

静的・動的特徴の明示的な関係によりHMMから
導出されるトラジェクトリモデル

全 炳河 徳田 恵一 北村 正 (名工大)

A Trajectory Model Derived from HMM with Explicit
Relationship between Static and Dynamic Features

Heiga Zen, Keiichi Tokuda, Tadashi Kitamura
(Nagoya Institute of Technology)

背景

音声認識システムの代表的枠組み

特徴量 : MFCC+ Δ MFCC

音響モデル : 連続分布HMM

言語モデル : 単語N-gram

HMMの問題点

- (1) 状態内での時間的変化をモデル化できない
 - (2) 出力ベクトル間の時間的独立性を仮定
- ⇒ 様々な音響モデルが提案

背景

(1) 状態内での時間的変化をモデル化できない

多項式近似HMM, 隠れ動的モデル (HDM),

声道共振周波数モデル, HMM-trajectory法など

(2) 出力ベクトル間の時間的独立性の仮定

条件付きHMM, フレーム間相関HMM,

部分隠れマルコフモデル (PHMM), セグメントモデル,

ダイナミックベイジアンネットワーク (DBN) など

背景

動的特徴量の利用（古井;1986）

- ・ 特徴ベクトルに動的特徴量を追加
- ・ 認識性能が大幅に改善
- ・ 時間方向の依存性をモデル化するための一手法

動的特徴量の計算

前後数フレームの静的特徴量から回帰係数として計算

⇒ 静的特徴・動的特徴系列間には確定的な関係が存在！

HMM + (MFCC · Δ MFCC) の枠組みでは無視！

発表内容

HMMから導出されるトラジェクトリモデル

1. 静的特徴・動的特徴間の関係をHMMに導入

HMMをトラジェクトリモデルとして再定式化

2. Viterbi学習形式のパラメータ更新式の導出

3. 準最適状態系列選択アルゴリズムの提案

4. 連続音声認識実験による評価

発表内容

HMMから導出されるトラジェクトリモデル

1. 静的特徴・動的特徴間の関係をHMMに導入

HMMをトラジェクトリモデルとして再定式化

2. Viterbi学習形式のパラメータ更新式の導出

3. 準最適状態系列選択アルゴリズムの提案


4. 連続音声認識実験による評価

トラジェクトリHMMの導出(1)

長さ T の観測系列 \mathbf{o} に対するHMMの尤度

$$P(\mathbf{o} | \lambda) = \sum_{\text{all } \mathbf{q}} P(\mathbf{o} | \mathbf{q}, \lambda) P(\mathbf{q} | \lambda)$$

$$P(\mathbf{o} | \mathbf{q}, \lambda) = \mathcal{N}(\mathbf{o} | \boldsymbol{\mu}_{\mathbf{q}}, \boldsymbol{\Sigma}_{\mathbf{q}}) \quad (3MT \text{次元のガウス分布})$$



\mathbf{o}_t : 観測ベクトル ($3M$ 次元)

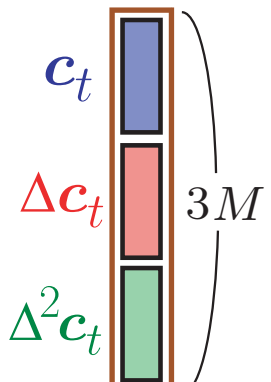
\mathbf{q} : 状態系列

$\boldsymbol{\mu}_{q_t}$: 状態 q_t の平均ベクトル

$\boldsymbol{\Sigma}_{q_t}$: 状態 q_t の共分散行列

トラジェクトリHMMの導出(2)


観測ベクトルが静的特徴と動的特徴から成る場合

$$o_t = \begin{bmatrix} \mathbf{c}_t^\top & \Delta \mathbf{c}_t^\top & \Delta^2 \mathbf{c}_t^\top \end{bmatrix}^\top$$


\mathbf{c}_t : 静的特徴ベクトル
 $\Delta \mathbf{c}_t$: 1次動的特徴ベクトル
 $\Delta^2 \mathbf{c}_t$: 2次動的特徴ベクトル

各時刻の動的特徴は前後数フレームの静的特徴から計算

(例) $\Delta \mathbf{c}_t = 0.5 \mathbf{c}_{t+1} - 0.5 \mathbf{c}_{t-1}$



トラジェクトリHMMの導出(3)

O と C の関係を行列形式で表せば,

$$\begin{matrix} O \\ \begin{matrix} c_t \\ \Delta c_t \\ \Delta^2 c_t \\ \vdots \\ c_t \\ \Delta c_t \\ \Delta^2 c_t \end{matrix} \end{matrix} = \begin{matrix} W \\ \begin{matrix} 1 & 0 & 0 & \dots \\ 0 & \frac{1}{2} & 0 & \dots \\ 2 & -1 & 0 & \dots \\ 0 & 1 & 0 & \dots \\ & & \ddots & \\ & & & \dots \\ \dots & 0 & 0 & 1 \\ \dots & 0 & \frac{-1}{2} & 0 \\ \dots & 0 & -1 & 2 \end{matrix} \end{matrix} \begin{matrix} C \\ \begin{matrix} c_1 \\ \vdots \\ c_T \end{matrix} \end{matrix}$$

W : 動的特徴計算時の係数を要素とする窓行列
($3MT \times MT$)

c しか自由度はない!
 $\Rightarrow c$ のみ確率変数とみなしてHMMの尤度関数を変形

トラジェクトリHMMの導出(4)

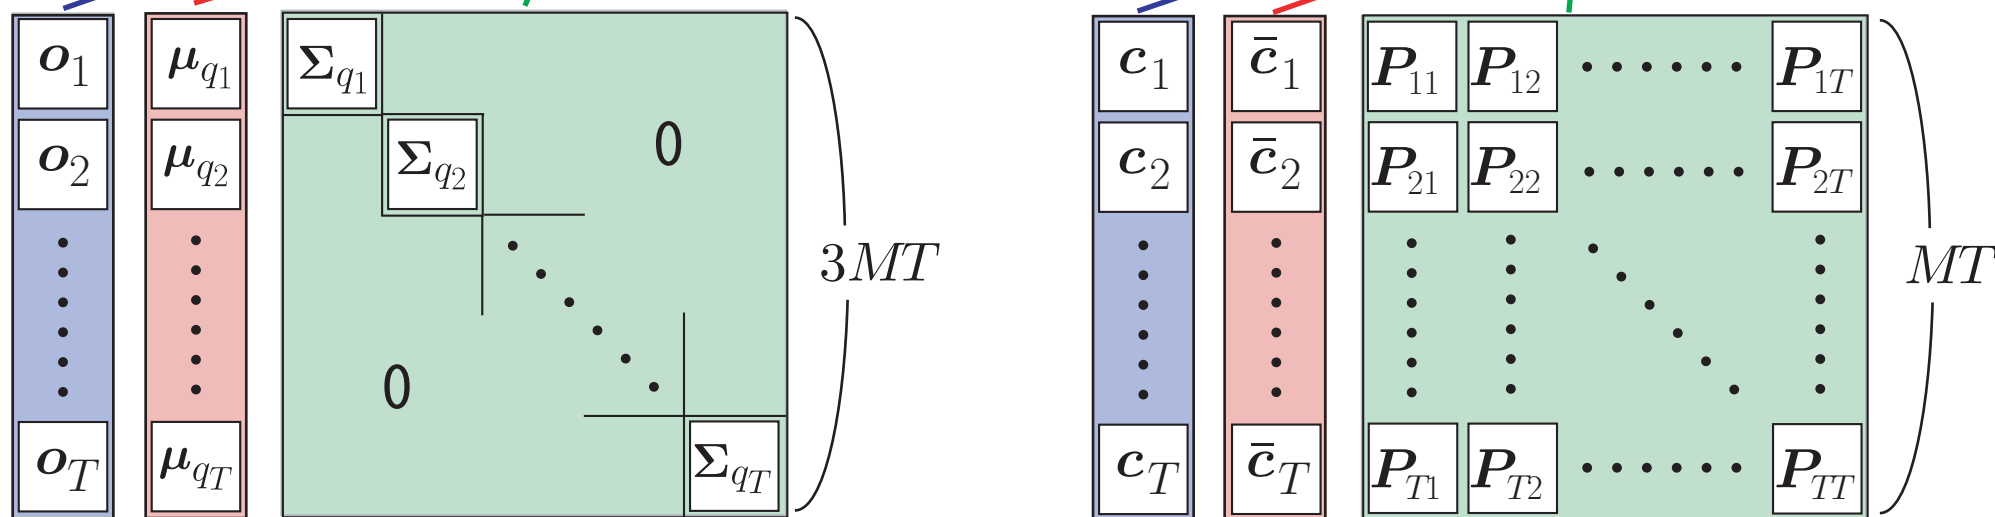
$$P(\mathbf{W}\mathbf{c} \mid \mathbf{q}, \lambda) = \mathcal{N}(\mathbf{W}\mathbf{c} \mid \boldsymbol{\mu}_q, \boldsymbol{\Sigma}_q) \\ = K_q \cdot \mathcal{N}(\mathbf{c} \mid \bar{\mathbf{c}}_q, \mathbf{P}_q)$$

$\bar{\mathbf{c}}_q$: 平均ベクトル (MT)

\mathbf{P}_q : 共分散行列 ($MT \times MT$)

K_q : \mathbf{c} によらない定数

$$\mathcal{N}(\mathbf{o} \mid \boldsymbol{\mu}_q, \boldsymbol{\Sigma}_q) = K_q \cdot \mathcal{N}(\mathbf{c} \mid \bar{\mathbf{c}}_q, \mathbf{P}_q)$$



$$\bar{\mathbf{c}}_q = \mathbf{P}_q \mathbf{r}_q \quad \mathbf{R}_q = \mathbf{W}^\top \boldsymbol{\Sigma}_q^{-1} \mathbf{W} = \mathbf{P}_q^{-1} \quad \mathbf{r}_q = \mathbf{W}^\top \boldsymbol{\Sigma}_q^{-1} \boldsymbol{\mu}_q$$

トラジェクトリHMMの定義

静的特徴系列 \mathbf{c} に対するトラジェクトリHMMの尤度

$$P(\mathbf{c} | \lambda) = \sum_{\text{all } \mathbf{q}} P(\mathbf{c} | \mathbf{q}, \lambda) P(\mathbf{q} | \lambda)$$

$$P(\mathbf{c} | \mathbf{q}, \lambda) = \mathcal{N}(\mathbf{c} | \bar{\mathbf{c}}_q, P_q) : \text{トラジェクトリ尤度}$$

平均ベクトル $\bar{\mathbf{c}}_q$ は滑らかに変化するトラジェクトリ

⇒ 状態内での時間依存性を表現可能

時間方向の共分散行列 P_q が全共分散

⇒ 出力ベクトルの時間依存性を表現可能

トラジェクトリHMMのパラメータ構造 = 通常のHMMのパラメータ構造

尤度の定義が異なる ⇒ 学習アルゴリズムも異なる

発表内容

HMMから導出されるトラジェクトリモデル

1. 静的特徴・動的特徴間の関係をHMMに導入
HMMをトラジェクトリモデルとして再定式化
2. Viterbi学習形式のパラメータ更新式の導出
3. 準最適状態系列選択アルゴリズムの提案
4. 連続音声認識実験による評価

トラジェクトリHMMの学習アルゴリズム

トラジェクトリHMMのQ関数（隠れ変数：状態遷移系列 q ）

$$Q(\lambda, \lambda') = \sum_{\text{all } q} P(\mathbf{q} \mid \mathbf{c}, \lambda) \log P(\mathbf{c}, \mathbf{q} \mid \lambda')$$

全ての状態系列に関する和を計算することは困難

⇒ 一本の状態系列による近似を導入

$q' = \arg \max_q \log P(\mathbf{c} \mid q, \lambda)$: 最適状態系列の探索

$\lambda' = \arg \max_{\lambda} \log P(\mathbf{c} \mid q', \lambda)$: パラメータの最適化

トラジェクトリHMMの学習アルゴリズム

対数トラジェクトリ尤度関数

$$\log P(\mathbf{c} | \mathbf{q}, \lambda) = -\frac{1}{2} \left\{ MT \log(2\pi) - \log |\mathbf{R}_q| \right. \\ \left. + \mathbf{c}^\top \mathbf{P}_q^{-1} \mathbf{c} + \mathbf{r}_q^\top \mathbf{P}_q \mathbf{r}_q - 2\mathbf{r}_q \mathbf{c}^\top \right\}$$

更新するパラメータ

$$\mathbf{m} = \left[\mu_1^\top, \mu_2^\top, \dots, \mu_N^\top \right]^\top$$

\mathbf{m} : 全状態の平均ベクトル

ϕ : 全状態の共分散行列

$$\phi = \left[\Sigma_1^{-1}, \Sigma_2^{-1}, \dots, \Sigma_N^{-1} \right]^\top$$

N : 総状態数

全モデルのパラメータを同時に更新

パラメータ更新式(平均)

対数トラジエクトリ尤度関数を m で偏微分して0とおくと

$$\begin{matrix} S_q^\top W P_q W^\top S_q & \Phi^{-1} & m & S_q^\top W c \\ \left(\begin{array}{c} 3NM \\ \text{対称正定値} \\ 3NM \end{array} \right) & \left(\begin{array}{c} 3NM \\ \text{対角} \\ 3NM \end{array} \right) & \left(\begin{array}{c} 3NM \end{array} \right) & = \left(\begin{array}{c} 3NM \end{array} \right) \end{matrix}$$

式中の各変数の意味は予稿を参照

線形方程式を解くことで m が一意に決定される

パラメータ更新式(分散)

対数トラジエクトリ尤度関数を ϕ で偏微分

$$\frac{\partial \log P(\mathbf{c}, \mathbf{q} \mid \lambda)}{\partial \phi} = \frac{1}{2} \mathbf{S}_q^\top \text{diag}^{-1} \left(\begin{aligned} & \mathbf{W} P_q \mathbf{W}^\top \\ & - \mathbf{W} \mathbf{c} \mathbf{c}^\top \mathbf{W}^\top + 2\mu_q \mathbf{c}^\top \mathbf{W}^\top \\ & + \mathbf{W} \bar{\mathbf{c}}_q \bar{\mathbf{c}}_q^\top \mathbf{W}^\top - 2\mu_q \bar{\mathbf{c}}_q^\top \mathbf{W}^\top \end{aligned} \right)$$

非線形方程式であるため容易には解けない

⇒ 上式を用いて最急降下法で更新

発表内容

HMMから導出されるトラジェクトリモデル

1. 静的特徴・動的特徴間の関係をHMMに導入
HMMをトラジェクトリモデルとして再定式化
2. Viterbi学習形式のパラメータ更新式の導出
3. 準最適状態系列選択アルゴリズムの提案
4. 連続音声認識実験による評価

トラジェクトリ尤度の計算

$$P(\mathbf{c} | \mathbf{q}, \lambda) = K_{\mathbf{q}}^{-1} \cdot P(\mathbf{o} | \mathbf{q}, \lambda)$$

$$K_{\mathbf{q}} = \frac{\sqrt{(2\pi)^{MT} |P_{\mathbf{q}}|}}{\sqrt{(2\pi)^{3MT} |\Sigma_{\mathbf{q}}|}} \cdot \exp \left\{ -\frac{1}{2} \left(\mu_{\mathbf{q}}^{\top} \Sigma_{\mathbf{q}}^{-1} \mu_{\mathbf{q}} - \mathbf{r}_{\mathbf{q}}^{\top} P_{\mathbf{q}} \mathbf{r}_{\mathbf{q}} \right) \right\}$$

トラジェクトリ尤度 = 正規化定数 $K_{\mathbf{q}}$ × HMMの尤度

トラジェクトリ尤度を直接計算 ⇒ 高次元の線形演算が必要

トラジェクトリ尤度を時間方向に再帰的に計算したい

⇒ $|P_{\mathbf{q}}|$ と $\mathbf{r}_{\mathbf{q}}^{\top} P_{\mathbf{q}} \mathbf{r}_{\mathbf{q}}$ を時間方向に再帰的に計算

トラジェクトリ尤度の再帰計算

$$P(\mathbf{c} | \mathbf{q}, \lambda) = \prod_{t=1}^T \frac{1}{K_{\mathbf{q}_{t+L}}^{(t)}} \cdot P(\mathbf{o}_t | \mathbf{q}_t, \lambda)$$

$$K_{\mathbf{q}_{t+L}}^{(t)} = \frac{\sqrt{(2\pi)^M} |\mathbf{U}_{\mathbf{q}_{t+L}}^{(t,t)}|^{-1}}{\sqrt{(2\pi)^{3M} |\boldsymbol{\Sigma}_{\mathbf{q}_t}|}} \cdot \exp \left\{ -\frac{1}{2} \left(\boldsymbol{\mu}_{\mathbf{q}_t}^\top \boldsymbol{\Sigma}_{\mathbf{q}_t}^{-1} \boldsymbol{\mu}_{\mathbf{q}_t} - \left[\mathbf{g}_{\mathbf{q}_{t+L}}^{(t)} \right]^\top \mathbf{g}_{\mathbf{q}_{t+L}}^{(t)} \right) \right\}$$

時間方向に再帰的に計算可能！

$\mathbf{U}_q \Rightarrow \mathbf{R}_q = \mathbf{U}_q^\top \mathbf{U}_q$: コレスキー分解より得られる上三角行列

$\mathbf{g}_q \Rightarrow \mathbf{R}_q \bar{\mathbf{c}}_q = \mathbf{r}_q \quad \mathbf{U}_q^\top \mathbf{U}_q \bar{\mathbf{c}}_q = \mathbf{r}_q$

$\mathbf{U}_q \bar{\mathbf{c}}_q = \mathbf{g}_q$: 前進代入より得られるベクトル

トラジェクトリHMMのためのViterbiアルゴリズム

トラジェクトリHMM


- ・ 各時刻の出力ベクトル間に依存関係 (P_q が全共分散)
- ・ マルコフ過程でない (∞ 重マルコフ過程)
- ・ 最適状態系列の探索 \Rightarrow 全探索

提案法

- ・ J 重マルコフ過程で近似
- ・ Viterbiアルゴリズムにより準最適状態系列を選択

トラジェクトリHMMのためのViterbiアルゴリズム


(例) 前後1フレームから動的特徴を計算 ($L=1$)
2重マルコフモデルの決定過程で近似 ($J=2$)



- 2フレーム前までの状態系列は既に決定
 - 動的特徴計算の窓が前後1フレームにかかる
- ⇒ 1フレームの先読みが必要

トラジェクトリHMMのためのViterbiアルゴリズム

(例) 前後1フレームから動的特徴を計算 ($L=1$)
2重マルコフモデルの決定過程で近似 ($J=2$)




○ ・ 2^{J+L} 個のパスについて

トラジェクトリ尤度を計算

トラジェクトリHMMのためのViterbiアルゴリズム

(例) 前後1フレームから動的特徴を計算 ($L=1$)
2重マルコフモデルの決定過程で近似 ($J=2$)



J フレーム遅れて
滞在する状態を決定
⇒ 近傍に与える影響を
考慮して状態を決定

調音結合の影響：
100ms~200ms

⇒ J を10程度とれば十分
(フレーム周期が10msの場合)

発表内容

HMMから導出されるトラジェクトリモデル

1. 静的特徴・動的特徴間の関係をHMMに導入
→ HMMをトラジェクトリモデルとして再定式化
2. Viterbi学習形式のパラメータ更新式の導出
3. 準最適状態系列選択アルゴリズムの提案
4. 連続音声認識実験による評価

実験条件

学習データ	ATR日本語連続音声データベース B-set 男性話者 MHT 503文章中の450文章
評価データ	同一話者 学習データに含まれない53文章
周波数	16 kHz
分析窓	25-ms Blackman窓
フレーム周期	10-ms
分析方法	18次メルケプストラム分析
動的特徴	前後1フレームから回帰係数として計算
特徴ベクトル	$c(0) \sim c(18)$, $\Delta c(0) \sim \Delta c(18)$, $\Delta\Delta c(0) \sim \Delta\Delta c(18)$
トポロジー	3状態 スキップのないleft-to-right モデル 混合数 1 コンテキスト非依存


学習結果

学習データ及び評価データに対する
フレーム平均対数トラジェクトリ尤度

	training data	test data
standard-HMM	6.87	6.93
trajectory-HMM	15.0	15.1

導出されたパラメータ更新式により
トラジェクトリ尤度が増加

平均系列の例




実発声（学習データ） —

通常のHMMの平均系列 —

通常のHMMの平均系列 → 時間的に不連続

平均系列の例




実発声（学習データ） — 通常のHMMより生成された系列 —
通常のHMMの平均系列 —

通常のHMMの平均系列 → 時間的に不連続

通常のHMMより生成された系列 → 時間的に滑らかに変化

平均系列の例



実発声（学習データ） — 通常のHMMより生成された系列 —
通常のHMMの平均系列 — トラジェクトリHMMの平均系列 —

通常のHMMの平均系列 → 時間的に不連続

通常のHMMより生成された系列 → 時間的に滑らかに変化

トラジェクトリHMMの平均系列 → 時間的に滑らかに変化

より実発声に近い平均系列

認識実験結果

通常のHMMを用いて上位200個の仮説を出力
トラジェクトリ尤度でリスコア

	%Err.	#Corr.	#Del.	#Sub.	#Ins.	#Total
standard-HMM	20.1	1855	119	200	119	2174
trajectory-HMM	17.2	1903	118	153	103	2174

誤り削減率 約15%

まとめ


HMMよりトラジェクトリモデルを導出

- ・ 静的特徴と動的特徴間の関係をHMMに導入
→ トラジェクトリモデルとして再定式化
- ・ Viterbi学習形式の学習アルゴリズムを提案
- ・ 連続音声認識実験により有効性を確認

今後の予定

- ・ Baum-Welch (EM) 型学習アルゴリズムの導出
- ・ Viterbiデコーダの実装
- ・ より大規模な評価実験
- ・ HMM音声合成への適用

選択された状態系列の尤度



$J \rightarrow$ 大 \Rightarrow トラジェクトリ尤度が高い状態系列を選択

$J=6$ 程度でほぼ収束