$  のテンプレートモデル  $TM_c$  と入力パターン  $IP$  との DP マッチングには、以下の対称型漸化式を用いる。

$$Q(i, j) = \max \begin{cases} Q(i, j-1) + C(x_i, S_j) \\ Q(i-1, j-1) + 2C(x_i, S_j) \\ Q(i-1, j) + C(x_i, S_j) \end{cases} \quad (2)$$

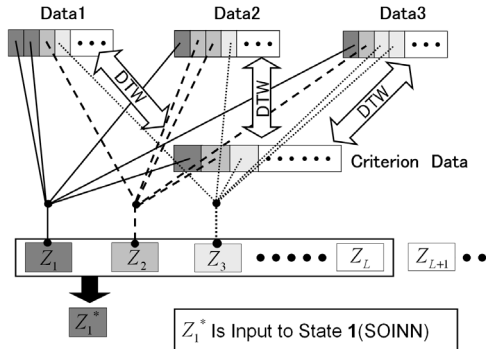


図 1: STEP2. の処理過程 (図 1 は DP マッチングに基づく、各 SOINN 空間へのデータ入力方法を示す。図 1 において Criterion Data は標準パターンを示し、Data1~3 は訓練パターンを示す。)

式 (2) において  $C(x_i, S_j)$  はテンプレートモデル  $TM_c$  の  $j$  番目の状態  $S_j$  に対する、入力パターン  $IP$  の  $i$  番目の要素  $x_i$  の尤度を示す。SOINN-DP 法では、この尤度の和が最大になるように DP マッチングが行われる。

上記の漸化式に従い、各クラスの訓練パターンから構成されたテンプレートモデルと入力パターンを DP マッチングし、入力パターンがどのクラスに属するかを認識する。

2.31 尤度  $C(x_i, S_j)$  の算出方法 SOINN の学習後、テンプレートモデルの各状態には複数のクラス (SOINN により形成されたノードと辺の集合) が生成している (図 2)。ここで SOINN によって生成された 1 つのクラスを内部クラスと定義する。内部クラスはノードの参照ベクトル (プロトタイプベクトル) 群で表現されている。このノードの参照ベクトル群から尤度  $C(x_i, S_j)$  を定義する。SOINN-DP 法では、大域的尤度と局所的尤度の 2 つの尤度を定義し、この 2 つの尤度の和を  $C(x_i, S_j)$  と定義する。

大域的尤度の算出

大域的尤度は、 $j$  番目の状態  $S_j$  の SOINN 内に存在する全ノードを多次元正規分布の確率密度関数で近似し、この密度関数からの生起確率  $P_{whole}(x_i|S_j)$  によって算出される。ここで  $\log(P_{whole}(x_i|S_j))$  を、大域的尤度と定義する。また  $P_{whole}(x_i|S_j)$  の平均  $\mu_j$  は状態  $S_j$  の SOINN 内に存在する全ノードの平均ベクトルとし、共分散行列  $\Sigma_j$  は最尤推定により算出した。

局所的尤度の算出

局所的尤度は、SOINN によってクラスタリングされた、複数の内部クラスの情報をを用いて算出される。図 2 において、class1~3 が内部クラスを示す。これらの各内部クラスを多変量正規分布に基づく核関数で近似する。ここで核関数を用いた理由は、各内部クラスが保有するノード数は少数の場合 (最低で二個) が多く、このような少数データから多次元正規分布を推定することが困難なためである。SOINN の  $k$  番目の内部クラスを  $U_{jk}$  と定義し、 $U_{jk}$  から推定される  $P_{class}(x_i|U_{jk})$  を以下に示す。

$$P_{class}(x_i|U_{jk}) = \frac{1}{(2\pi h_{jk}^2)^{M/2}} \exp\left\{-\frac{\|x_i - x_{jk}\|^2}{2h_{jk}^2}\right\} \quad (3)$$

$x_{jk}$  は SOINN 内の内部クラスを  $U_{jk}$  に存在する全ノードの平均ベクトル、 $h_{jk}$  は核関数の領域の大きさを示すパラメータであり、最尤推定により算出した。

最終的に、 $P_{whole}(x_i|S_j), P_{class}(x_i|U_{jk})$  を用いて SOINN-DP における尤度  $C(x_i, S_j)$  は次式で表わされる。




図 2: 状態  $S_j$  において SOINN から形成される 2 種類の確率分布の様子

$$C(\mathbf{x}, S_i) = \alpha \log\left(\sum_k^K \omega_j P_{class}(\mathbf{x})\right) + (1 - \alpha) \log(P_{whole}(\mathbf{x})) \quad (4)$$

式(4)において  $\alpha = 0.5$  とし,  $\omega_k = \frac{N_{jk}}{N_{all}}$  とした. ここで  $N_{all}$  は状態  $S_j$  の SOINN 内に存在する全ノードの総数を示し,  $K$  は状態  $S_j$  の SOINN 内の内部クラスの数である.

### 3. 実験

本章では, SOINN-DP 法の学習機能, 認識精度を検証するために音素データを用いた認識実験を行った.

#### 3.1 比較手法

SOINN-DP 法との比較手法には, HMM, ストキャスティック DP 法を用いた. HMM には連続分布型の left to right モデルを用いた. HMM のパラメータ推定法には, 一般的に用いられる Baum-Welch アルゴリズムを用いた. また Baum-Welch アルゴリズムのパラメータ推定精度を向上させるため, パラメータの初期値設定に Segmental-kmeans 法を用いた.

ストキャスティック DP 法 [中川 87] については, [中川 87] で用いられた漸化式と対称型漸化式の両方を用いて実験した. これは対称型漸化式を用いている SOINN-DP 法との比較を行うためである.

#### 3.2 パラメータ設定

SOINN-DP 法では, SOINN の持つパラメータおよび SOINN-DP の持つパラメータを予備実験により設定する. SOINN-DP 法のパラメータを設定するために, 孤立単語 5 クラスを用いた予備認識実験を行った. この実験において認識率が最大となったパラメータを, 後の音素認識実験に用いた.

3.2.1 SOINN のパラメータ SOINN ではノイズ除去を行うために, ニューロと辺の生成・削除に関するパラメータ  $\lambda, age_{dead}$  を導入している. 予備実験の結果から, 上記のパラメータをそれぞれ  $\lambda = 10000, age_{dead} = 30000$  に設定した.  $\lambda, age_{dead}$  の他に SOINN にはパラメータ  $c, \alpha_1, \alpha_2, \alpha_3, \beta, \gamma$  が存在するが, これらについては [Shen 06] に示された値  $c = 1, \alpha_1 = 1/6, \alpha_2 = 1/4, \alpha_3 = 1/4, \beta = 2/3, \gamma = 3/4$  を使用した.

3.2.2 SOINN-DP のパラメータセグメント数  $L$  の設定方法を説明する. セグメント数  $L$  は, 各状態 (各 SOINN 空間) に入力するデータ数を調節している.  $L$  を極端に大きい値に設定すると, 時系列的に離れたデータを 1 つの状態に入力することになり, 時系列を無視することになる. 逆に  $L$  を極端に小さい値に設定すると, 要素が少なくなり SOINN の学習精度が低下する. ここで, 本研究では特徴量の次元数  $p$  と, 訓練データ数  $N$  に応じて  $L$  を決定する. 予備実験を通して, 上記の範囲内における最適なセグメント数を  $L \geq \frac{6p}{N}$  を満たす最小の値と決定した. 後の実験ではこの決定方法に従って,  $L$  を決定した.

#### 3.3 実験条件

認識対象には, ked-TIMIT データベース [ked-TIMIT] 中に含まれる英語文章から抽出した音素 39 クラスを 100 個ずつ, 計 3900 個を使用した. 実験条件の詳細を表 1 に示す. SOINN-DP のセグメント数  $L$  は訓練データ 40 個の場合  $L = 6$ , 訓練データ 80 個の場合  $L = 3$  と決定した (3.2.2 節).

比較対象の手法についても, 表 1 と同じ条件で実験を行った. HMM の各状態の出力確率は全共分散行列を持つ混合正規分布とした. ここで, 最大の認識率を得る HMM の最適なパラメータ (状態数および混合正規分布の混合数) を探索する必要がある. このため, それらのパラメータを変化させながら

表 1: 音素認識実験の条件

認識対象:	音素データ 39 クラス (aa,ae,ah,ao,ax, ay,bcl,ch,dcl,dh,dx,eh,er,ey,f,gcl,h,ih,iy,jh,k,kcl, l,m,n,ng,ow,p,pcl,r,s,sh,t,tcl,uw,v,w,y,z)
音声データベース:	kedTIMIT 計 3900 サンプル (1 クラスにつき 100 サンプル)
評価話者:	男性 1 名
評価方法:	訓練データとテストデータを入れ替えながら, 10 回のクロスバリデーション実験
データセット:	1 回の実験に用いる 1 クラスあたりのデータ数 (訓練データ, テストデータ)=(40,60),(80,20)
特徴量:	12 次元 MFCC, 対数パワー, 12 次元 $\Delta$ MFCC, $\Delta$ 対数パワー, 12 次元 $\Delta\Delta$ MFCC, $\Delta\Delta$ 対数パワー 計 39 次元

表 2: 音素実験におけるテストデータに対する認識率 [%](TD40(TD80) は訓練データ数が 40(80) 個であることを示している.)

Method	SO-DP	ST-DP(1)	ST-DP(2)	HMM
TD40 [%]	56.36	30.81	51.71	47.69 (5S,2M)
TD80 [%]	62.55	33.83	55.46	51.90 (5S,4M)

実験を行い, 最適なパラメータを探索し, そのパラメータを用いた場合の認識率を求め, これを HMM による認識率とした.

#### 3.4 音素認識実験の結果

10 回のクロスバリデーション実験の結果から得られたテストデータに対する平均認識率を表 2 に示す. 「SO-DP」は SOINN-DP 法, 「ST-DP(1)」は非対称漸化式を用いたストキャスティック DP 法, 「ST-DP(2)」は対称漸化式を用いたストキャスティック DP 法をそれぞれ示す. HMM の認識率の右の ( ) 内は, 最大の認識率を得た時のパラメータ (S:状態数, M:混合数) を示す.

表 2 より SOINN-DP 法の平均認識率は, ストキャスティック DP 法, HMM のそれに比べ, 良好であった.

HMM を用いた実験については, 比較のため状態数を 1 個から 13 個まで変動させ実験を行なった結果, 状態数 3~7 の付近において認識率が最大となったため, 状態数 3~7 が本実験で使用した音素データに対する最適状態数であると推定した.

そこで状態数 3~7 において, 各状態に割り当てられている出力確率を混合連続確率分布に変更し, 混合数を変化させ表 1 の条件で実験を行なった. その結果, 訓練データ 40 個の場合, 5 状態 2 混合, 訓練データ 80 個の場合, 5 状態 4 混合で認識率が最大となった.

ストキャスティック DP 法については, [中川 87] で提案された非対称型漸化式を用いるより, 対称型漸化式を用いた認識結果の方が良好であった. これは, 対称型漸化式を用いる方が時系列の伸縮を吸収しやすいためと考えられる.

総じて音素認識実験の結果, SOINN-DP 法では, ストキャスティック DP 法, HMM で得られる最大の認識率より, 良好な認識率を得られることを示した.

#### 3.5 実験から得られた知見

##### ストキャスティック DP 法との比較

SOINN-DP 法は, 1 つの状態を SOINN によって詳細に近似することで頑健なテンプレートモデルを構築することを目指した. また SOINN-DP 法はストキャスティック DP 法の拡張手法である. ストキャスティック DP 法との認識率を比較した結果, SOINN-DP 法はストキャスティック DP 法よりも認識率の点で優れていた. この結果から, SOINN-DP 法はストキャ

スティック DP 法よりも時系列データの頑健なモデル化を行うことが可能であることを示した。

#### HMM との比較

次に SOINN-DP 法では各状態の出力分布を SOINN によって自動的に決定することが可能である。また状態数は標準パターンの時系列数と決定されるため、状態数も予め設定する必要がない。一方、HMM で時系列データを学習する際、状態数と状態の出力分布 (連続分布の場合、混合数) を事前に決める作業が必要である。

このため実験では HMM の状態数および混合数を変化させながら、認識率が最も高くなる場合を探索した。この探索結果から得られた HMM の最大認識率より、SOINN-DP 法の認識率は良好であった。以上の結果より、SOINN-DP 法では事前に状態数および出力分布のパラメータを設定せずに、高い認識率が得られることが示された。

## 4. 考察

### 4.1 SOINN の認識性能への寄与

SOINN-DP 法の認識性能に SOINN がどのように寄与しているかを議論する。ここでは SOINN を用いて分布を近似しない手法を 2 つ定義し、SOINN-DP 法との比較を行った。SOINN の学習結果を用いない手法と比較を行うことで、SOINN の認識精度への寄与を検証した。SOINN の学習結果を用いない比較手法には以下の 2 つの手法を用いた。

手法: 1 要素ベクトル群  $\mathcal{Z}^*_j$  を SOINN に入力せず、 $\mathcal{Z}^*_j$  から直接、最尤推定により多次元正規分布  $P(\mathbf{x}|S_j)$  を求めた。尤度  $C(x_i, S_j) = \log(P(\mathbf{x}|S_j))$  とし、この尤度  $C(x_i, S_j)$  を用いた漸化式によって入力データの認識を行った。

手法: 2 要素ベクトル群  $\mathcal{Z}^*_i$  を SOINN に入力し、SOINN の分類結果から  $P_{whole}(\mathbf{x}_i|S_j)$  を求めた。ただし SOINN のクラスタリング結果から得られる  $P_{class}(\mathbf{x}_i|U_{jk})$  を入力パターンの認識に用いなかった。これは式 (4) において  $\alpha = 0$  と置くことに等しい。

ここで検証実験は表 1 と同様の条件下で行い、1 回の実験に用いる 1 クラスあたりの訓練データは 80 個、セグメント数  $L = 3$  とした。

検証実験の結果から得られた、SOINN の学習結果を用いない手法 ([手法 1] および [手法 2]) で得られた認識率と SOINN を用いる手法 (SOINN-DP 法) で得られた認識率を表 3 に示す。SOINN-DP 法の認識率は [手法 1]、[手法 2] の認識率を約 4 % 上回っている。この結果より、SOINN の学習結果として得られる内部クラスの情報をを用いる SOINN-DP 法がこの情報を用いない [手法 1]、[手法 2] に対して認識率の点で優位性があることが示された。総じて、SOINN の学習結果として得られる内部クラスの情報をを用いることで、認識率の向上が見られることを確認した。

ここで式 (4) において  $\alpha$  を 0~1.0 まで 0.05 ずつ変化させながら、それぞれの  $\alpha$  を用いた場合について、上記と同様の実験を行った。実験の結果、 $(\alpha) = 0.45$  で最大の認識率を得た。これは  $\alpha$  を入力データにフィッティングさせることによって、さらに SOINN-DP 法の認識精度を向上させることが可能であることを示唆している。

### 4.2 SOINN-DP 法の計算量

まずプレートモデルの作成 (学習) では、1 フレームを 1 状態に対応させ、全ての状態で SOINN により学習が行われる。また入力パターンの認識には、対称型漸化式を用いてパスを全探索している。これらの理由より、現在 SOINN-DP 法は

表 3: SOINN を用いない場合の認識率と SOINN-DP 法で得られる認識率の比較

	SOINN を用いない手法		SOINN を用いた手法	
Method	[手法 1]	[手法 2]	SOINN-DP	$\alpha = 0.45$
[%]	58.41	58.86	62.55	63.22

ストキャスティック DP 法および HMM に比べ計算時間を必要とする。具体的に音素認識実験 (表 1) において SOINN-DP 法は、対称型漸化式を用いたストキャスティック DP 法より学習過程で約 2 倍、認識過程で約 1.5 倍の計算量を要する。この問題に対し、DP マッチングの計算量を削減する方法が考えられる。この方法は [内田 06] で議論されている。今後これらの方法論を用い、DP マッチングの計算量を削減して提案手法の高速化を図る予定である。

## 5. 結論

本研究では、1 つのフレームを 1 つの状態に対応させ、各状態の出力分布を Self-Organizing Incremental Neural Network (SOINN) によって近似することで、時系列データを頑健にモデル化可能な SOINN-DP 法を提案した。

SOINN-DP 法の有効性を検証するため、音素を用いて識別実験を行った。実験では、HMM およびストキャスティック DP 法と性能比較を行い、認識精度の面で提案手法の有効性を検証した。

#### 謝辞

本研究の実施にあたり NEDO 産業技術研究助成事業から支援を頂きました。記して感謝いたします。

## 参考文献

- [Rabiner 89] Rabiner, L. R.: A tutorial on hidden markov models and selected applications in speech recognition, in *Proc. IEEE*, pp. 257-286 (1989)
- [Shen 06] Shen, F. and Hasegawa, O.: An Incremental Network for On-line Unsupervised Classification and Topology Learning, *Neural Networks*, Vol. 19, No. 1, pp. 90-106 (2006)
- [ked-TIMIT] University of Edinburgh, Center for Speech Technology Research CSTR US KED TIMIT, <http://www.teu.ac.jp/media/~earth/FK/>
- [Wilson 95] Wilson, A. and Bobick, A.: Learning Visual Behavior for Gesture Analysis, in *Proc. IEEE International Symposium on Computer Vision*, Vol. 5A Motion2 (1995)
- [Yamato 92] Yamato, J., Ohya, J., and Ishii, K.: Recognizing human action in time-sequential images using hidden Markov models, in *Proc. IEEE ICCV*, pp. 379-387 (1992)
- [中川 87] 中川聖一: ストキャスティック DP 法および統計的手法による不特定話者の英語子音の認識, *信学論 (D)*, Vol. 70, No. 1 (1987)
- [内田 06] 内田誠一: DP マッチング概説 ~ 基本と様々な拡張~, in *IEICE Technical Report CVIM2006-166*, 第 106 巻, pp. 31-35 (2006)