

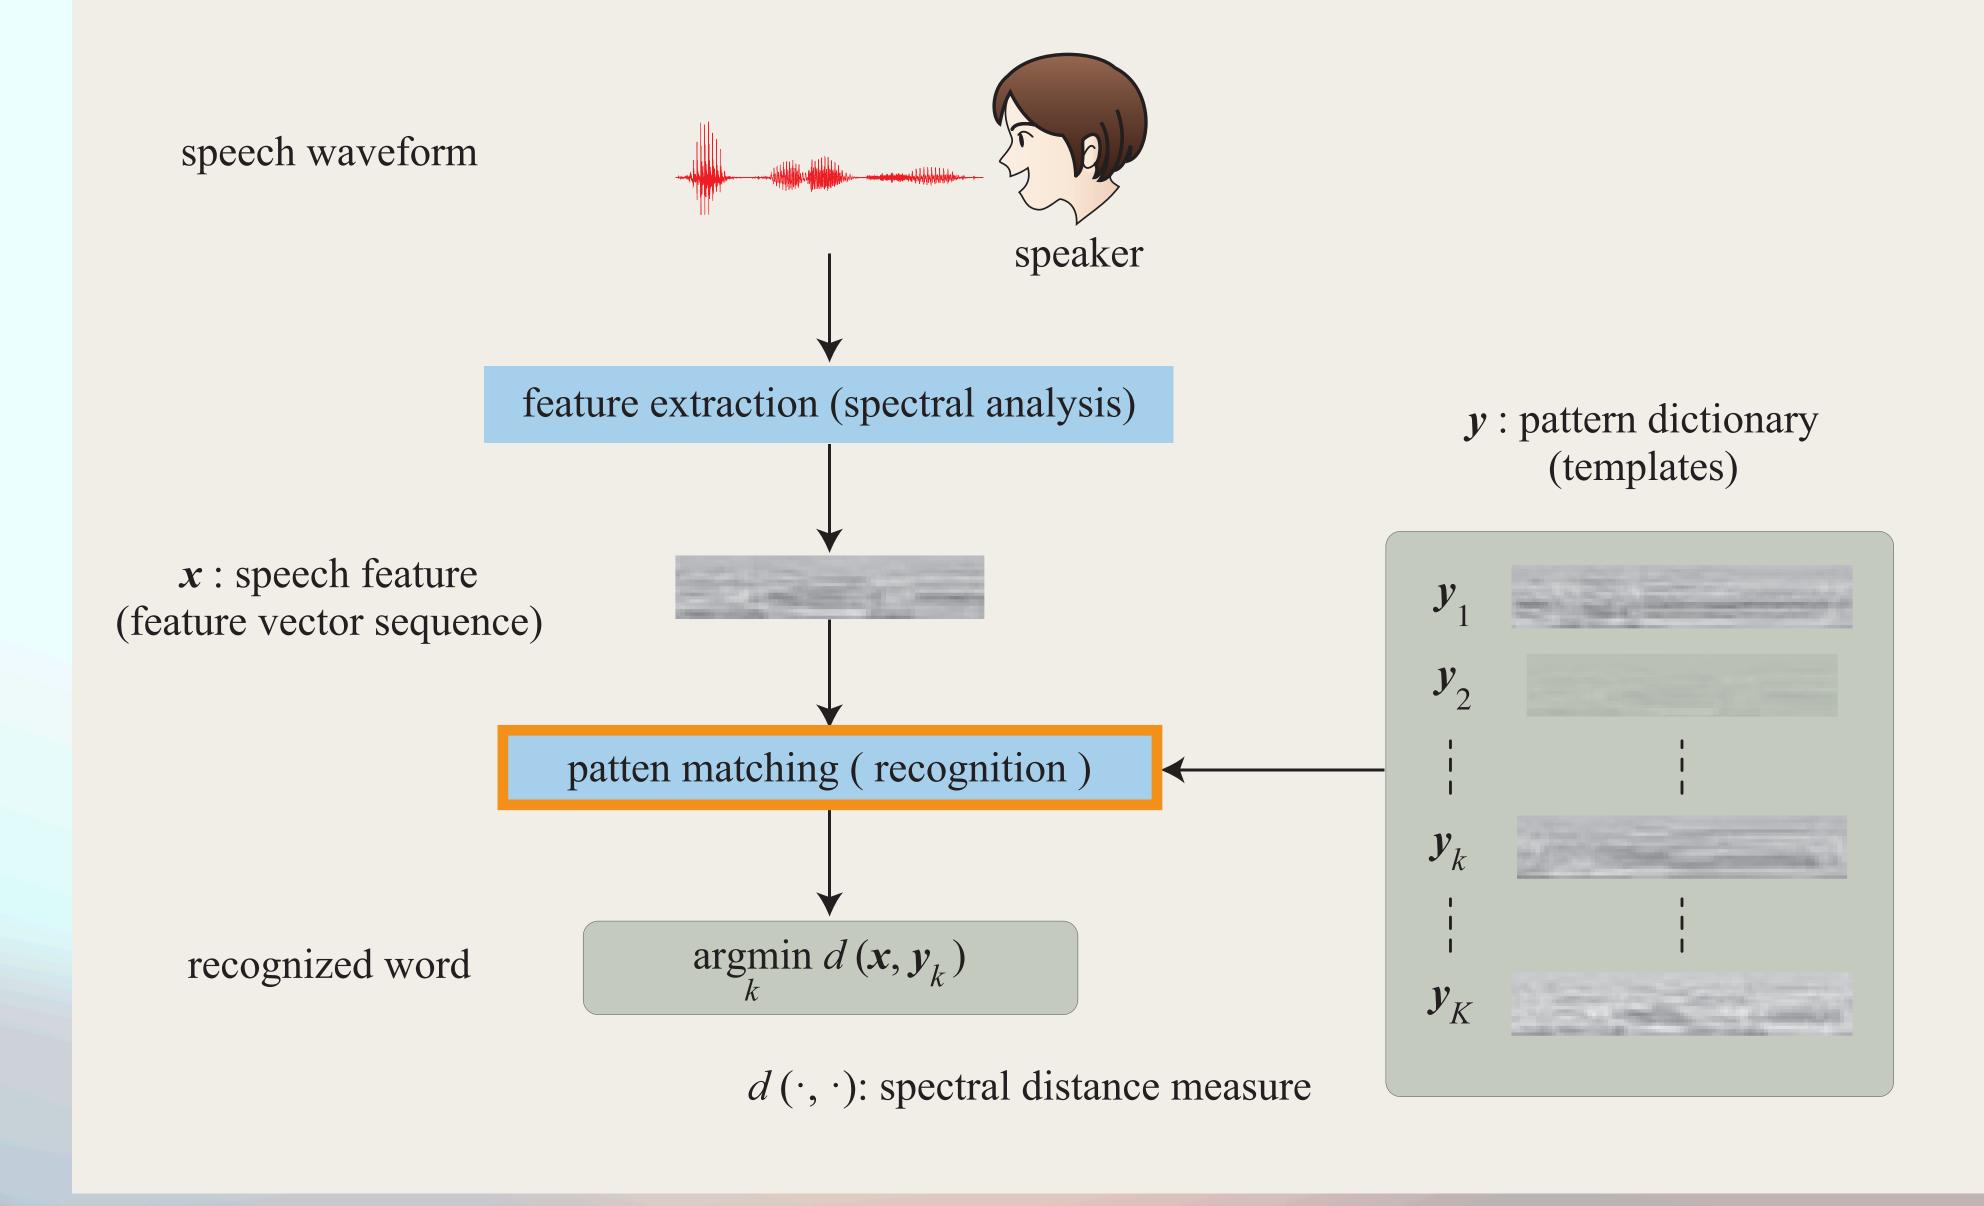
メディア情報学実験
メディア情報検索・認識実験(音声)

日個人算法

Hidden Markov Model Algorithms

出席カードに学籍番号と氏名を記入し、2限の時間中に前方の箱に提出してください。





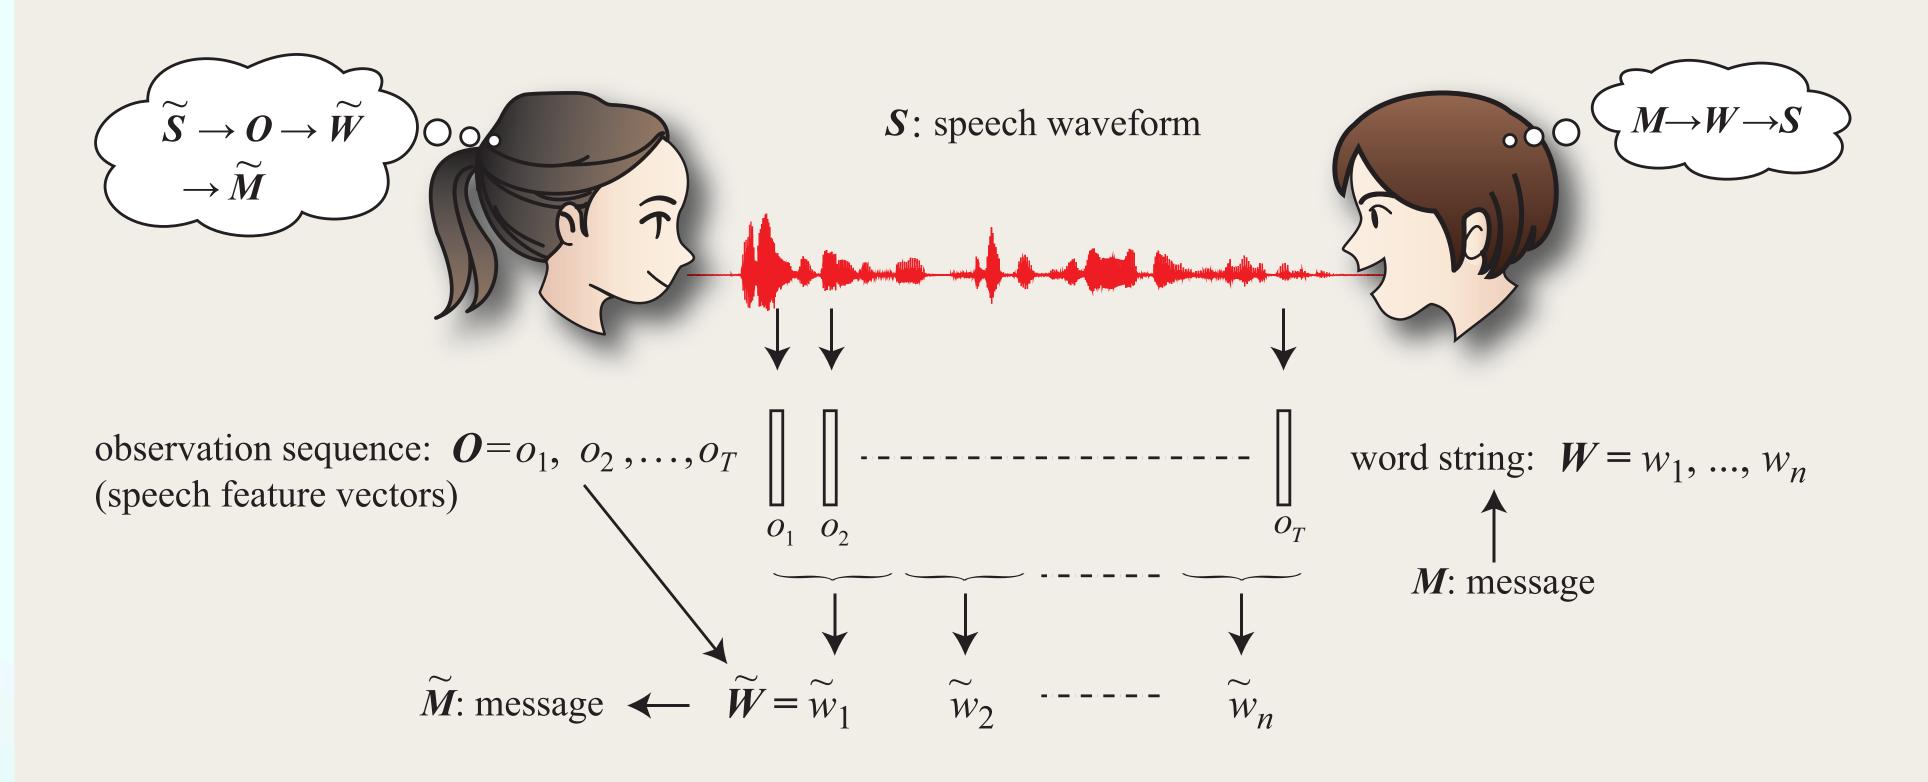
古典的な音声認識の pattern matchingでは「統計的音声認識」の枠組みにおいて隠れマルコフモデル(Hidden Markov Model: HMM)を利用する。



統計的音声認識

STATISTICAL SPEECH RECOGNITION





acoustic model language model conditional probability of W given $O: P(W|O) = \frac{P(O|W) \ P(W)}{P(O)}$

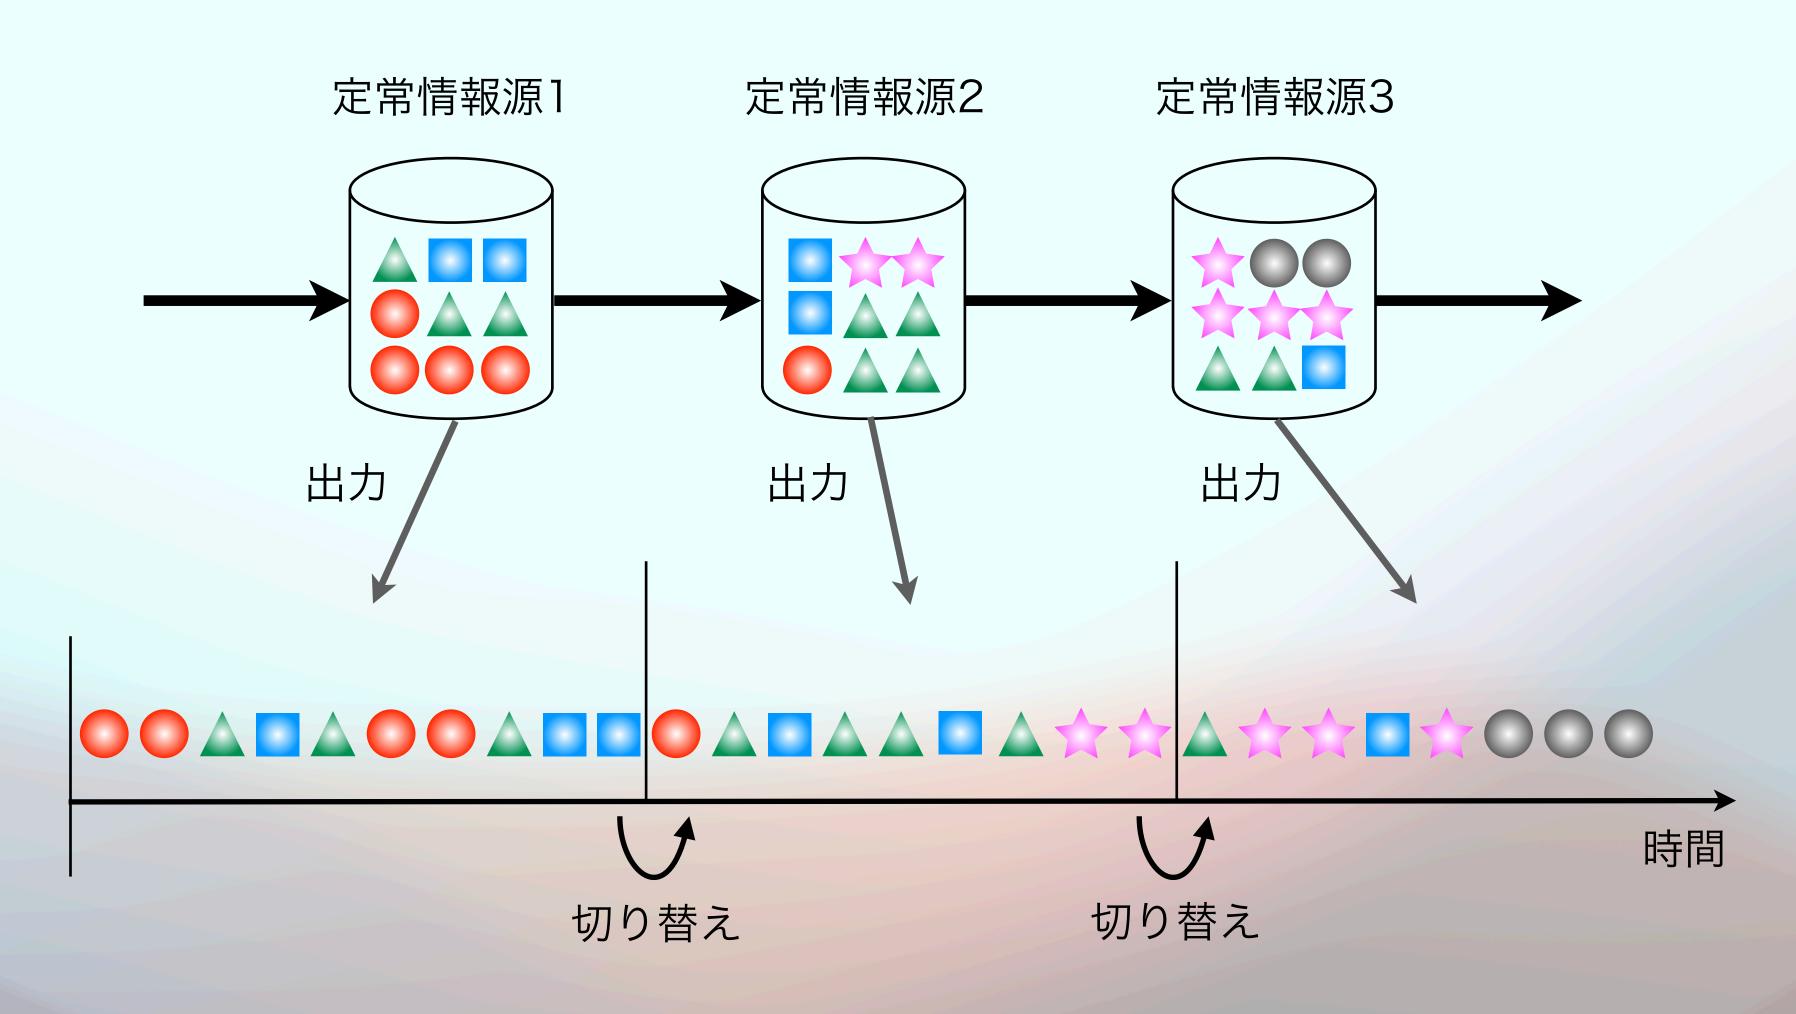
recognized word string: $\widetilde{W} = \underset{W}{\operatorname{argmax}} P(W|O)$

音声認識とは音声信号 S から単語列 W を推定すること。 特徴量時系列 O が与えられた条件で単語列 W が生成する条件付き確率を評価。



非定常信号源のモデル

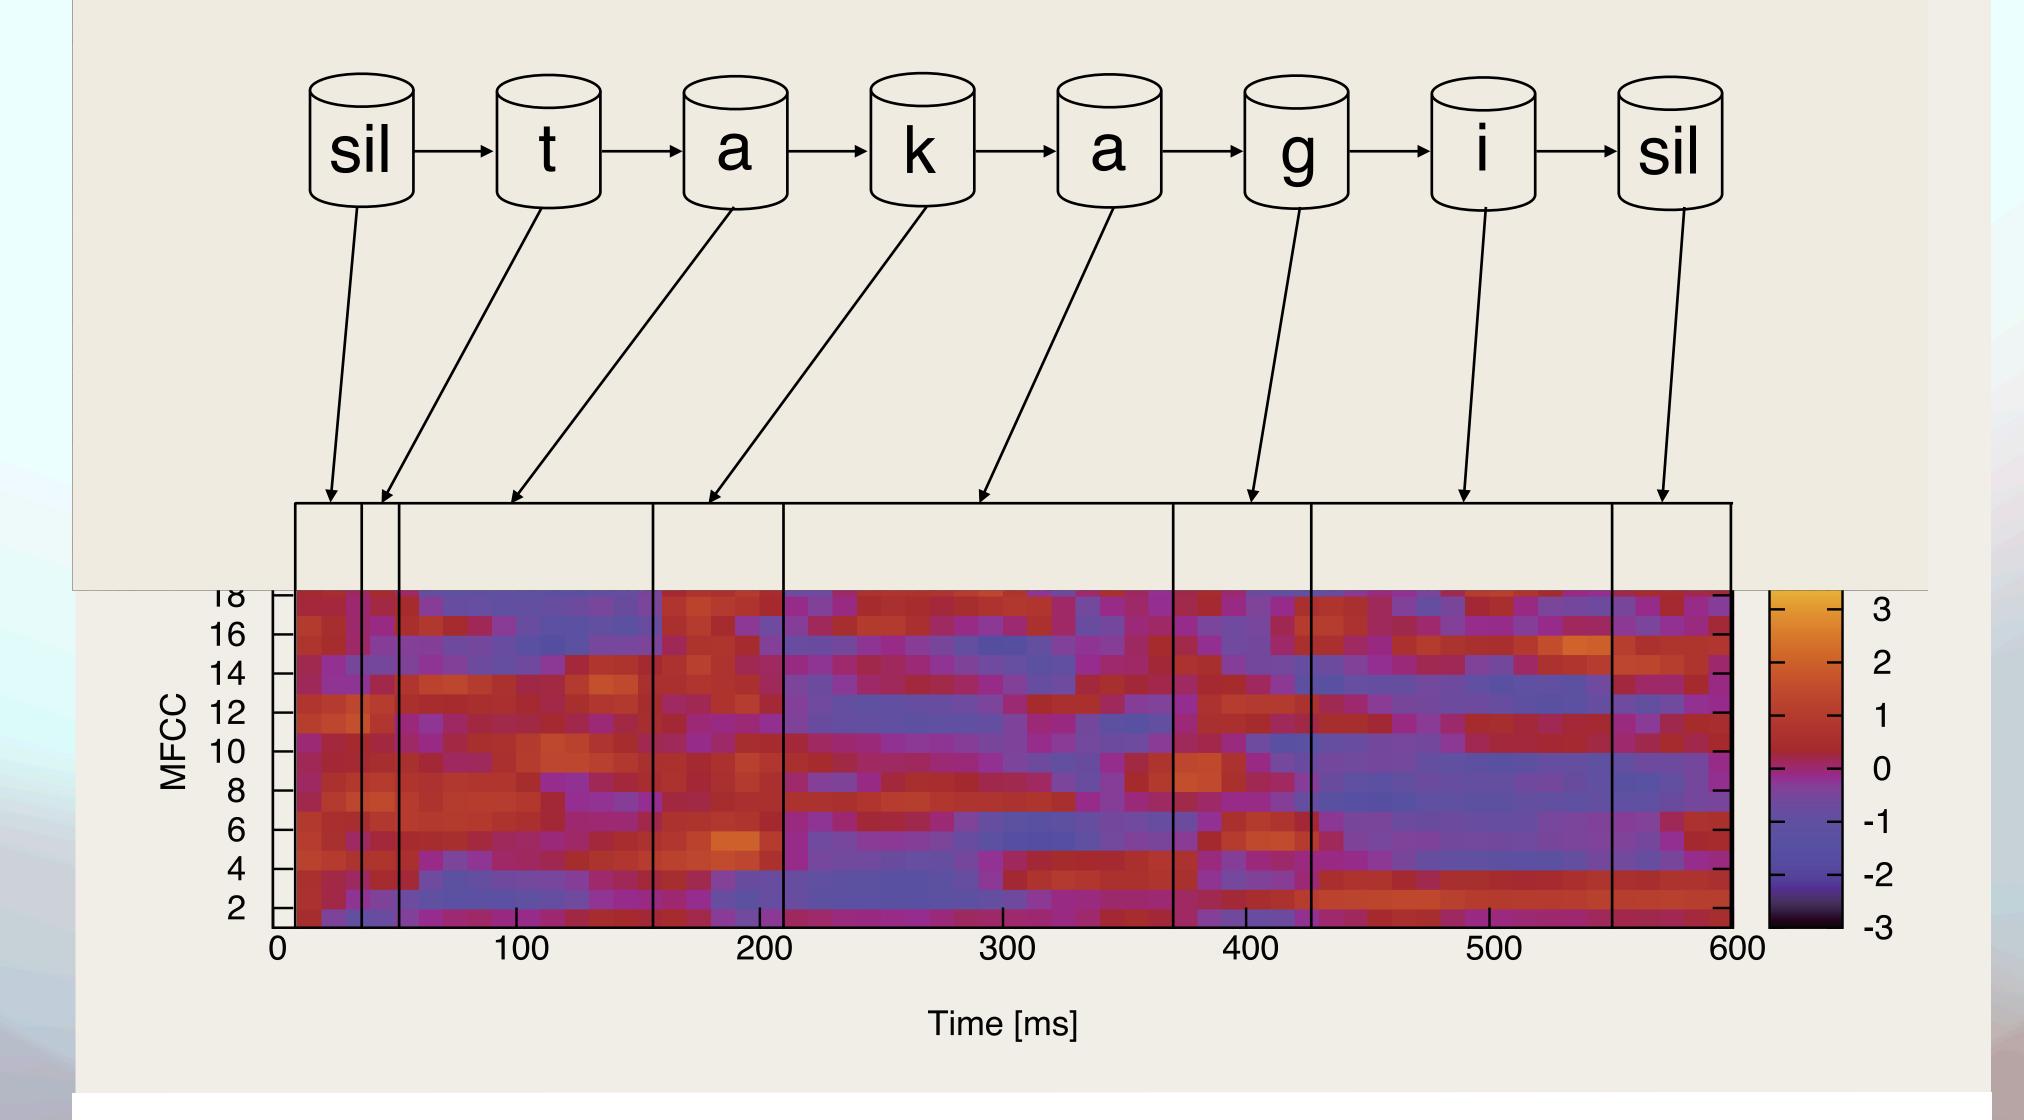
異なる定常情報源を次々に切り替える



音素(定常情報源)が発音順に並び(切り替わり)言語音となる。



音声のスペクトル分布の変化のモデル

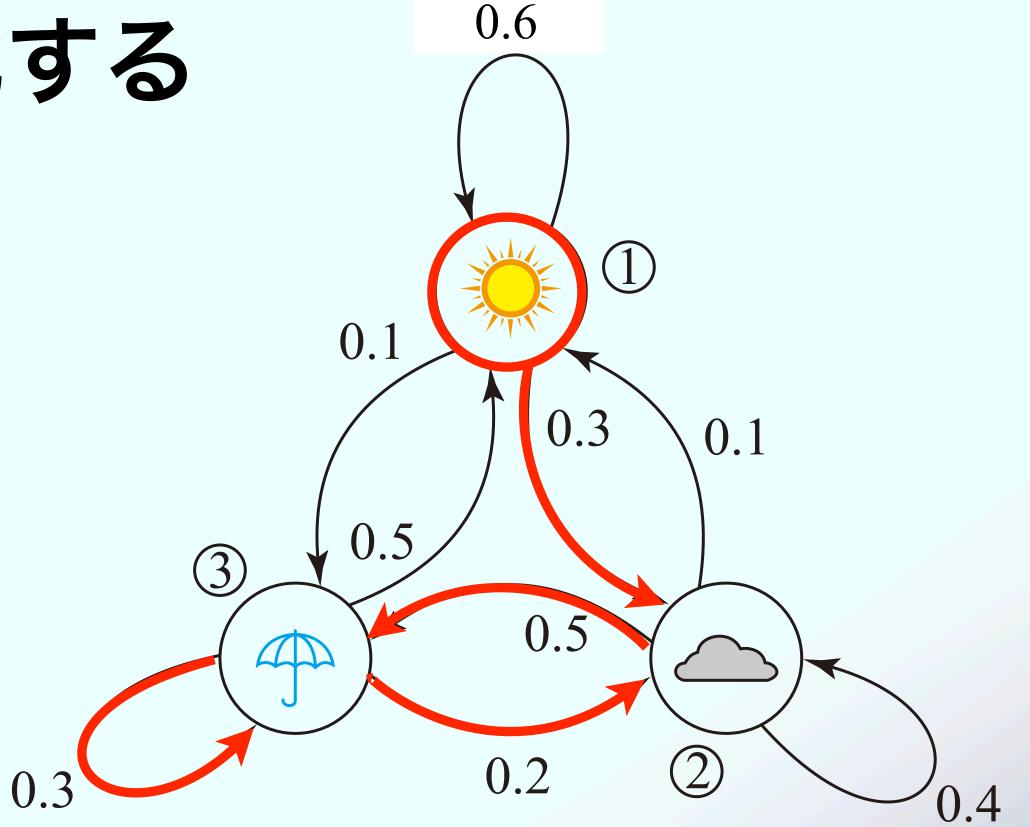


定常情報源は一定の分布の多次元実数ベクトル。単語の前後の sil は無音声。



天気変化をモデル化する

単純(一重)マルコフモデル

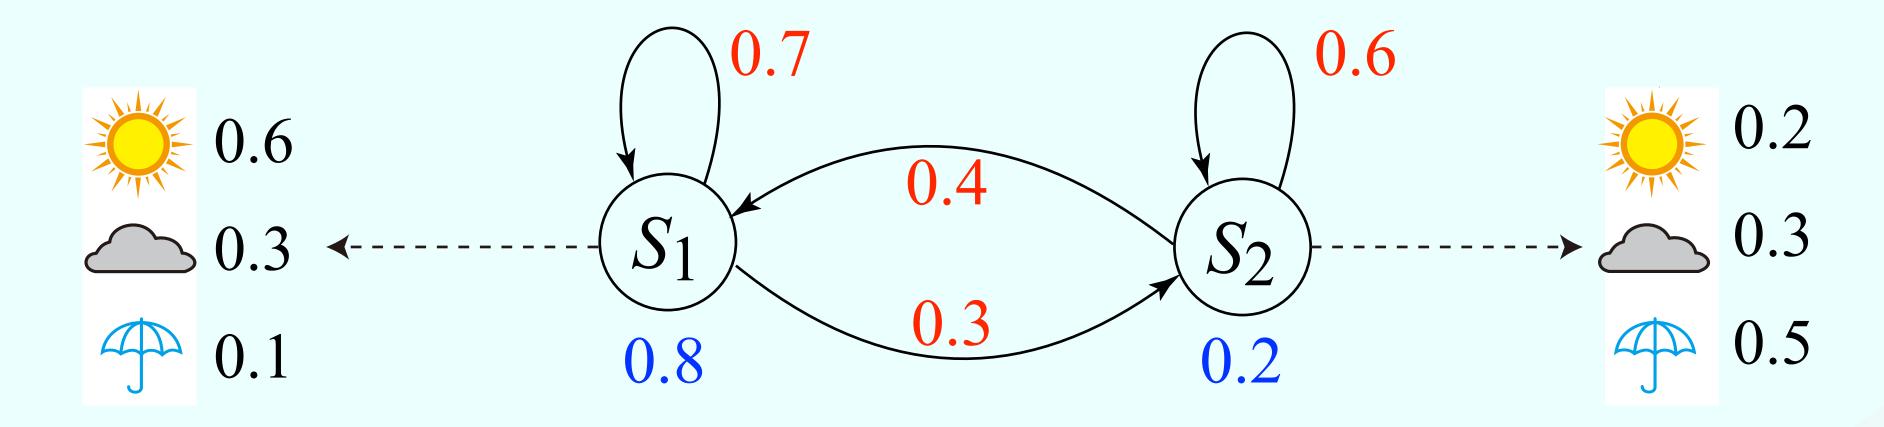


$$P(\bigcirc \rightarrow \bigcirc \rightarrow \bigcirc \rightarrow \bigcirc \rightarrow \bigcirc \rightarrow \bigcirc)$$

= 0.3×0.5×0.3×0.2
= 0.009

天気の確率を計算:遷移確率の積



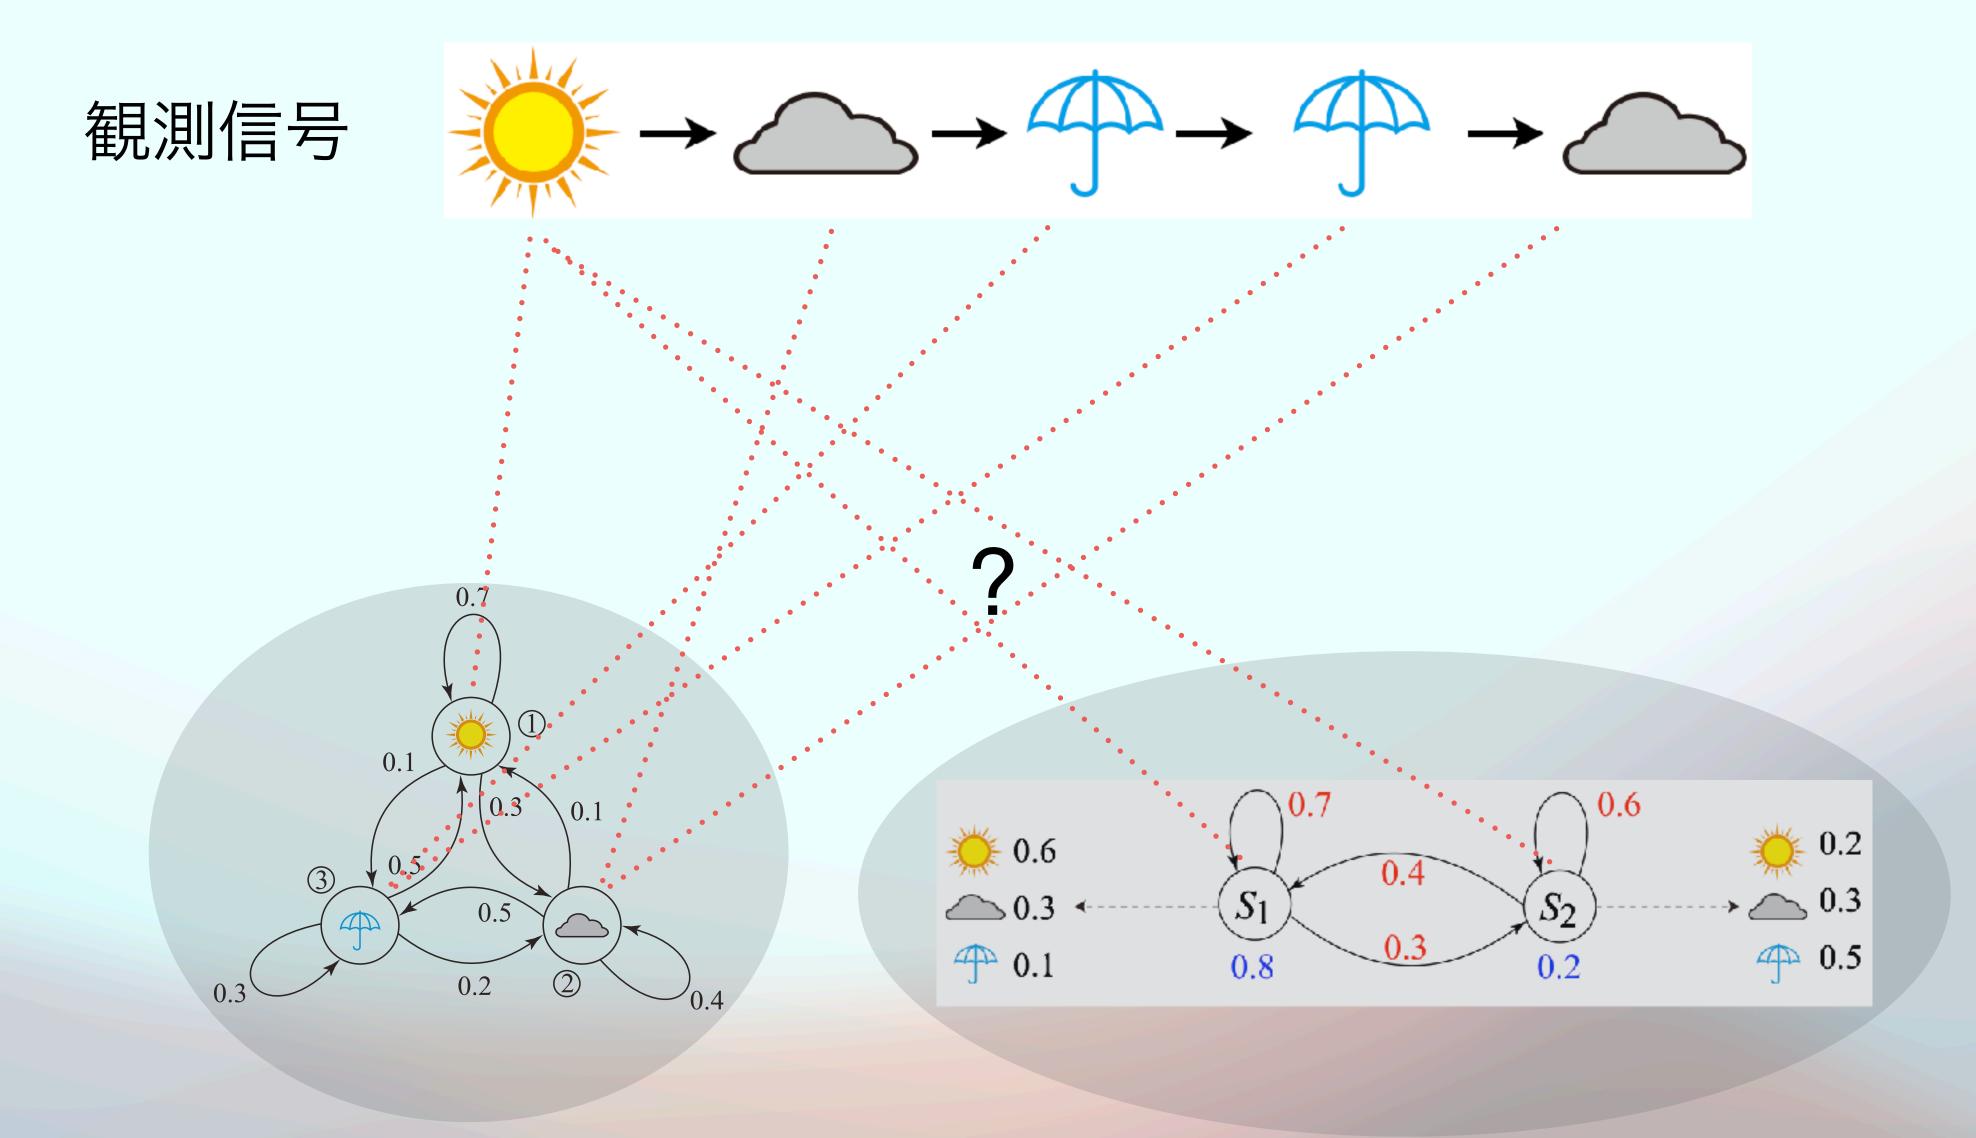


天気の隠れマルコフモデル:状態と天気は確率的に対応。

$$P(\longrightarrow \longrightarrow \longrightarrow \longrightarrow \longrightarrow)$$
= 0.8×0.6×0.7×0.3×0.3×0.5×0.6×0.5×0.4×0.3
$$S1 \qquad S1 \qquad S2 \qquad S2 \qquad S1$$
+0.2×0.2×0.4×0.3×0.3×0.5×0.4×0.1×0.3×0.3
$$S2 \qquad S1 \qquad S2 \qquad S1 \qquad S2$$

状態遷移は複数の可能性があり一意に定まらない

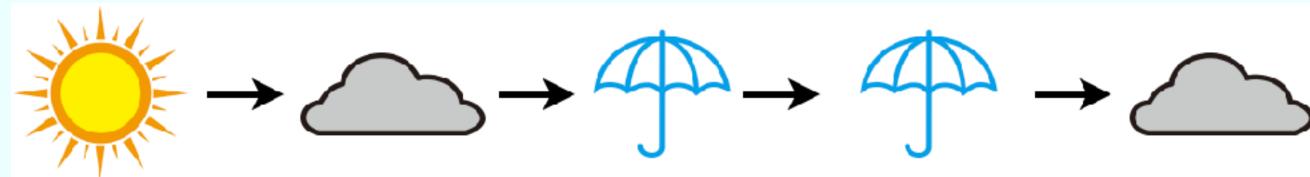




マルコフモデル 観測信号から内部状態が一意に定まる 隠れマルコフモデル **観測信号から内部状態が一意に定まらない** (隠れている)



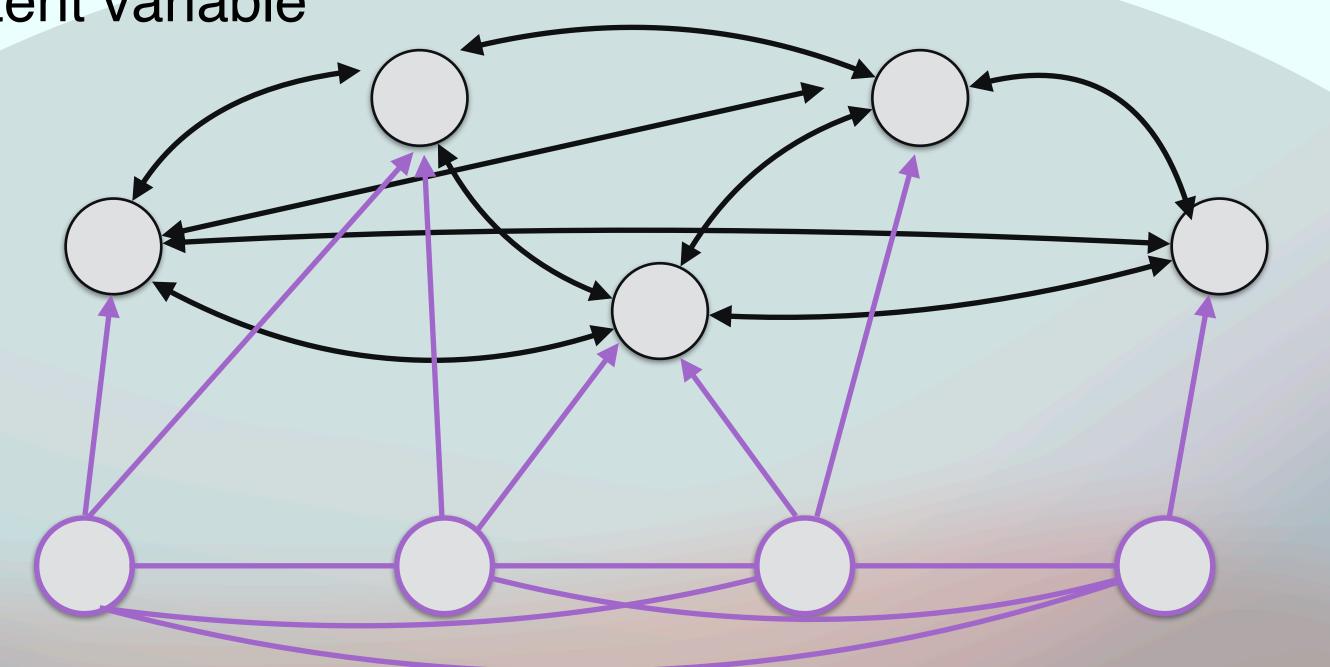
観測信号





隠れ変数 hidden variable

潜在変数 latent variable



現象の背後にある要因を仮定し、それを隠れ/潜在変数として表す。 e.g. 別の地方の天気、海水温、地球規模の大気の状態



HMMの定式化

N:モデルλの状態数

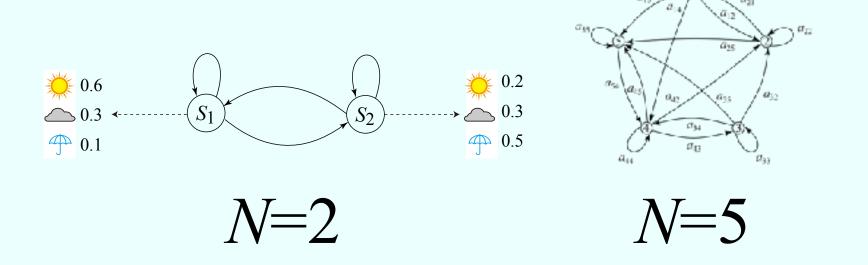
M: 出力シンボル種類数

A:状態遷移確率

B:シンボル出力確率

π:初期状態確率

$$\pi = {\pi i} = (0.8 \ 0.2)$$





HMM
$$\lambda = (N, M, A, B, \pi)$$

$$\lambda = (A, B, \pi)$$
0.2
0.3
0.5

$$A = \{aij\} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} = \begin{pmatrix} 0.7 & 0.3 \\ 0.4 & 0.6 \end{pmatrix}$$

$$\mathbf{B} = \{b_i(k)\} = \begin{pmatrix} b_1(0) & b_1(0) & b_1(0) \\ b_2(0) & b_2(0) & b_2(0) \end{pmatrix} = \begin{pmatrix} 0.6 & 0.3 & 0.1 \\ 0.2 & 0.3 & 0.5 \end{pmatrix}$$





HMMを使ってパターン認識

認識

観測系列 $O=o_1, o_2, ..., o_T$ とモデル λ が与えられたとき $P(O|\lambda)$ を効率的に計算する

学習

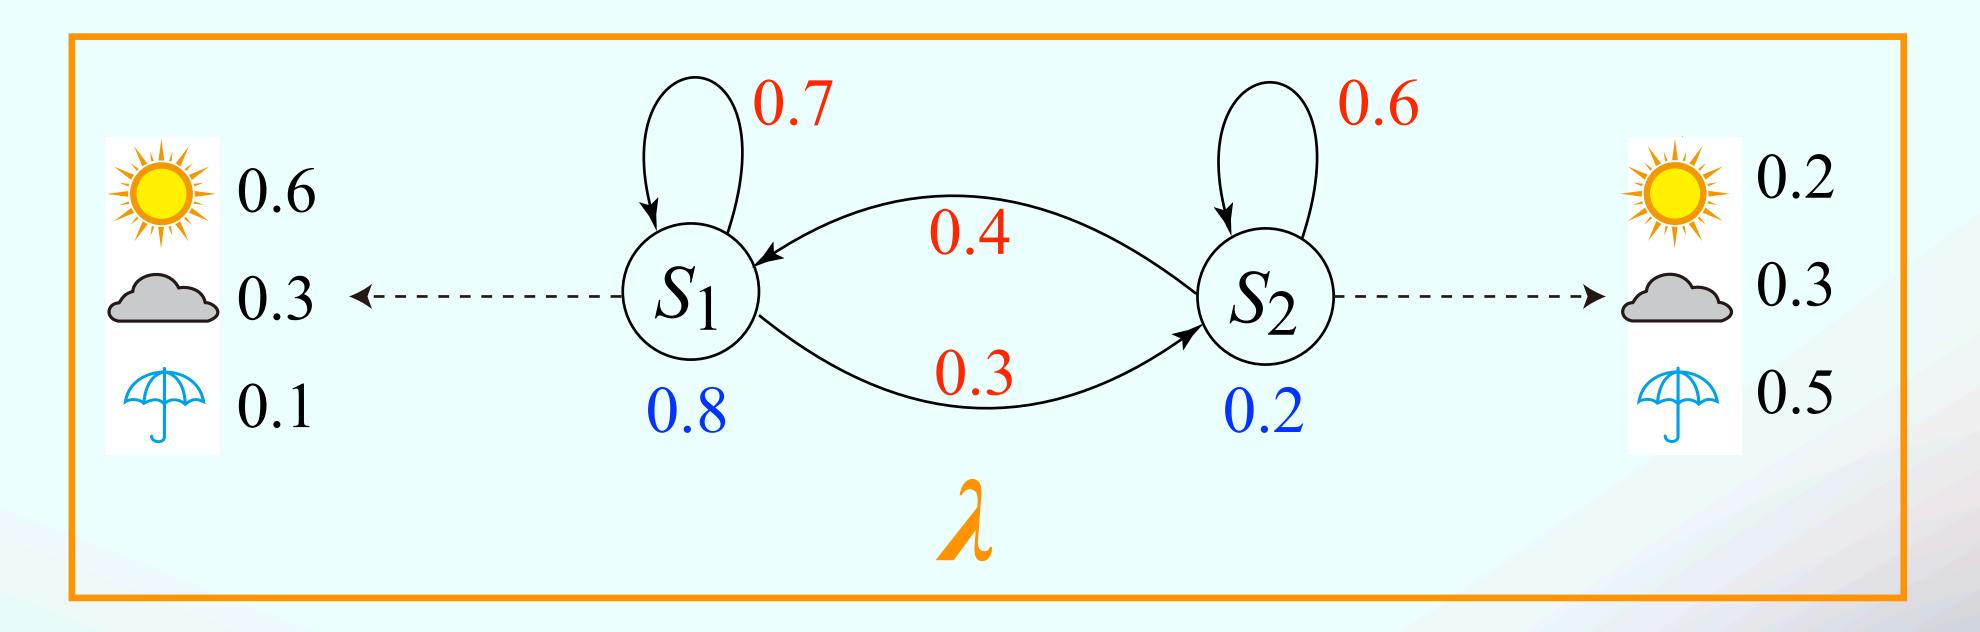
観測系列 $O=o_1, o_2, ..., o_T$ に対して $P(O|\lambda)$ を最大化するモデル λ を求める

観測系列0から状態系列0が一意に定まらないため、計算に工夫が必要。

状態系列 $Q = q_1 q_2 q_3 \dots q_T$



天気モデルの0とん





認識

観測系列 $O=o_1, o_2, ..., o_T$ とモデル λ が与えられたとき $P(O|\lambda)$ を効率的に計算する



長さTの全ての状態系列 $Q = q_1, q_2, ..., q_T$ を枚挙し、 各状態系列に関する確率を累積してみると…

状態 q_1 の初期状態確率 状態 q_1 で観測記号 O_1 を出力する確率

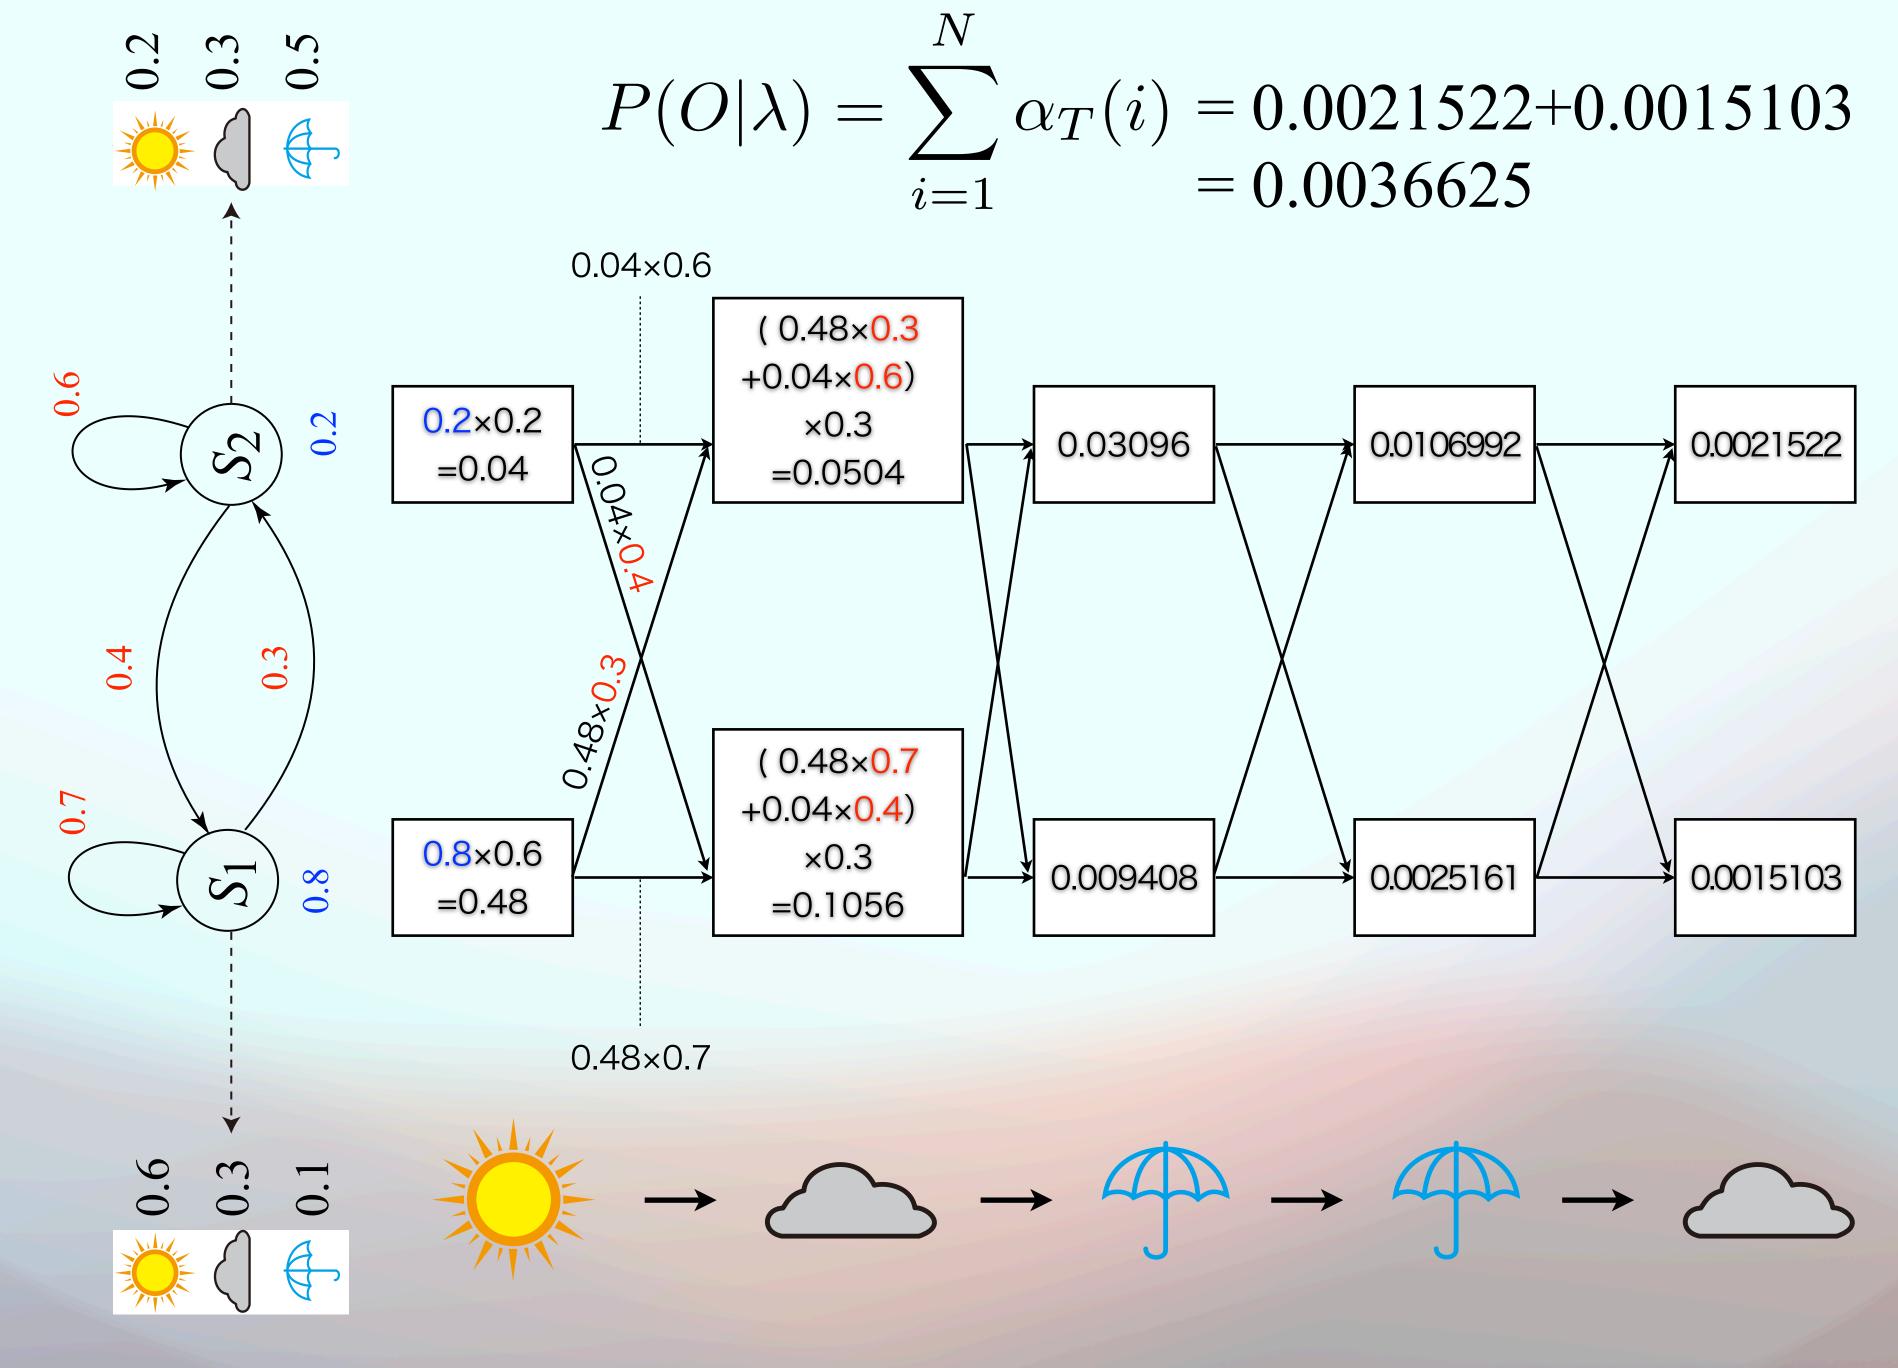
$$P(O|\lambda) = \sum_{\substack{\pi_{q_1} b_{q_1}(o_1) a_{q_1 q_2} b_{q_2}(o_2) \cdots a_{q_{T-1} q_T} b_{q_T}(o_T)} \pi_{q_1} b_{q_1}(o_1) a_{q_1 q_2} b_{q_2}(o_2) \cdots a_{q_{T-1} q_T} b_{q_T}(o_T)$$
(5.3)

長さTの全ての状態系列 $oldsymbol{Q}$

状態系列
$$Q = q_1, q_2, ..., q_T$$
 の総数= N^T $N=3$, $T=50$ 各 Q について乗算 $(2T-1)N^T$ 回、 7.2×10^{23} 加算 N^T-1 回。

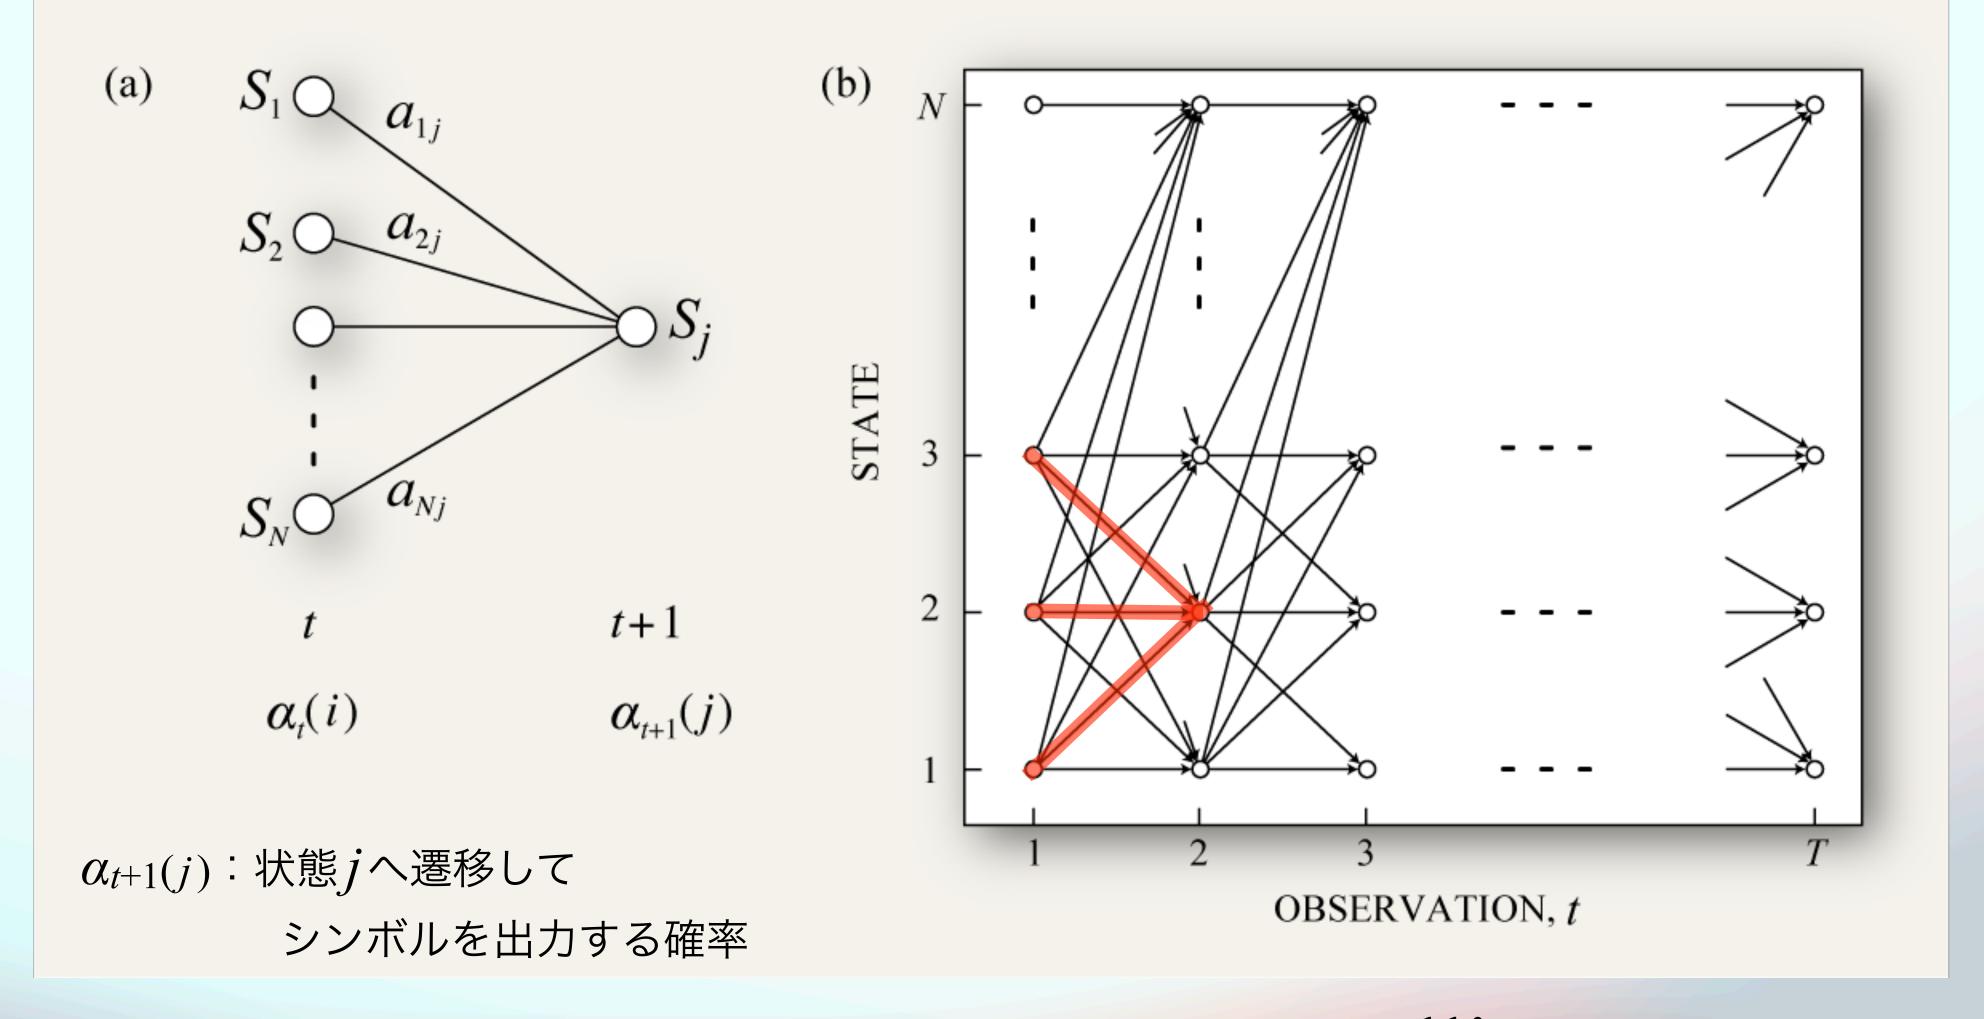
この例は3状態のHMMで0.5秒の音声の確率を計算することに相当...非現実的な計算量





動的計画法(部分問題の計算結果を記録しながら解いていく手法)で計算。





$$N=3, T=50$$

 $7.2\times10^{23} \longrightarrow 885$

trellis

- ・トレリス計算という。
- 動的計画法で計算量は1021分の1に



前向きパスアルゴリズム Forward Algorithm

1) 初期化

$$\alpha_1(i) = \pi_i b_i(\boldsymbol{o}_1), \quad 1 \le i \le N. \tag{5.5}$$

時刻1の状態iの前向き確率 $\alpha_1(i)$ は状態iの初期状態確率とシンボルo1の出力確率の積

2) 帰納

$$\alpha_{t+1}(j) =$$

$$\begin{bmatrix} \sum_{i=1}^{N} \alpha_t(i) a_{ij} \end{bmatrix} b_j(\boldsymbol{o}_{t+1}), \quad 1 \leq t \leq T-1, \quad 1 \leq j \leq N. \quad (5.6)$$
時刻 $t+1$ の状態 j でシンボル \boldsymbol{o}_{t+1} を出力する確率

時刻 tの状態 iから時刻 t+1の状態 jへの遷移に伴う前向き確率 $lpha_t(i)$ の積和

3) 停止

$$P(\mathbf{O}|\lambda) = \sum_{i=1}^{N} \alpha_T(i). \tag{5.7}$$

最終時刻 Tの前向き確率 $\alpha_T(i)$ の和が $P(O \mid \lambda)$ である。

 α を前向き確率という。(1) 初期化の後、状態jと時刻tを進めながら式 (5.6) によって前向き確率 α の積和の累積を進め、最終時刻Tの α の和を計算。



後ろ向きパスアルゴリズム Backward Algorithm

1) 初期化

$$\beta_T(i) = 1, \quad 1 \le i \le N. \tag{5.8}$$

2) 帰納

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(\mathbf{o}_{t+1}) \beta_{t+1}(j), \quad t = T - 1, T - 2, \dots, 1, \quad 1 \le i \le N.$$
(5.9)

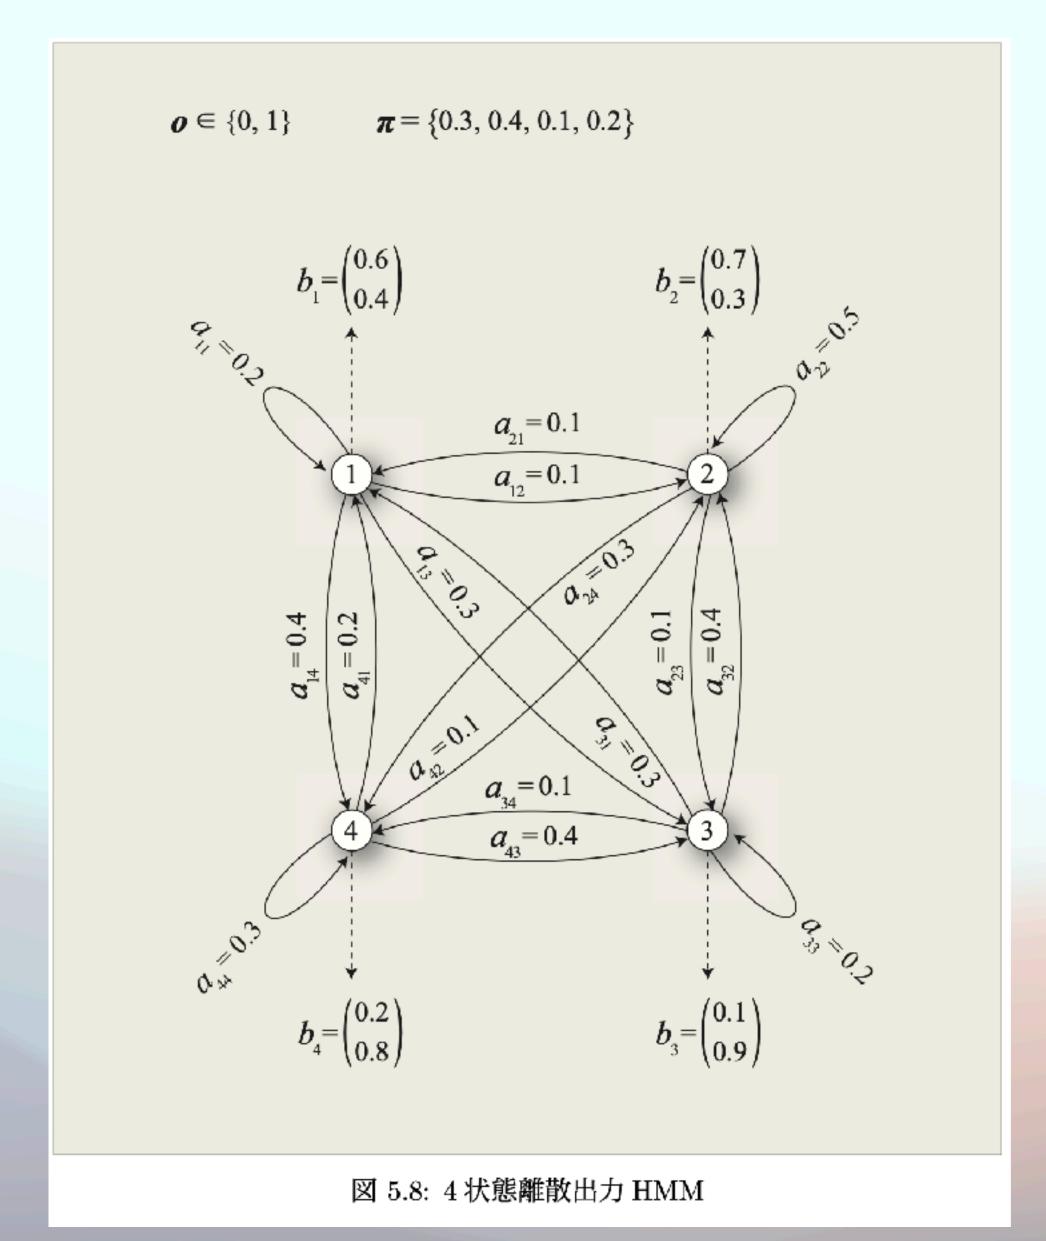
3) 停止

$$P(\mathbf{O}|\lambda) = \sum_{i=1}^{N} \pi_i b_i(\mathbf{o}_1) \beta_1(i).$$
 (5.10)

 β を後ろ向き確率という。(1) 初期化の後、状態jと時刻tを進めながら式 (5.9) によって後ろ向き確率 β の積和の累積を進め、最終時刻Tの α の和を計算。



実習5.6.3 p.5-15~18 Forward・Backwardアルゴリズム



$$\boldsymbol{A} = \begin{pmatrix} 0.2 & 0.1 & 0.3 & 0.4 \\ 0.1 & 0.5 & 0.1 & 0.3 \\ 0.3 & 0.4 & 0.2 & 0.1 \\ 0.2 & 0.1 & 0.4 & 0.3 \end{pmatrix}, \tag{5.44}$$

$$\boldsymbol{B} = \begin{pmatrix} 0.6 & 0.4 \\ 0.7 & 0.3 \\ 0.1 & 0.9 \\ 0.2 & 0.8 \end{pmatrix}, \tag{5.45}$$

 $\pi = \{0.3, 0.4, 0.1, 0.2\}$

観測系列 0=0110 に対する確率を

・Forwardアルゴリズム ・Backwardアルゴリズム を用いて計算(各状態・時刻の確率も表示)

穴埋め課題

- ~/asr/drill/forward.c
- ~/asr/drill/backward.c



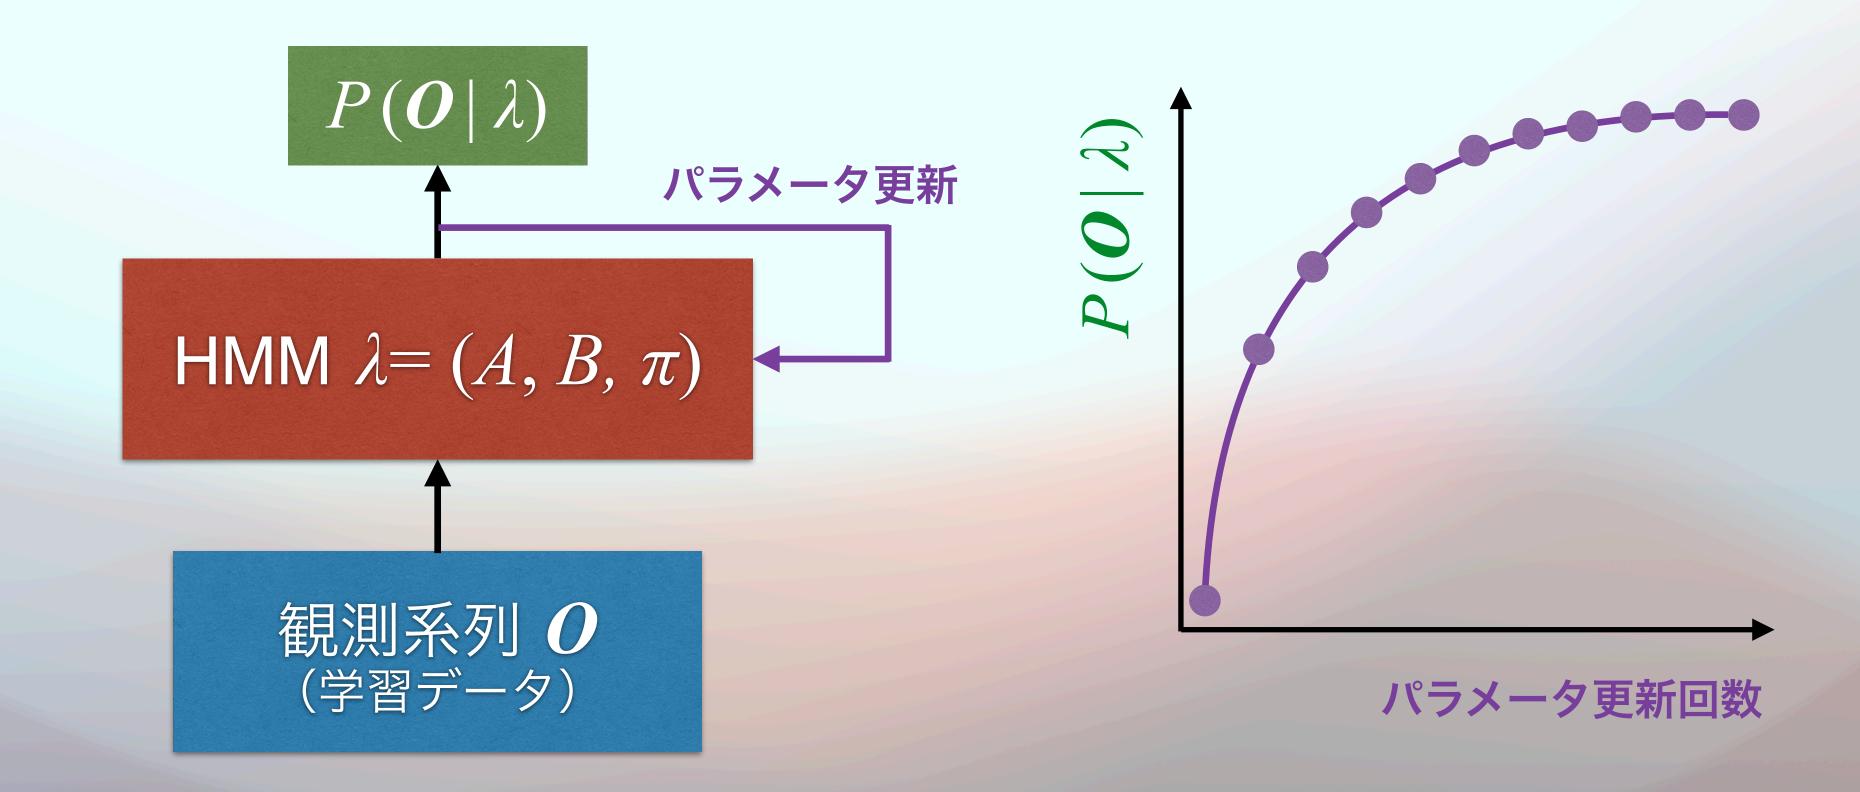
学習

観測系列 $O=o_1, o_2, ..., o_T$ に対して

 $P(O|\lambda)$ を最大化するモデル λ を求める

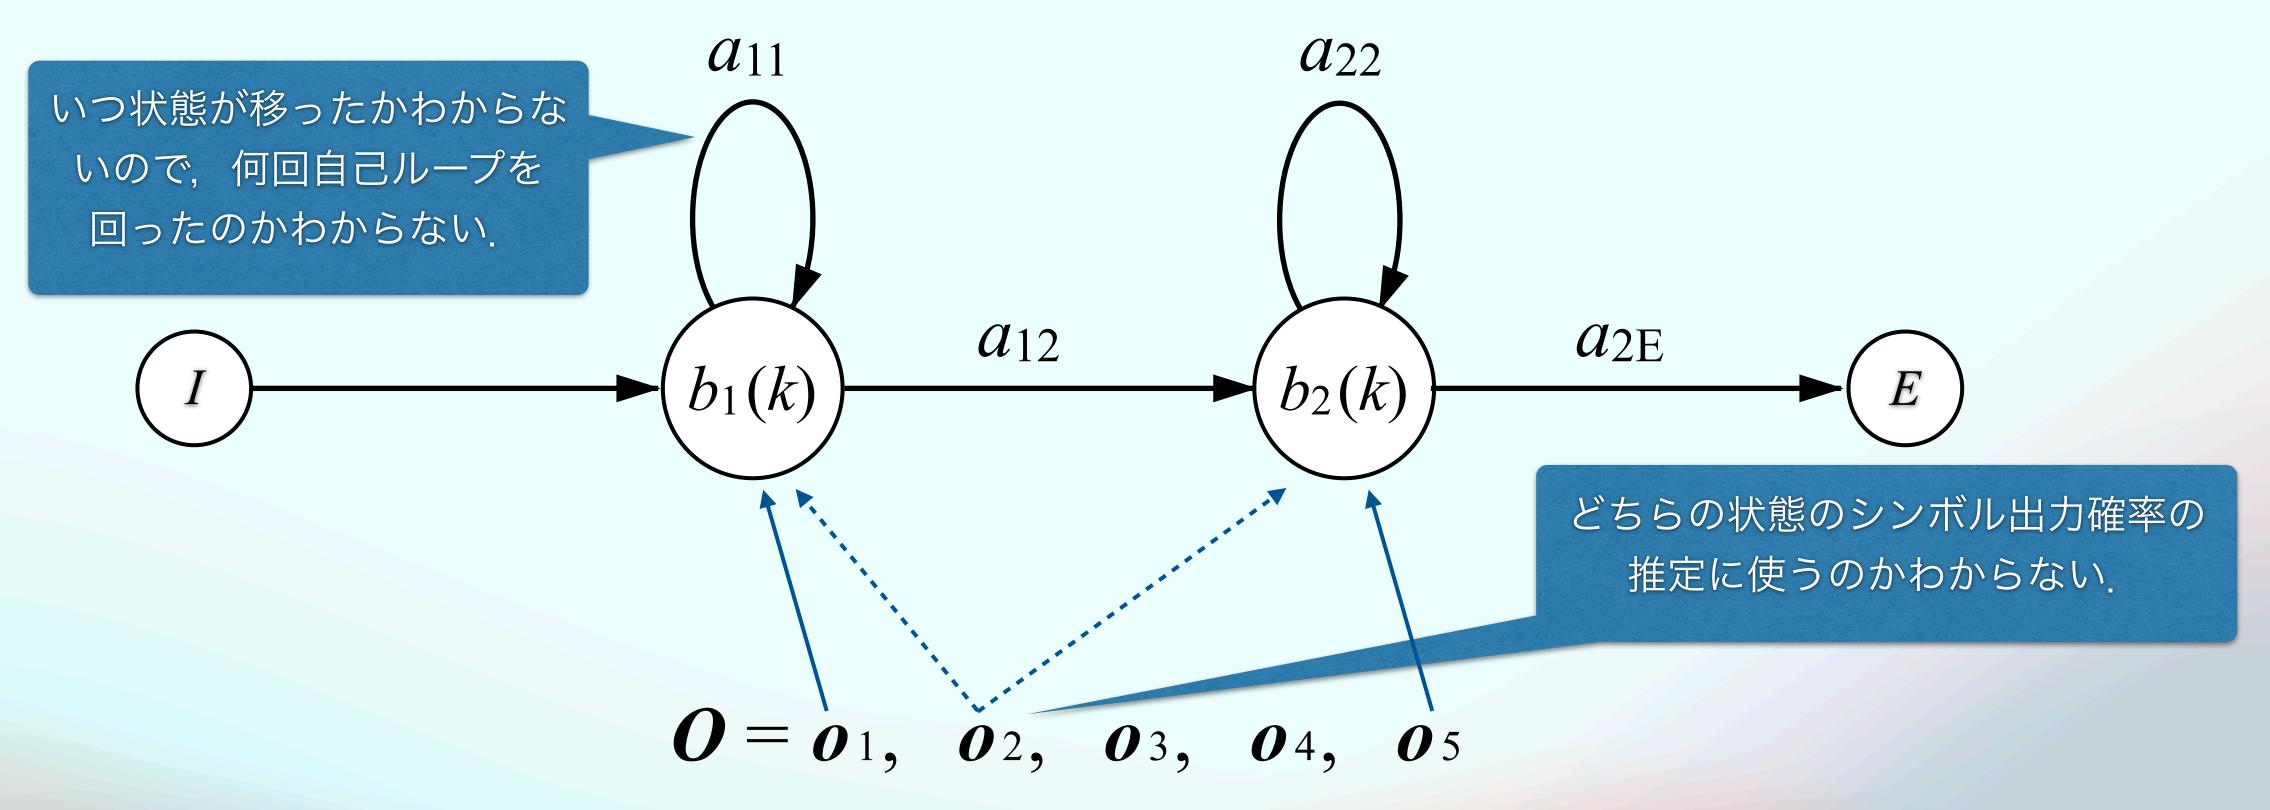


観測データから母集団の確率分布を学習するにあたって、観測データとして直接 観測できない潜在変数(隠れ変数)がある場合の学習方法の重要なものとして EM (expectation–maximization algorithm) アルゴリズムがある。





状態遷移確率 a_{ij} とシンボル出力確率 $b_i(k)$



問題点:学習データに対して状態遷移がわからない

もし、状態遷移が既知であれば、

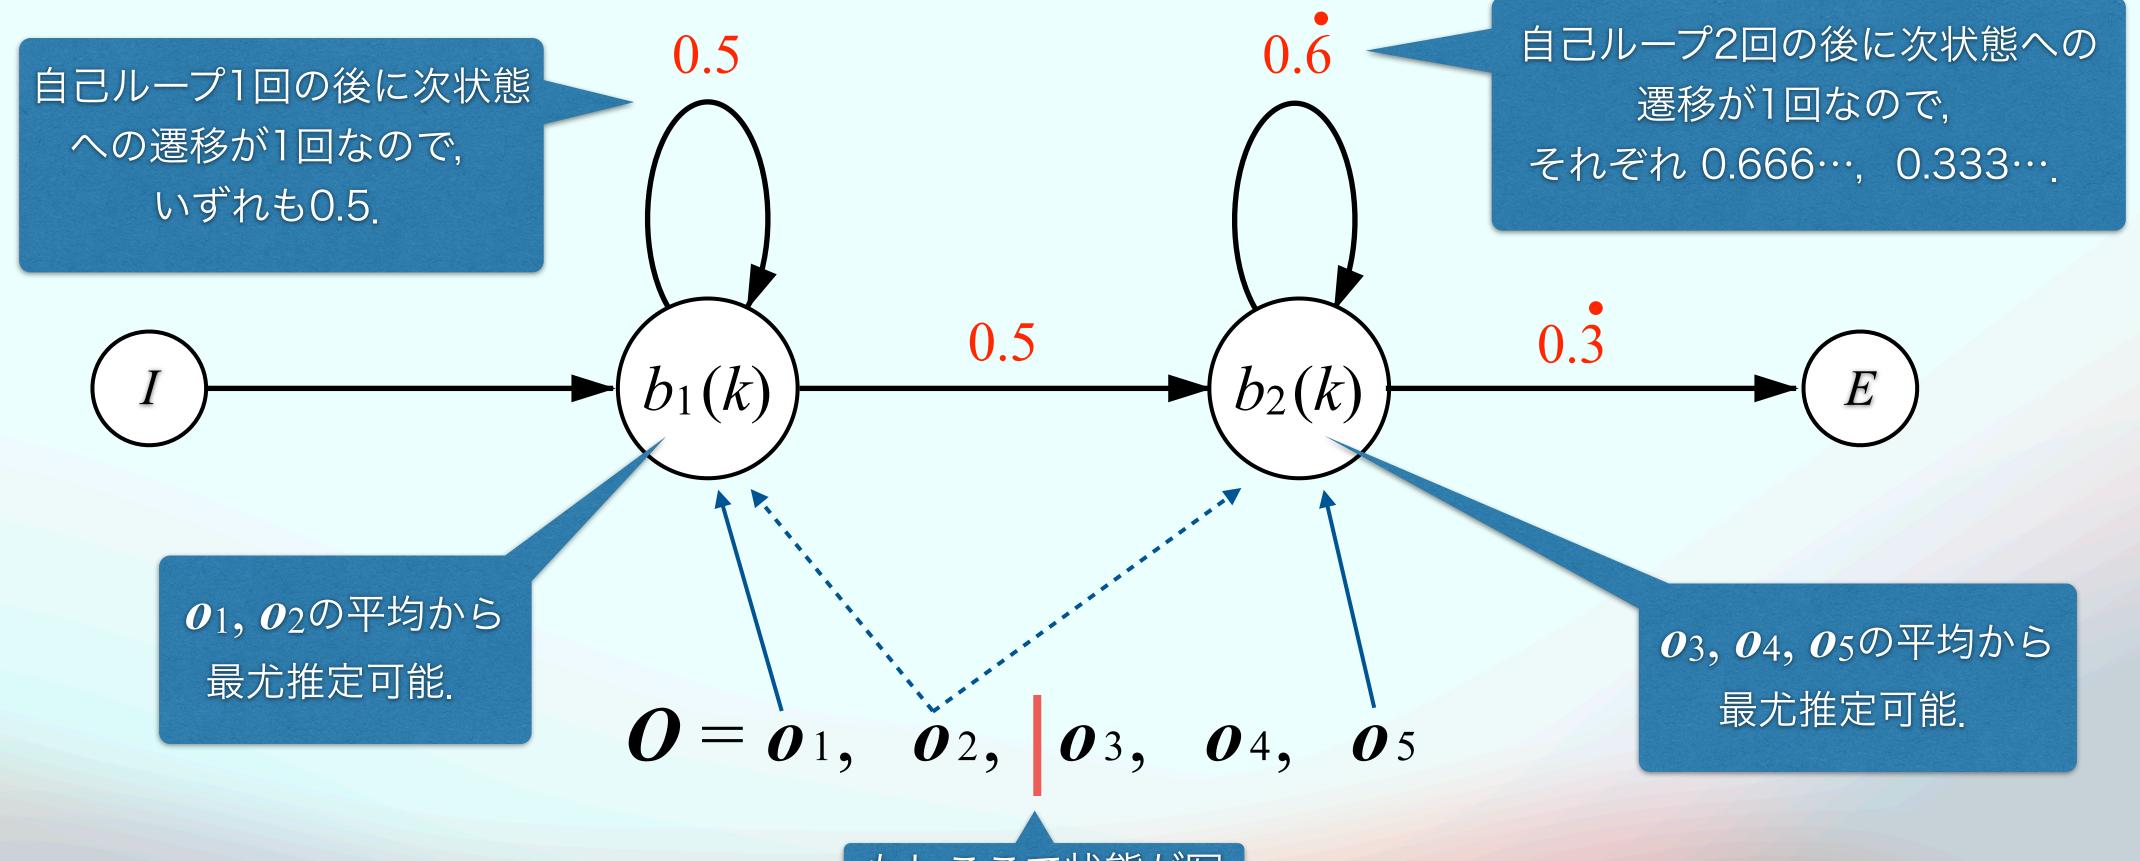
状態遷移確率は状態からの遷移の数え上げ,

シンボル出力確率は状態ごとに対応するシンボル出力平均から最尤推定することができる.

荒木雅弘, イラストで学ぶ音声認識, 講談社, 東京, 2015年の解説による.



状態遷移確率 a_{ij} とシンボル出力確率 $b_i(k)$



もう少し別の状況を考える…

- $O_2 \rightarrow O_3$ のとき $S_1 \rightarrow S_2$:確率0.5
- $O_3 \rightarrow O_4$ のとき $S_1 \rightarrow S_2$:確率0.5

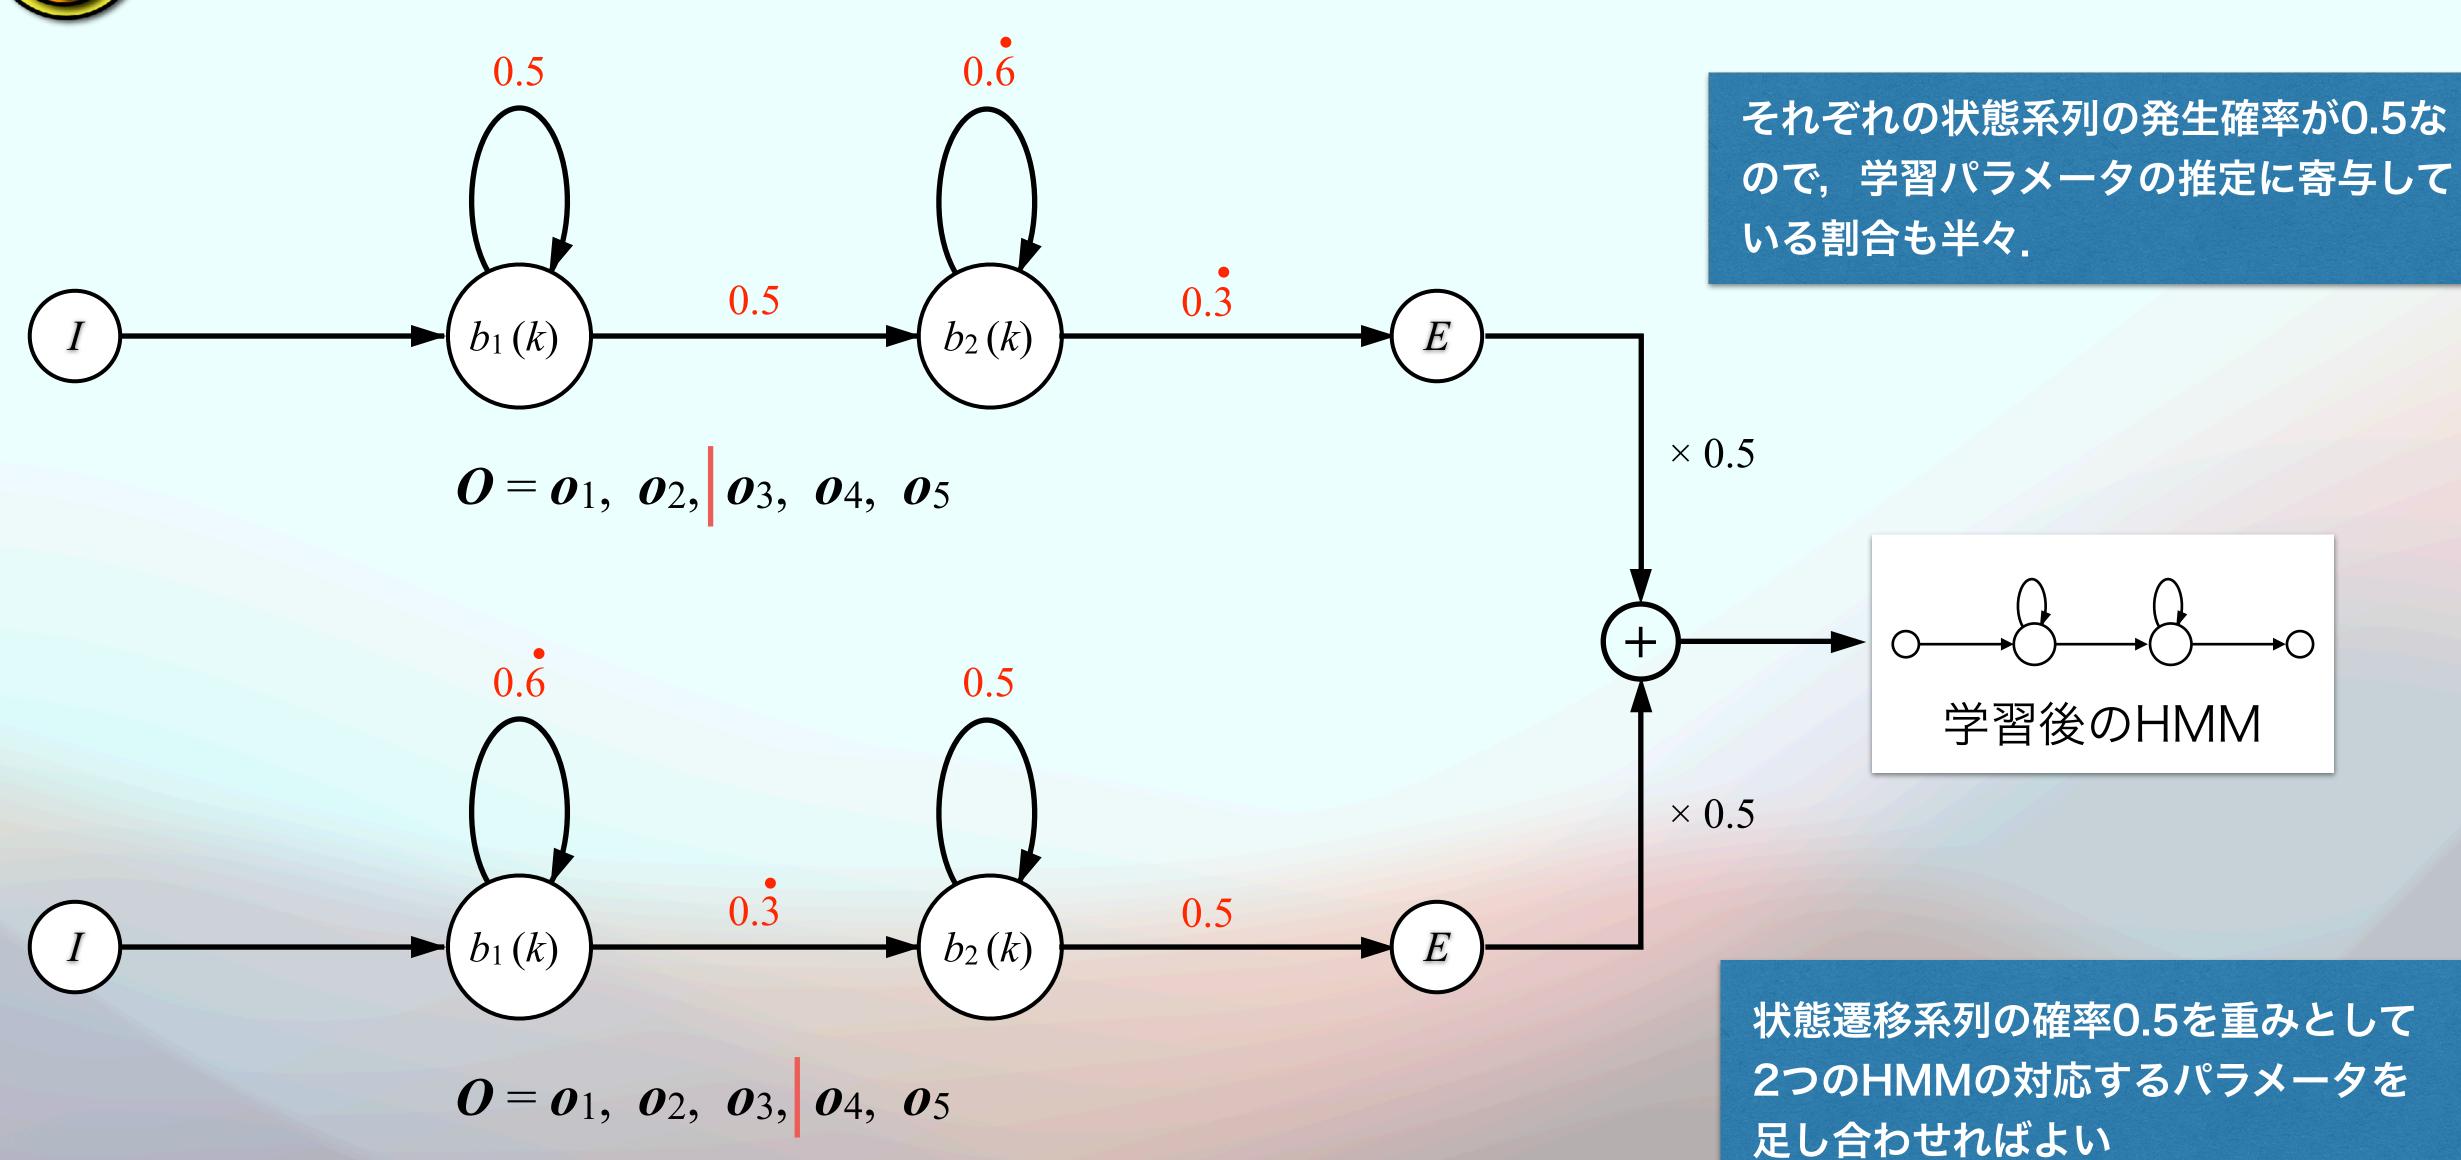
もしここで状態が写 移ったということが 既知であれば

この図は

 $O_2 \rightarrow O_3$ のとき $S_1 \rightarrow S_2$:確率0.5の状況



状態遷移確率 a_{ij} とシンボル出力確率 $b_i(k)$



荒木雅弘, イラストで学ぶ音声認識, 講談社, 東京, 2015年の解説による.



EMアルゴリズム Expectation–Maximization algorithm

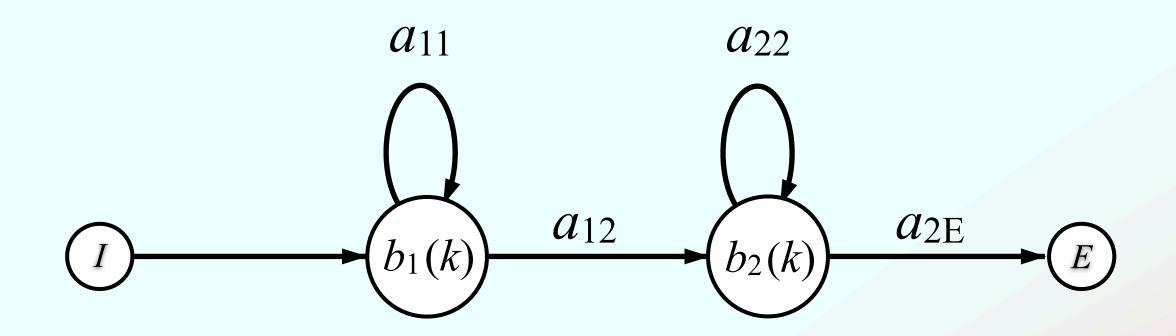
1. HMMのパラメータを適当な初期値に設定.

2. Eステップ

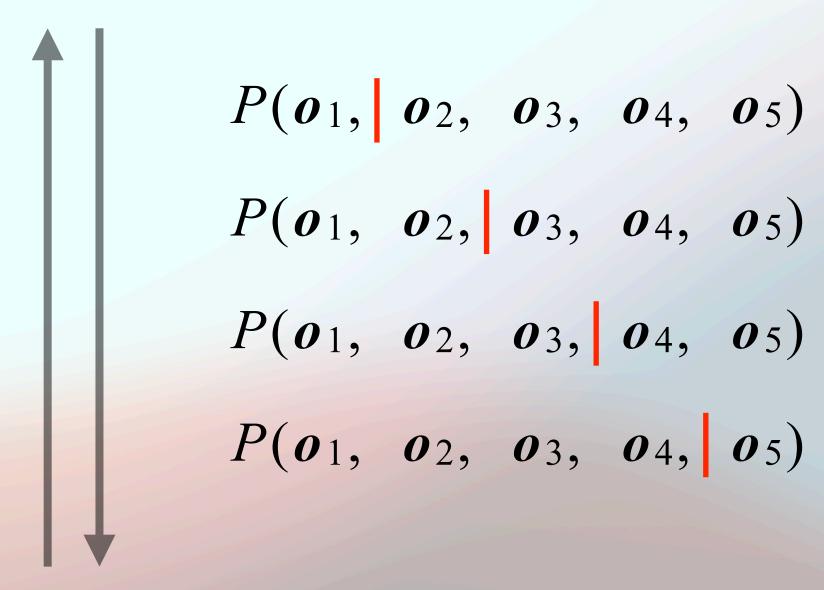
- (a) 学習データに対して、状態遷移を与えた時の確率を 現在のHMMを用いて計算.
- (b) それを全ての可能な状態遷移系列について求める.

3. Mステップ

- (a) 全ての可能な状態遷移系列について, HMMのパラメータを最尤推定.
- (b) Eステップで求めた状態遷移確率を重みとして 最尤推定した結果を足し合わせる.
- 4. EステップとMステップを, Mステップのパラメータの変化量が 一定値以下になるまで繰り返す.



Mステップ Eステップで得られた確率を基にHMMを学習



Eステップ Mステップで得られたHMMで それぞれの状態遷移系列の確率を計算

荒木雅弘, イラストで学ぶ音声認識, 講談社, 東京, 2015年の解説による.



1. HMMのパラメータを適当な初期値に設定.

2. Eステップ

- (a) 学習データに対して、状態遷移を与えた時の確率を 現在のHMMを用いて計算.
- (b) それを全ての可能な状態遷移系列について求める.

3. Mステップ

- (a) 全ての可能な状態遷移系列について, HMMのパラメータを最尤推定.
- (b) Eステップで求めた状態遷移確率を重みとして 最尤推定した結果を足し合わせる.
- 4. EステップとMステップを, Mステップのパラメータの変化量が 一定値以下になるまで繰り返す.

Baum-Welch algorithm ある状態から最終状態までの確率を ForwardおよびBackward確率で計算

Algorithm 1 Baum-Welch Algorithm

- 1: Baum-Welch Algorithm
- $2: \bar{\lambda} = (\bar{\pi}_1, \dots, \bar{\pi}_N, \bar{a}_{1,1}, \dots, \bar{a}_{N,N}, \bar{b}_{1,1}, \dots, \bar{b}_{N,M}):$ パラメータ初期値 [入力]
- 3: v: 出力記号 [入力], o(1),o(2),...,o(T): 記号列 [入力]
- 4: c: 収束判定用閾値 [入力]
- 5: λ̄: パラメータ推定値 [出力]
- 6: $P(\lambda^{old}) \leftarrow -\infty$: 負の十分大きな値
- 7: START: $\lambda \leftarrow \bar{\lambda}$: パラメータの更新
- 8: Forward アルゴリズムにより λ の値から $\alpha_t(i)$ $(1 \le t \le T, 1 \le i \le N)$ と $P(\lambda)$ を計算する.
- 9: **if** $\log P(\lambda) \log P(\lambda^{old}) < \epsilon$ **then**
- 10: $\bar{\lambda} \leftarrow \lambda$: 推定結果
- 11: exit
- 12: **else**
- 13: $P(\lambda^{oid}) \leftarrow P(\lambda)$
- 14: end if
- 15: Backward アルゴリズムにより λ の値から $\beta_t(i)$ $(1 \le t \le T, \ 1 \le i \le N)$ と $P(\lambda)$ を計算する.
- 16: **for** i = 1 to N **do**

17:

$$\bar{\pi}_i = \frac{\alpha_1(i)\beta_1(i)}{P(\lambda)}$$

- 18: **end for**
- 19: **for** i = 1 to N **do**
- 20: **for** j = 1 to N **do**
- 21:

$$ar{a}_{i,j} = rac{\displaystyle\sum_{t=1}^{T-1} lpha_t(i) a_{i,j} b_j(o(t+1)) eta_{t+1}(j)}{\displaystyle\sum_{t=1}^{T-1} lpha_t(i) eta_t(i)}$$

- 22: end for
- 23: **end for**
- 24: **for** j = 1 to N **do**
- 25: **for** k = 1 to M **do**
- 26:

$$\bar{b}_{j,k} = \frac{\sum_{t=1}^{T} \delta_{v(k),o(t)} \alpha_t(j) \beta_t(j)}{\sum_{t=1}^{T} \alpha_t(j) \beta_t(j)}$$

 $\delta_{v(k),o(t)}$ はクロネッカーのデルタ. $\delta_{x,y} = 1 (x = y), 0 (x \neq y).$

- 27: end for
- 28: **end for**
- 29: $\bar{\lambda} = (\bar{\pi}_1, \dots, \bar{\pi}_N, \bar{a}_{1,1}, \dots, \bar{a}_{N,N}, \bar{b}_{1,1}, \dots, \bar{b}_{N,M})$
- 30: goto START
- 31: end of Baum-Welch Algorithm



Algorithm 1 Baum-Welch Algorithm

- 1: Baum-Welch Algorithm
- 2: $\bar{\lambda}=(\bar{\pi}_1,\ldots,\bar{\pi}_N,\bar{a}_{1,1},\ldots,\bar{a}_{N,N},\bar{b}_{1,1},\ldots,\bar{b}_{N,M})$: パラメータ初期値 [入力]
- 3: \mathbf{v} : 出力記号 [入力], $o(1), o(2), \ldots, o(T)$: 記号列 [入力]
- 4: ε: 収束判定用閾値 [入力]
- 5: λ̄: パラメータ推定値 [出力]
- 6: $P(\lambda^{old}) \leftarrow -\infty$: 負の十分大きな値
- 7: START: $\lambda \leftarrow \bar{\lambda}$: パラメータの更新

穴埋め部 (1)

- 8: Forward アルゴリズムにより λ の値から $\alpha_t(i)$ $(1 \le t \le T, 1 \le i \le N)$ と $P(\lambda)$ を 計算する.
- 9: if $\log P(\lambda) \log P(\lambda^{old}) < \epsilon$ then
- 10: $\bar{\lambda} \leftarrow \lambda$: 推定結果
- 11: exit
- 12: **else**
- 13: $P(\lambda^{old}) \leftarrow P(\lambda)$
- 14: **end if**

穴埋め部 (2)

- 15: Backward アルゴリズムにより λ の値から $\beta_t(i)$ $(1 \le t \le T, 1 \le i \le N)$ と $P(\lambda)$ を 計算する.
- 16. for i 1 + 0 N do



14: **end if**

15: Backward アルゴリズムにより λ の値から $\beta_t(i)$ $(1 \le t \le T, 1 \le i \le N)$ と $P(\lambda)$ を計算する.

16: **for** i = 1 to N **do**

17:

$$\bar{\pi}_i = \frac{\alpha_1(i)\beta_1(i)}{P(\lambda)}$$

穴埋め部 (3)

18: **end for**

19: **for** i = 1 to N **do**

20: **for** j = 1 to N **do**

21:

$$ar{a}_{i,j} = rac{\displaystyle\sum_{t=1}^{T-1} lpha_t(i) a_{i,j} b_j(o(t+1)) eta_{t+1}(j)}{\displaystyle\sum_{t=1}^{T-1} lpha_t(i) eta_t(i)}$$

穴埋め部 (4)

22: end for

23: **end for**

24: **for** j = 1 to N **do**



$$\sum_{t=1}^{\alpha_t(t)\beta_t(J)}$$

end for 22:

23: end for

24: **for** j = 1 to N **do**

for k=1 to M do 25:

26:

$$ar{b}_{j,k} = egin{aligned} rac{\displaystyle\sum_{t=1}^{T} \delta_{v(k),o(t)} lpha_t(j) eta_t(j)}{\displaystyle\sum_{t=1}^{T} lpha_t(j) eta_t(j)}$$
 穴埋め部 (5)

$$\delta_{v(k),o(t)}$$
 はクロネッカーのデルタ. $\delta_{x,y} = 1 (x = y), 0 (x \neq y).$

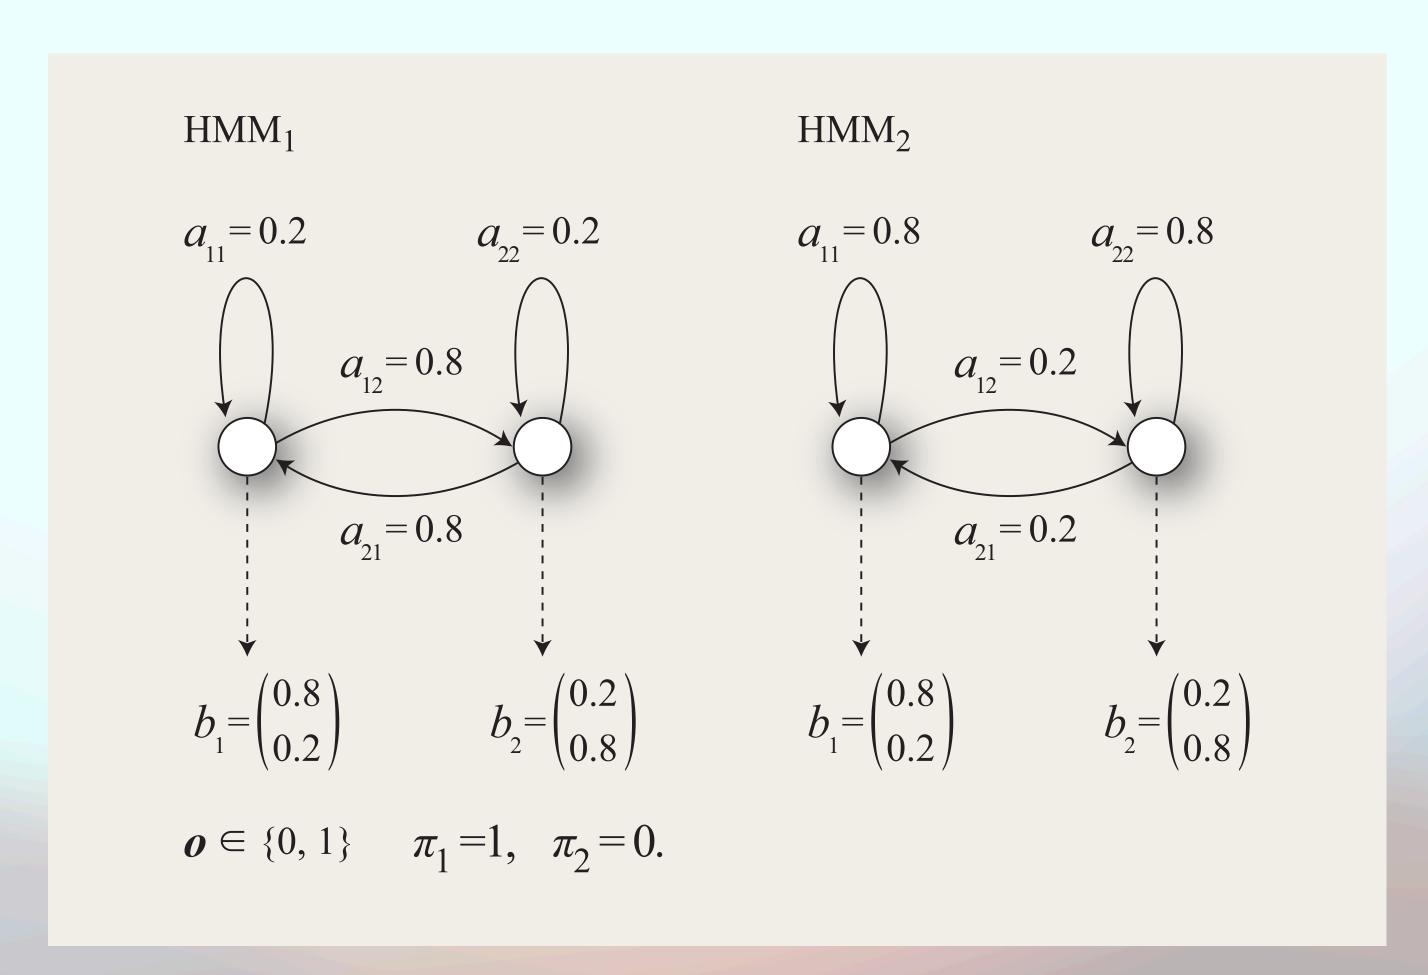
 $\lceil v(k) = o(t)$ であれば足す。でなければ足さない。」の実装方法

- $1. \delta_{x,v}$ を定義 (a)マクロ(#define) (b) 関数
- 2. 条件判断 if-then-else
- 3. 三項演算 ?:



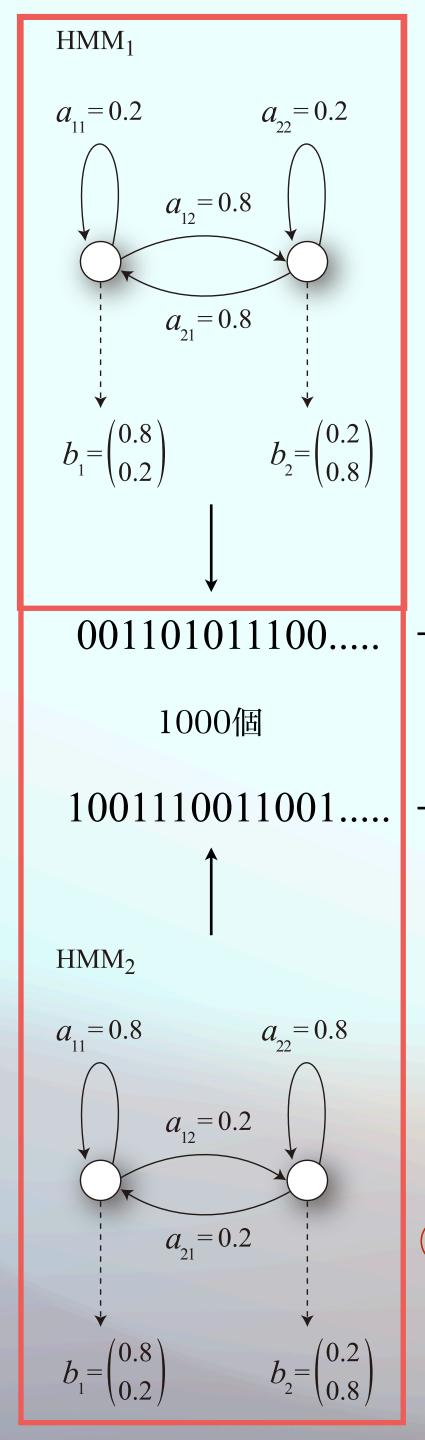
実習5.6.3 p.5-18 — HMMの学習と認識

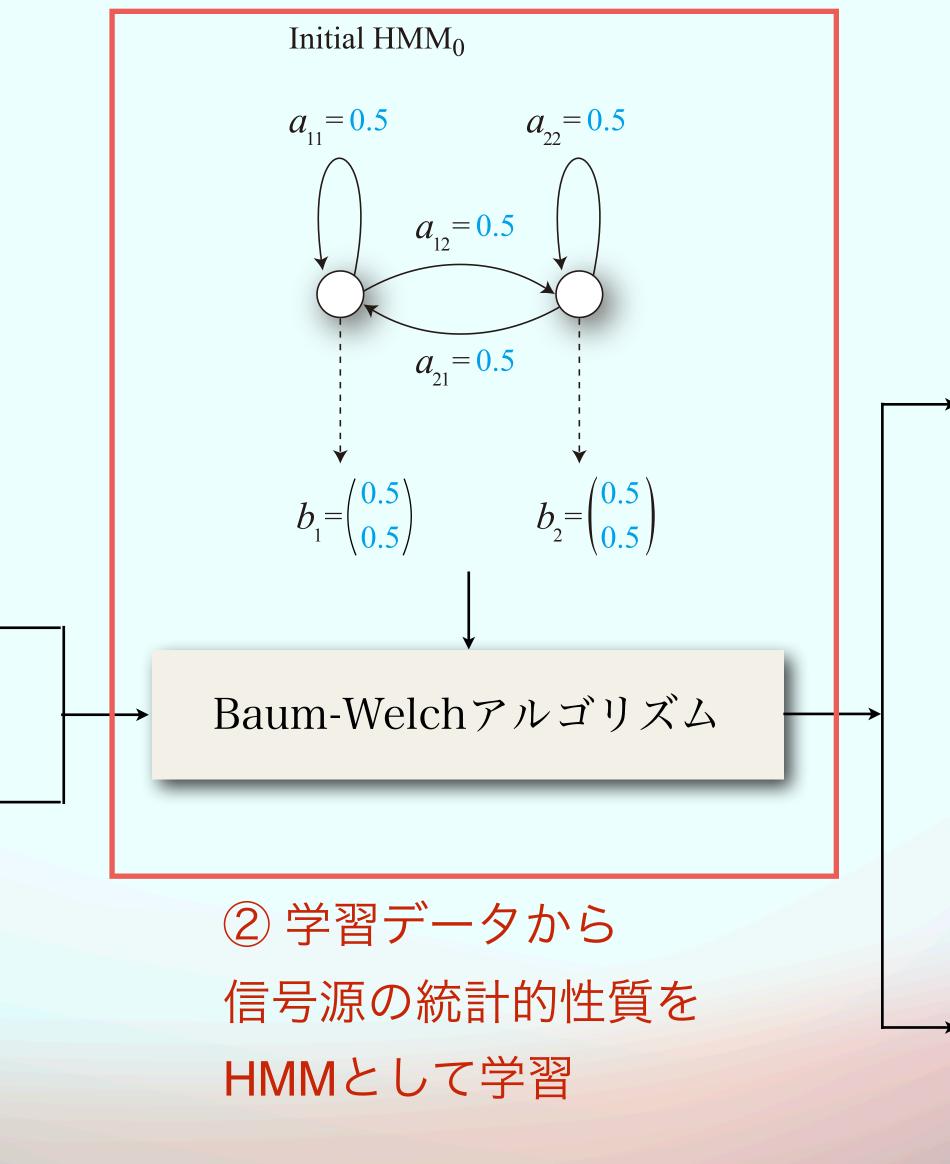
~/asr/drill/baumwelch.c の穴埋め課題



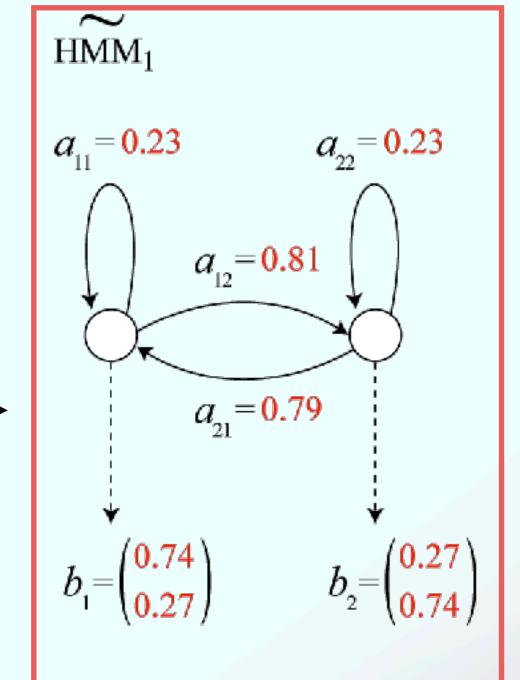
0と1の系列を出力/認識する隠れマルコフモデル HMMは記号系列の生成器としても認識器としても使うことができる

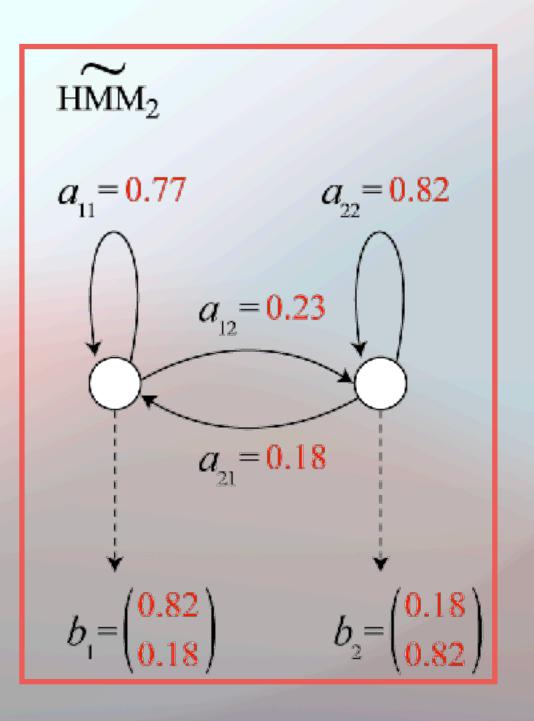






①2種類の信号源から ③学習済のHMMは 学習データを生成 信号源のHMMに類似







パラメータの学習の様子

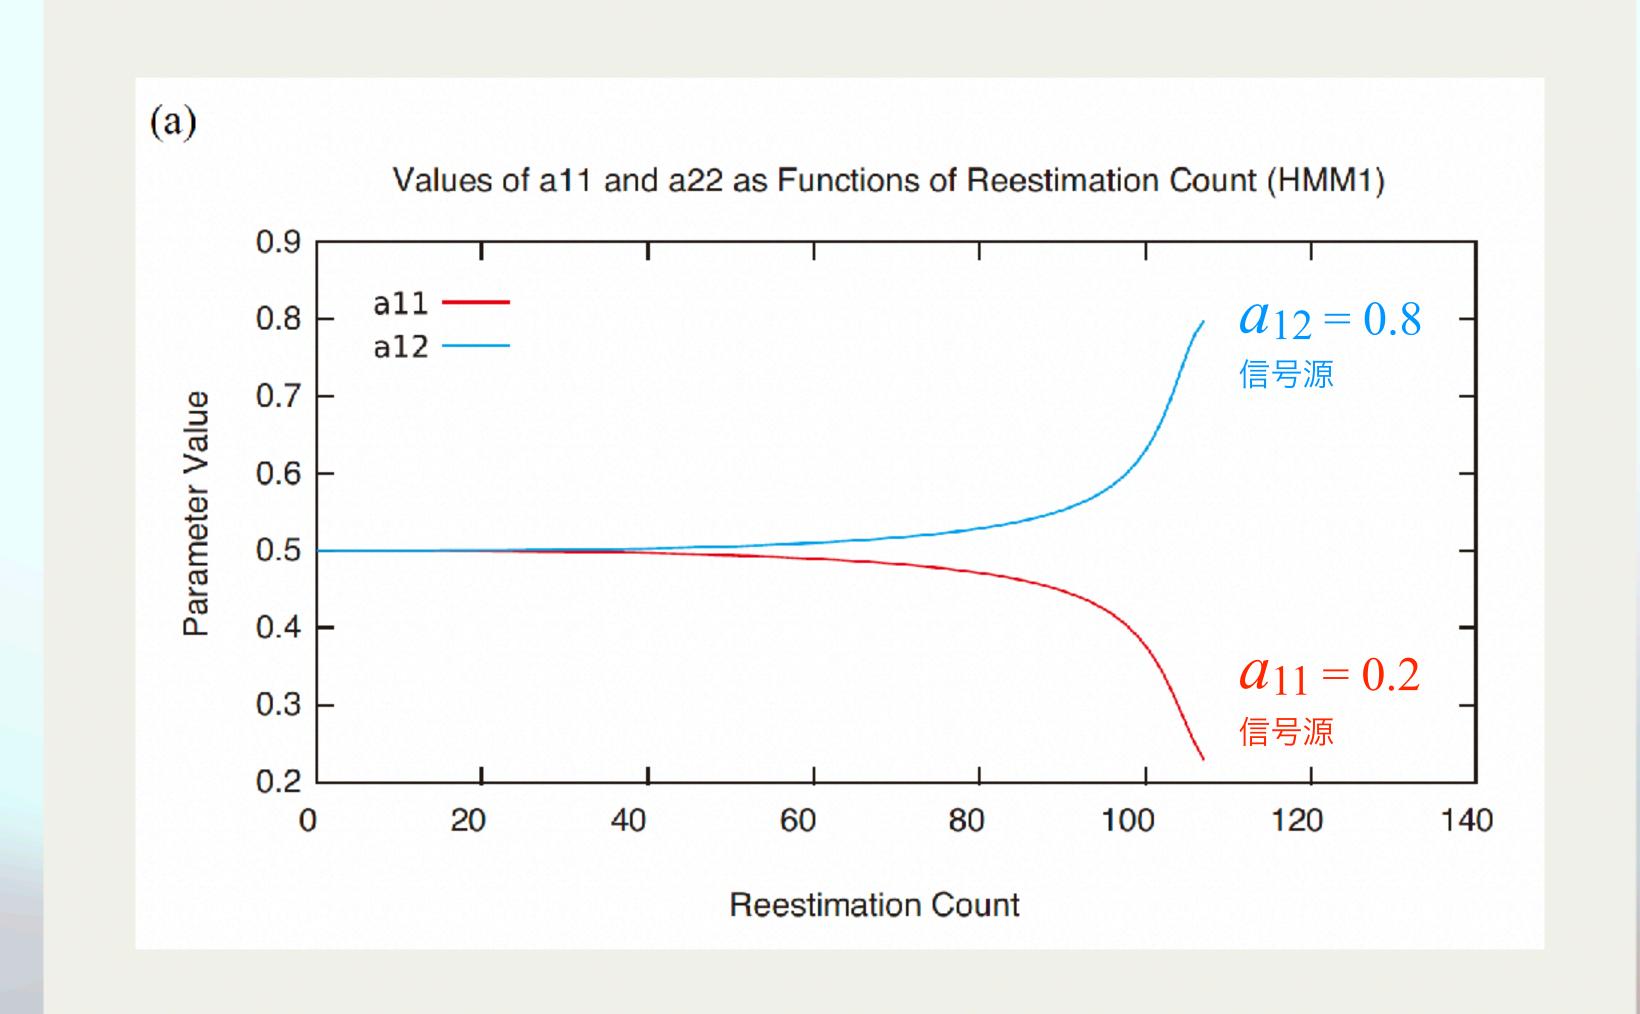
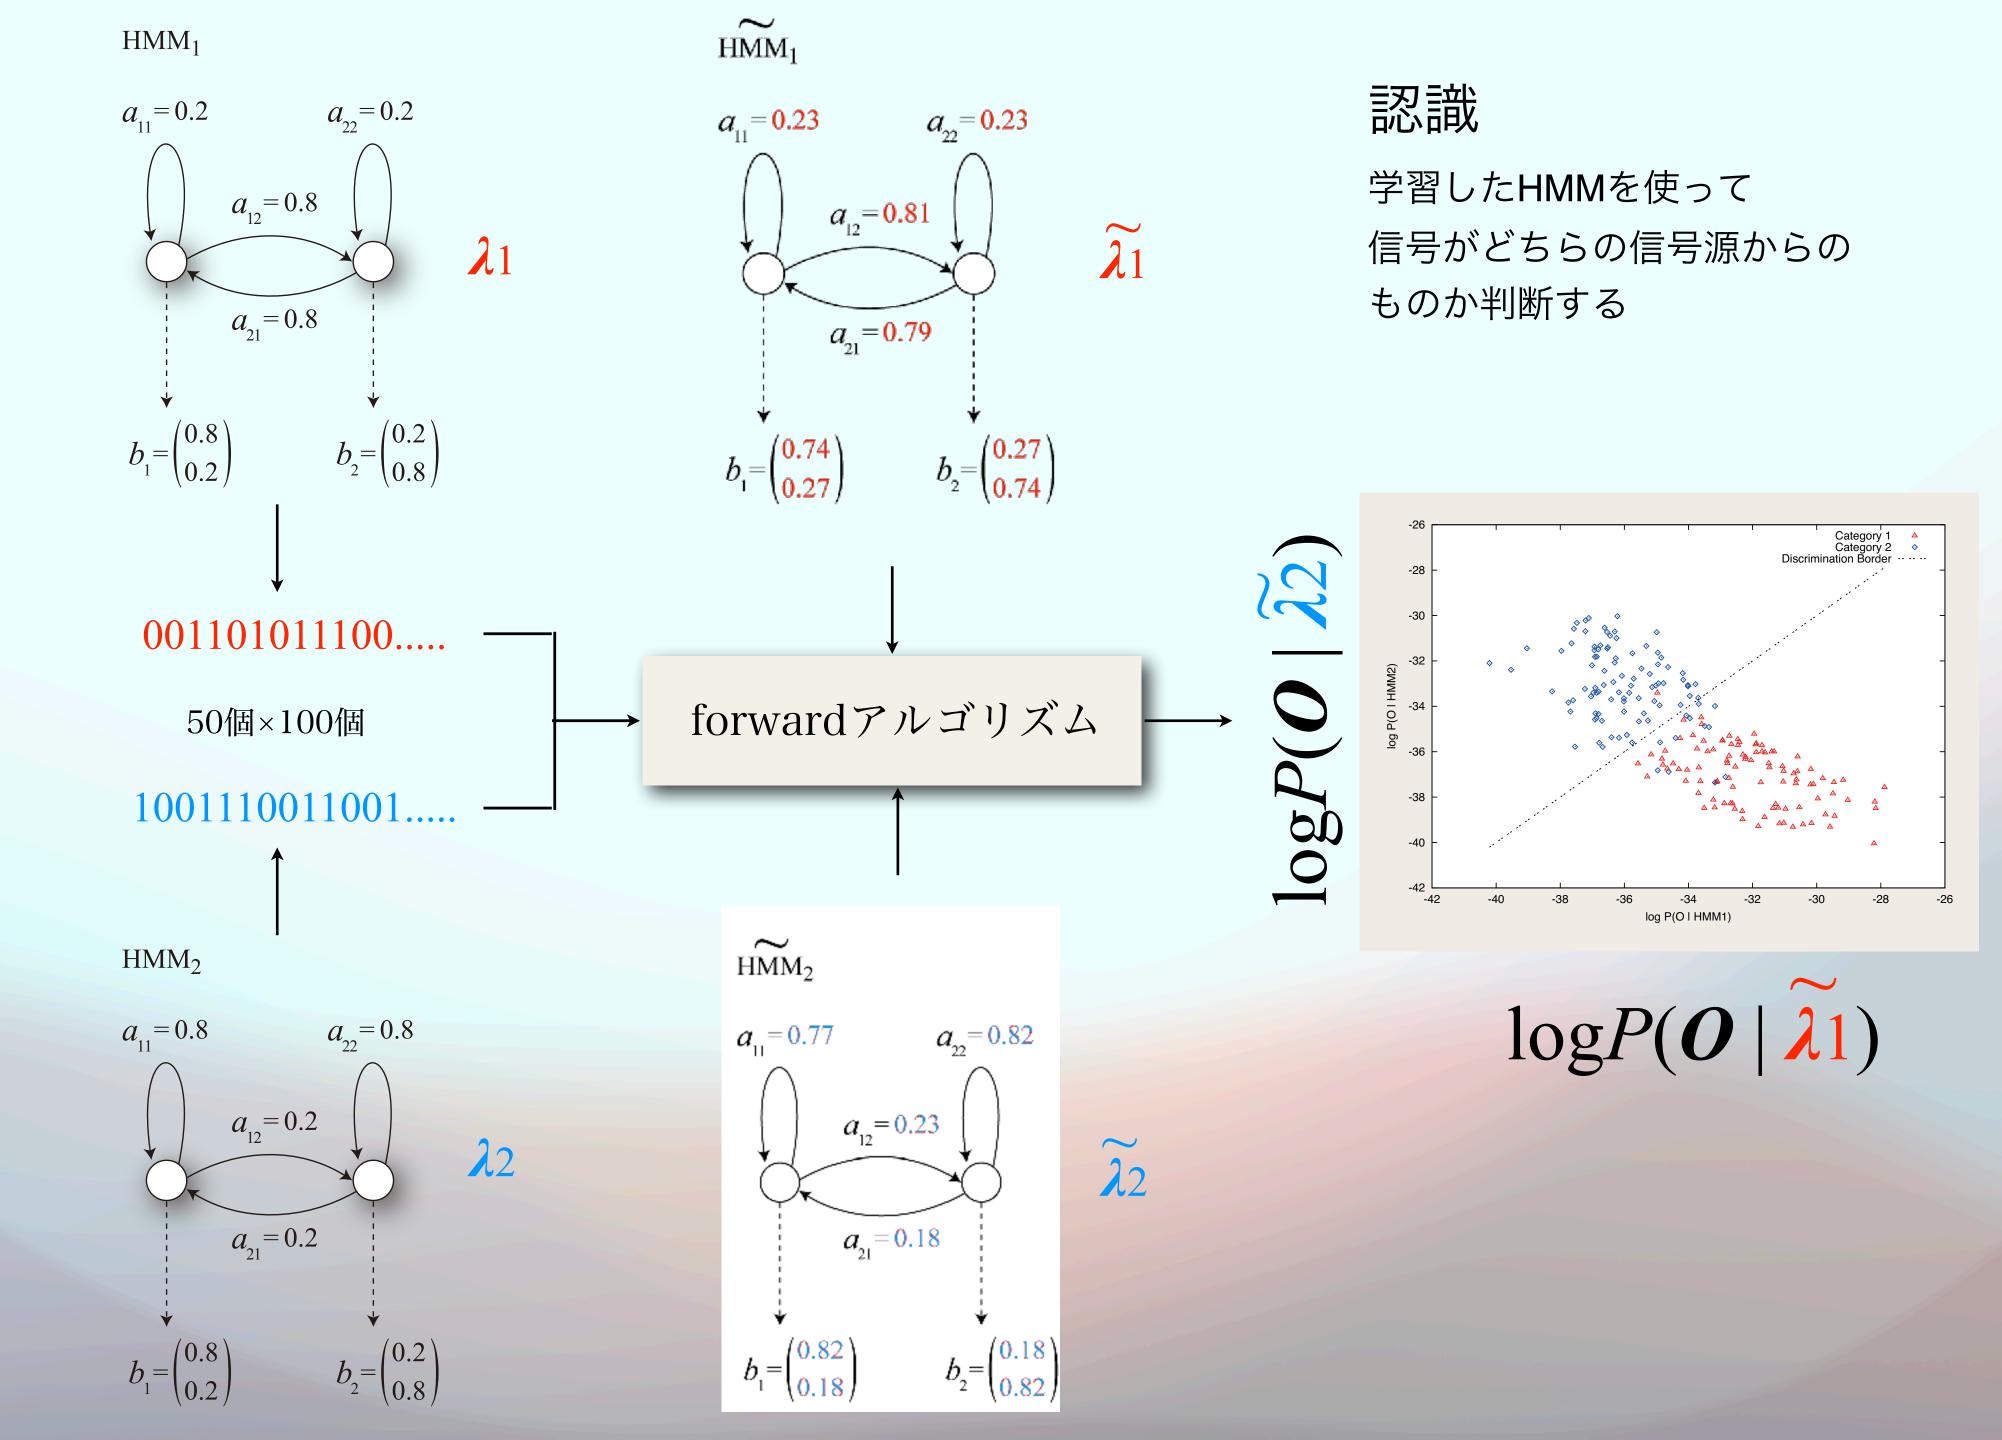
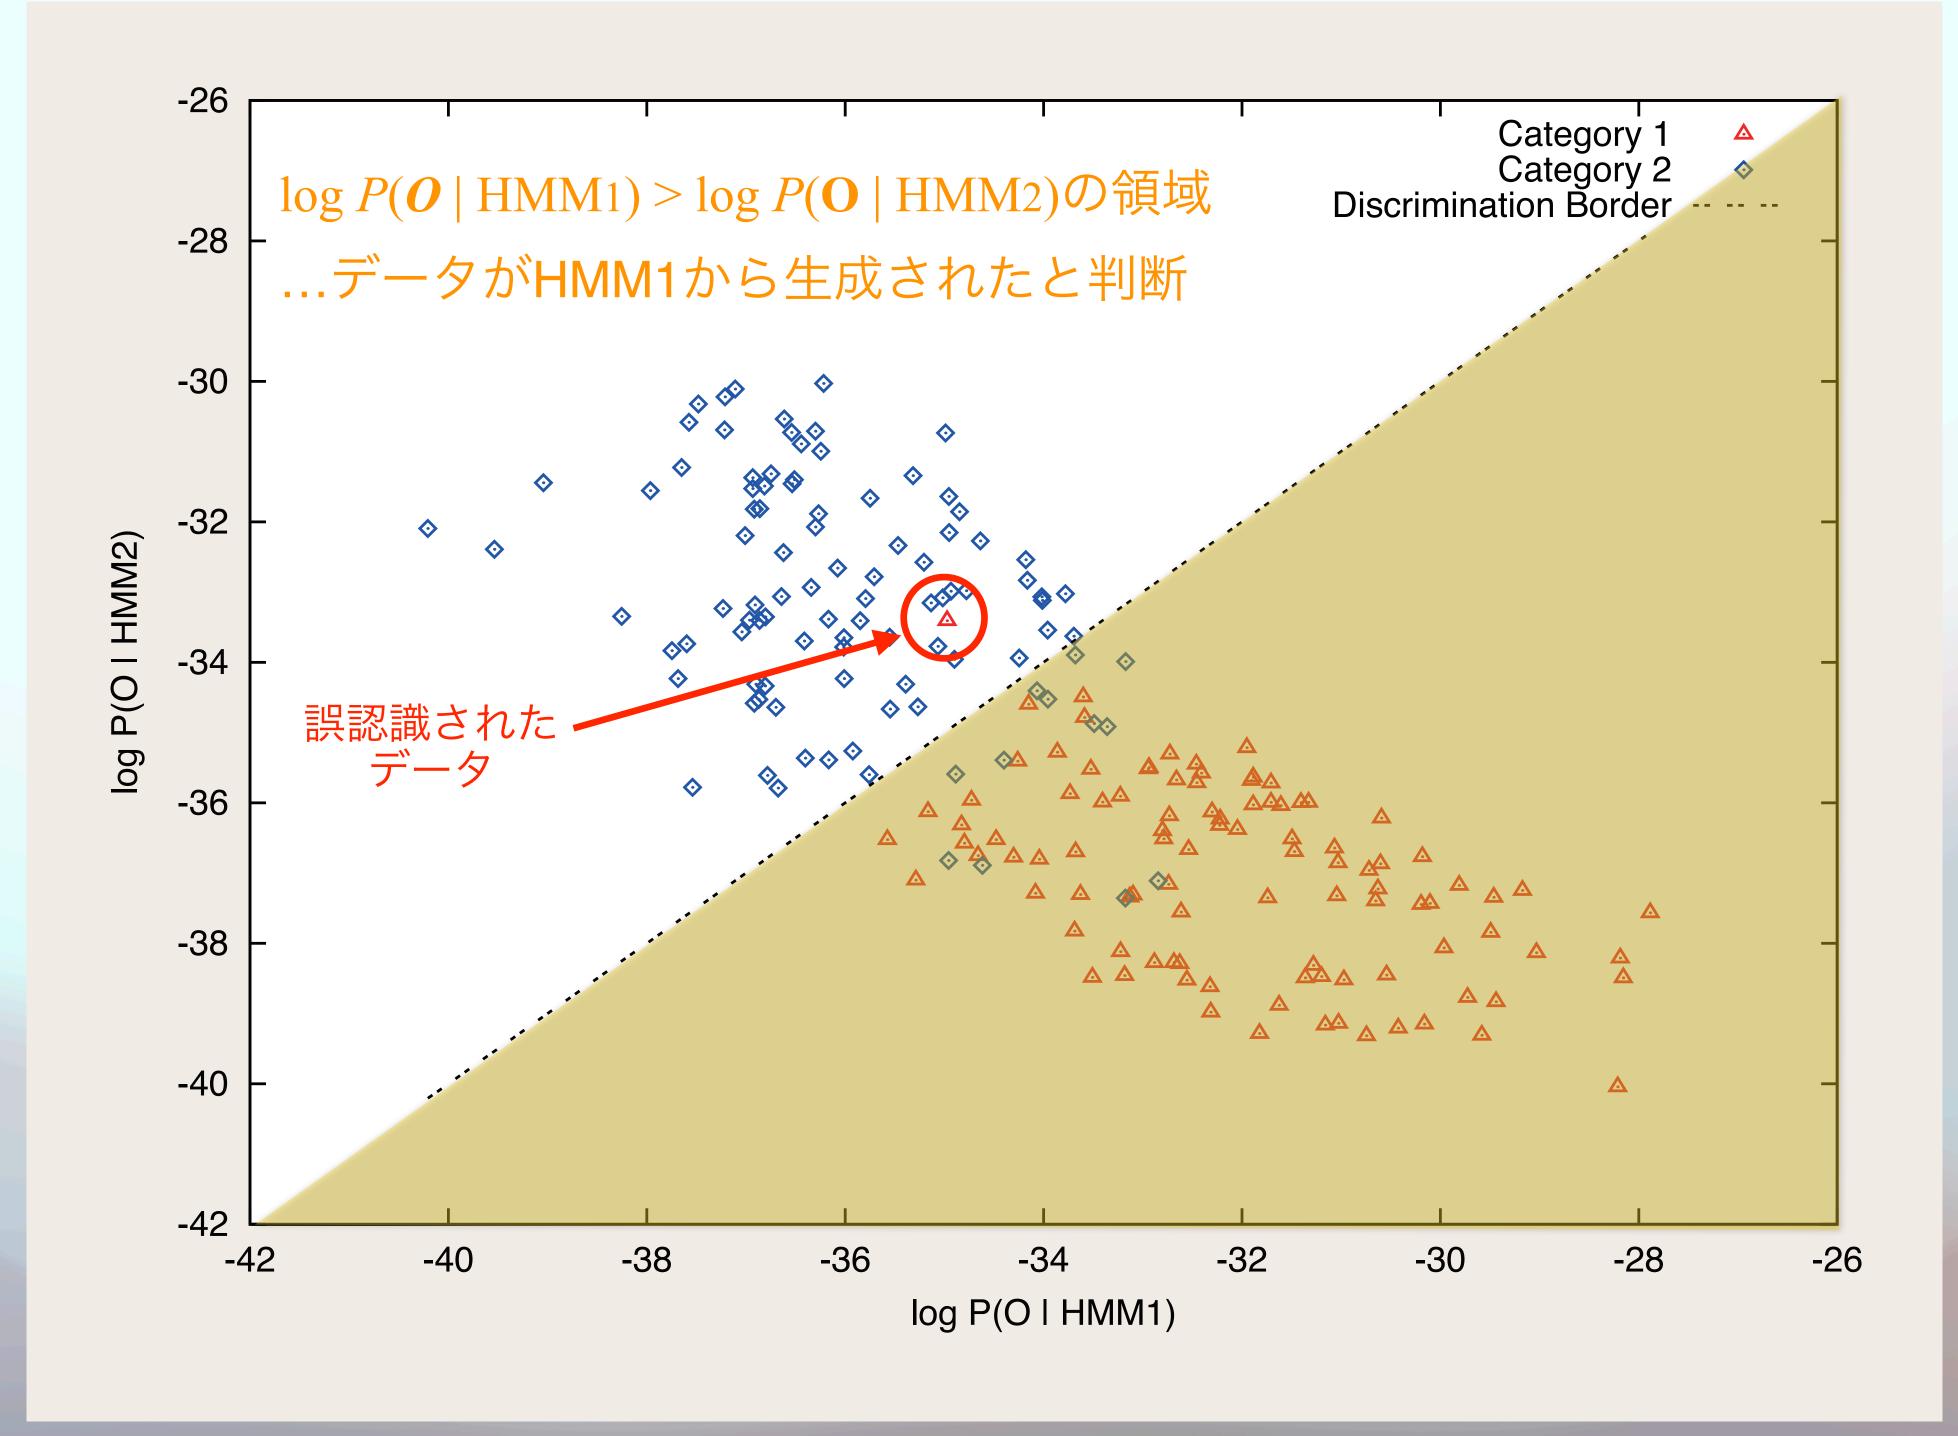


図 5.13: (a) HMM1の状態遷移確率 a_{11} と a_{12} が 再推定の繰り返しにより信号源のパラメータに近づく.











実習5.6.4 p.5-25 — 多次元ガウス確率密度関数

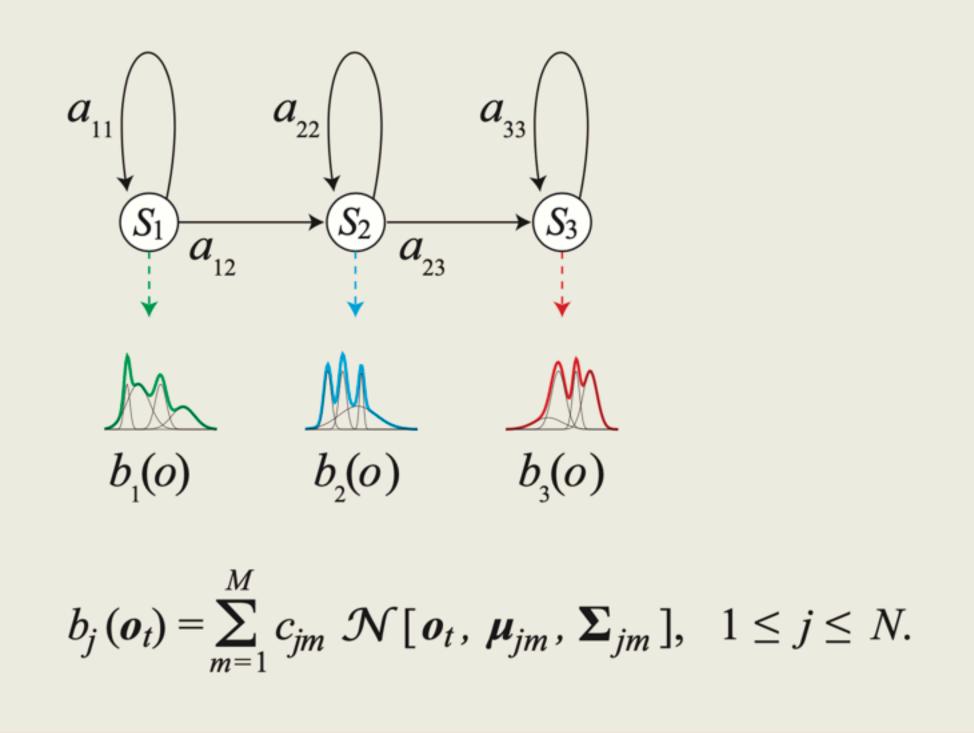
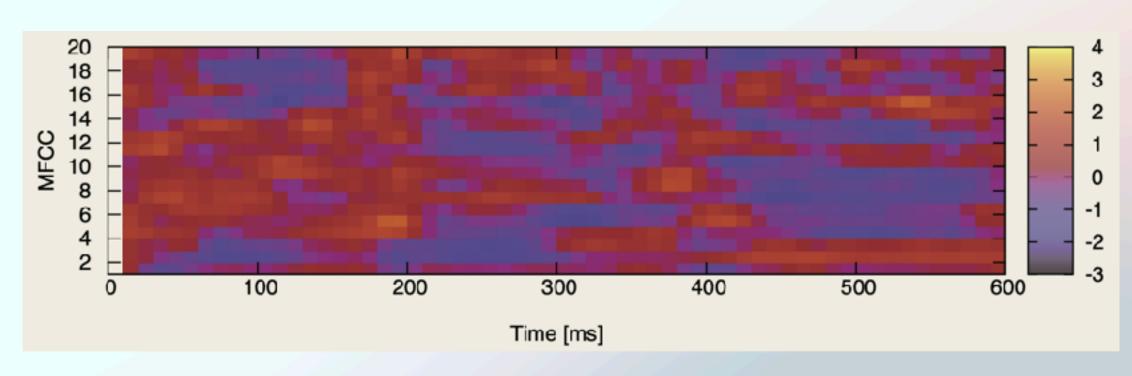


図 5.7: 出力確率密度が混合ガウス分布である連続 HMM

- ・単語HMMの学習と認識に必要
- ·~/asr/wrecog/program/gpdf.c の穴埋め課題…式(5.35)の実装



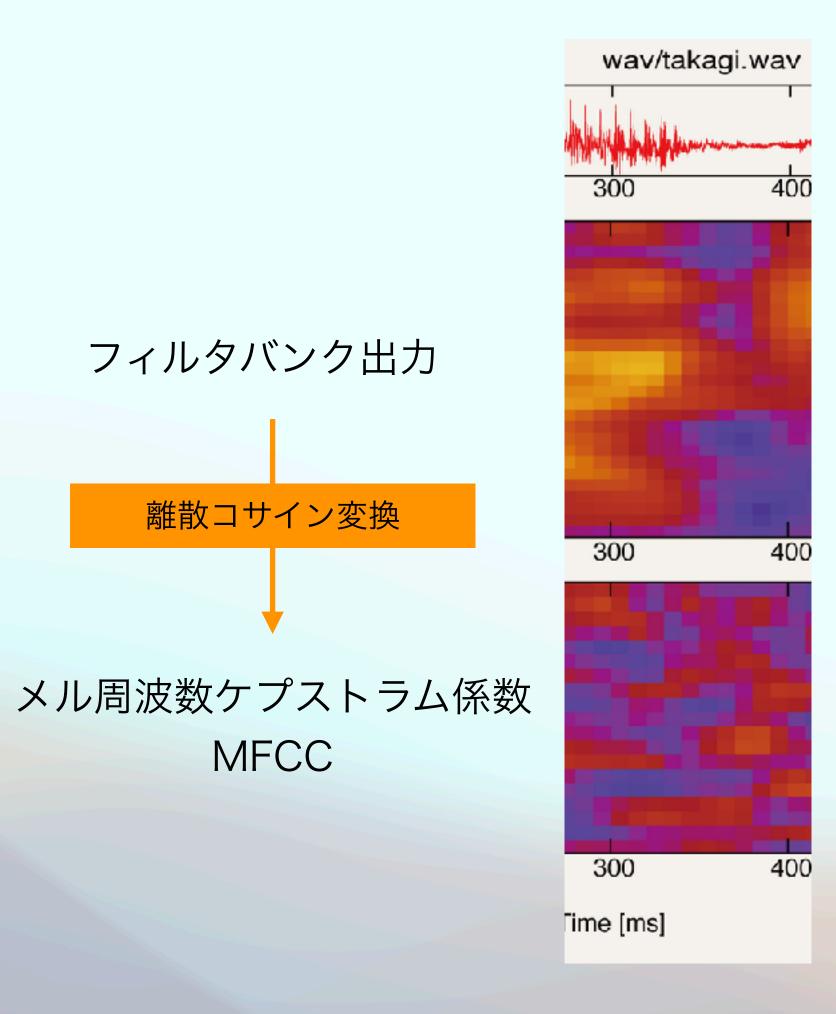
単語認識用音響モデル $P(\mathbf{O}|\lambda)$ としてHMMでモデル化する観測系列 \mathbf{O} はMFCCのような連続値(実数ベクトル)

$$\mathcal{N}(\boldsymbol{o}_{t}, \boldsymbol{\mu}_{jm}, \boldsymbol{\Sigma}_{jm}) = \frac{1}{\sqrt{\prod_{d=1}^{D} 2\pi\sigma_{d}^{2}}} \exp\left\{-\frac{1}{2} \sum_{d=1}^{D} \frac{(\boldsymbol{o}_{t}^{(d)} - \boldsymbol{\mu}_{m}^{(d)})^{2}}{\sigma_{d}^{2}}\right\}$$
(5.35)



Q: なぜフィルタバンク出力を離散コサイン変換してMFCCにする?

A: MFCCにすると次元間の相関が無くなりスペクトル分布のモデル化が容易になる



第 5 章 隠れマルコフモデル(HMM)

5.4 音声認識のための HMM

特徴量なので、多次元ガウス分布の確率密度関数を使います.

$$\mathcal{N}(\boldsymbol{o}_{t}, \boldsymbol{\mu}_{jm}, \boldsymbol{\Sigma}_{jm}) = \frac{1}{\sqrt{(2\pi)^{D}|\boldsymbol{\Sigma}_{m}|}} \exp \left\{ -\frac{1}{2} (\boldsymbol{o}_{t} - \boldsymbol{\mu}_{m})' \boldsymbol{\Sigma}_{m}^{-1} (\boldsymbol{o}_{t} - \boldsymbol{\mu}_{m}) \right\} (5.33)$$

であり,D は o_t の次数,' は転置,M は混合数, $\mathbf{\Sigma}_m^{-1}$ は $\mathbf{\Sigma}_m$ の逆行列, $|\mathbf{\Sigma}_m|$ は Σ_m の行列式を表わします. 多次元データを利用した場合, $|\Sigma_m|$ は共分散行 列となりますが,この実験では,次元間の相関が無いと仮定した対角共分散行列

を使用します.この場合,共分散行列は

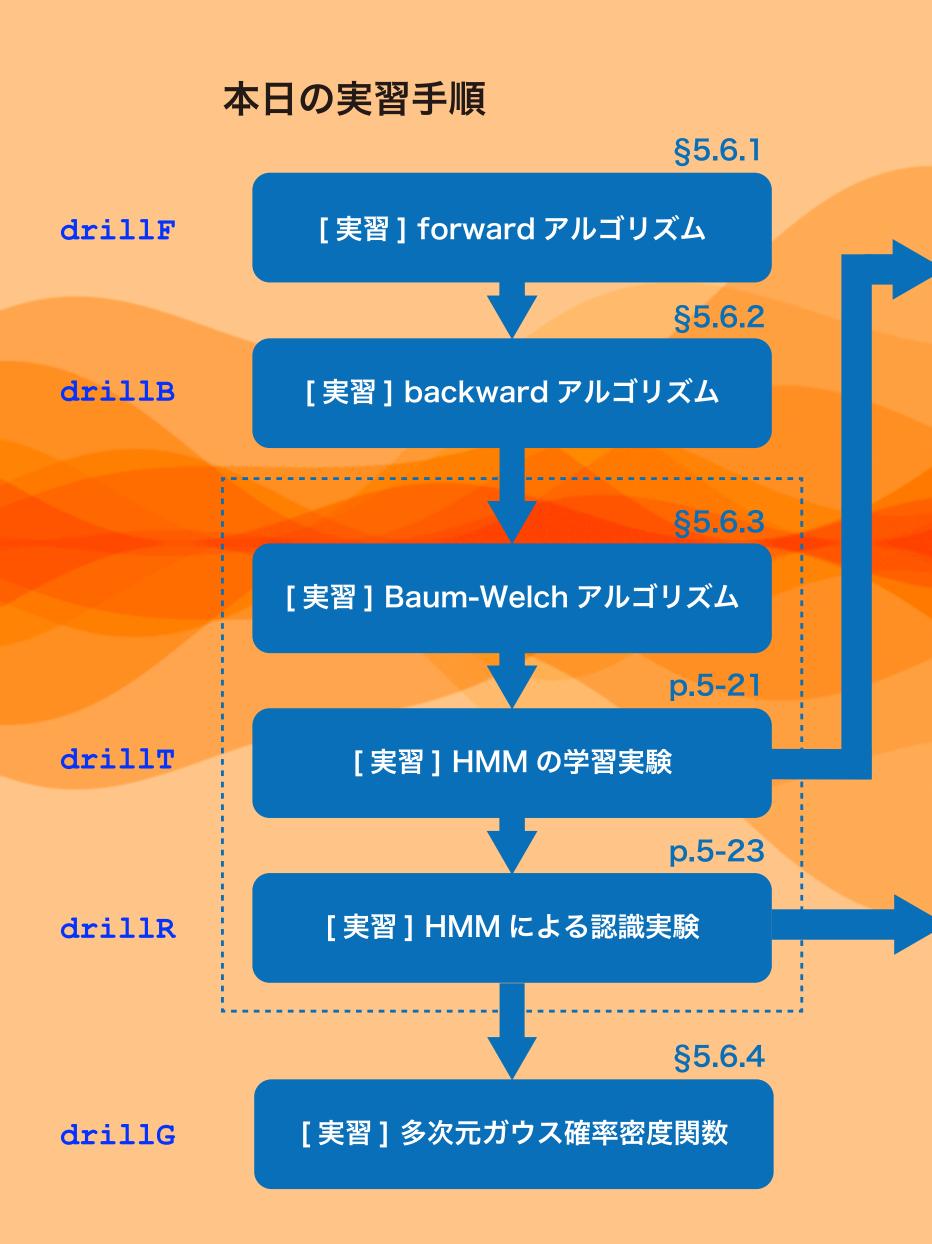
相関が有ると仮定すると非対角成分を推定 しなければならず、膨大な学習データが

となり,密度関数は,

$$\mathcal{N}(\boldsymbol{o}_{t}, \boldsymbol{\mu}_{jm}, \boldsymbol{\Sigma}_{jm}) = \frac{1}{\sqrt{\prod_{d=1}^{D} 2\pi\sigma_{d}^{2}}} \exp \left\{ -\frac{1}{2} \sum_{d=1}^{D} \frac{(\boldsymbol{o}_{t}^{(d)} - \boldsymbol{\mu}_{m}^{(d)})^{2}}{\sigma_{d}^{2}} \right\}$$
(5.35)

で与えられます.ここで, $oldsymbol{o}_t^{(d)}$ は観測ベクトル $oldsymbol{o}_t$ の第 d 次元, $oldsymbol{\mu}_m^{(d)}$ は第 m 混合 の平均値ベクトル μ_m の第d次元です.

本日の実習



この実習の実験はtcshで実行 コマンドラインで「tcsh」と入力するとシェルがtcshに切り替わる

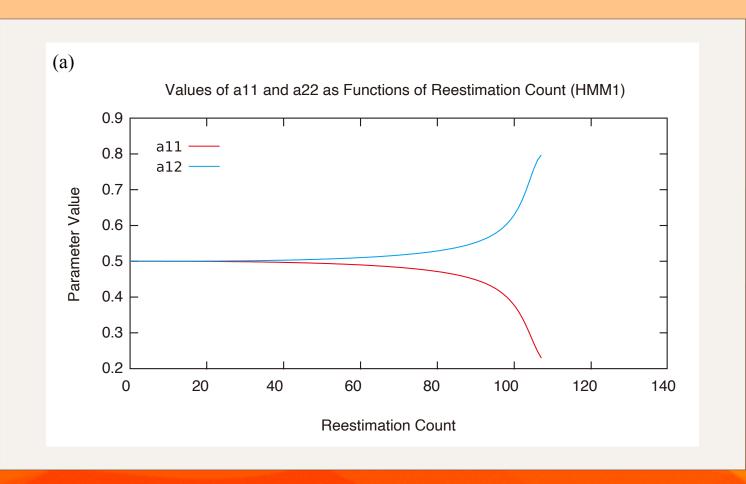


図 5.13(a): HMM1 の状態遷移確率 a11 と a12 が再推定の繰り返しにより信号源のパラメータに近づく様子.

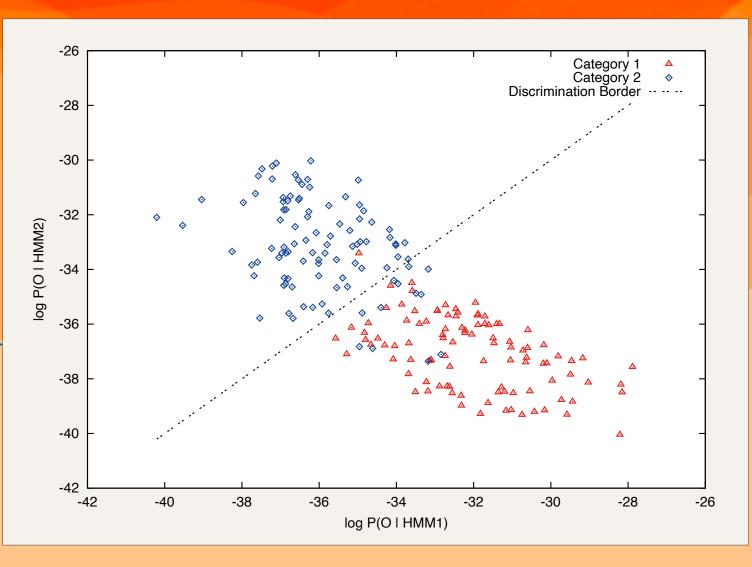


図 5.12 2カテゴリのパターン認識。点線は識別平面。

本日も時間が余ったら...

- ・単語音声データ(3日目)の録音
- ・認識対象単語が決まっていれば
- ・手順はテキスト第6章参照

【理由】

- ・単語音声の学習データ作成では、 ラベル付け作業がかなりの手間 (約90分)。
- ・録音だけは早めに行っておく。
- 余裕があればラベル付けを始める。

