



人工知能特論II 第7回

二宮 崇

今日の講義の予定

- 系列ラベリングのためのHMM
 - 解析
 - ビタビアルゴリズム
 - 学習
 - 最尤推定
- 教科書
 - 北研二(著) 辻井潤一(編) 言語と計算4 確率的言語モデル 東大出版会
 - C. D. Manning & Hinrich Schütze “FOUNDATIONS OF STATISTICAL NATURAL LANGUAGE PROCESSING” MIT Press, 1999
 - Christopher M. Bishop “PATTERN RECOGNITION AND MACHINE LEARNING” Springer, 2006



系列ラベリングのためのHMM

HMM FOR SEQUENTIAL LABELING



品詞解析

- 品詞タガー

"I have a pen."

トーカーナイザー

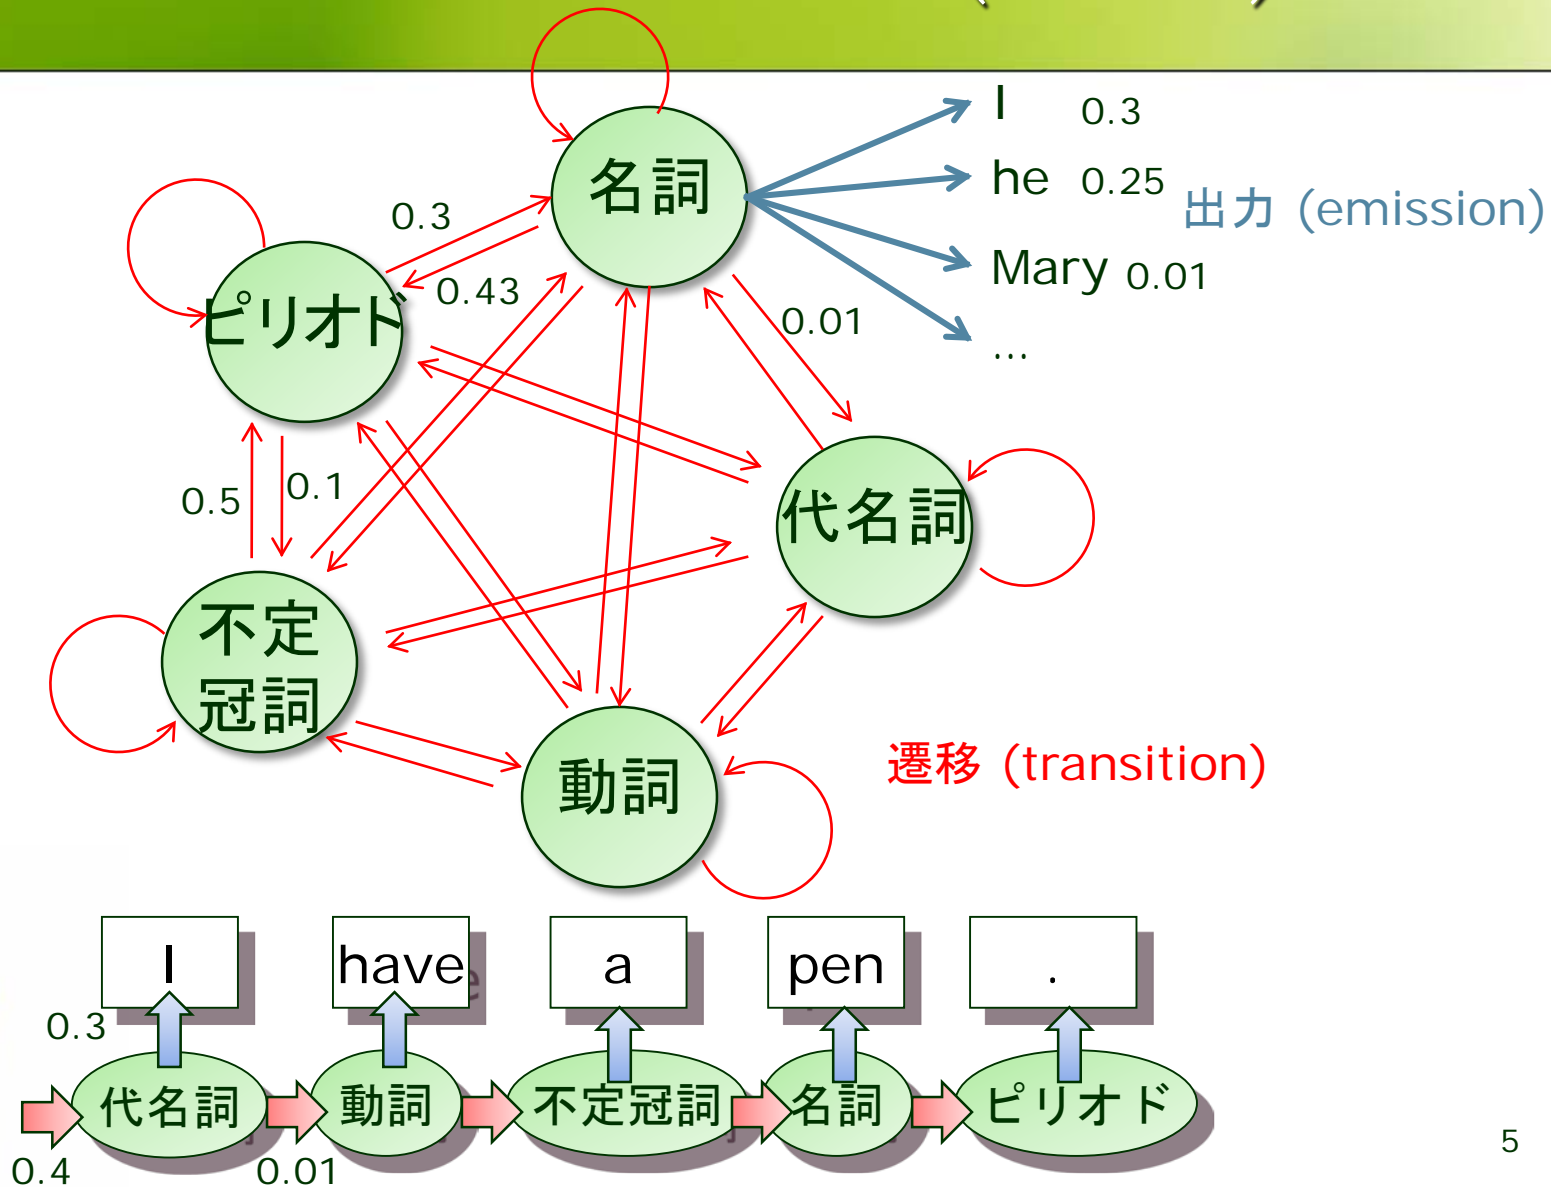
I have a pen .

POSタガー

I have a pen .
代名詞 動詞 不定冠詞 名詞 ピリオド



隠れマルコフモデル Hidden Markov Model (HMM)



隠れマルコフモデル

Hidden Markov Model (HMM)

- Q : 状態の有限集合
- Σ : 出力記号の有限集合
- π_q : 文頭が状態 q になる確率
 - $\sum_{r \in Q} \pi_r = 1$
- $a_{q,r}$: 状態 q から状態 r への遷移確率
 - $\sum_{r \in Q} a_{q,r} = 1$
- $b_{q,o}$: 状態 q における記号 o の出力確率
 - $\sum_{o \in \Sigma} b_{q,o} = 1$



状態記号列の確率と 生成確率

- 状態と記号の列が与えられた時

状態記号列: $q_1 o_1 q_2 o_2 \cdots q_T o_T$

$$\begin{aligned} p(q_1 o_1 q_2 o_2 \cdots q_T o_T) &= \pi_{q_1} b_{q_1, o_1} a_{q_1, q_2} b_{q_2, o_2} \cdots a_{q_{T-1}, q_T} b_{q_T, o_T} \\ &= \pi_{q_1} a_{q_1, q_2} \cdots a_{q_{T-1}, q_T} b_{q_1, o_1} b_{q_2, o_2} \cdots b_{q_T, o_T} \\ &= \pi_{q_1} \prod_{t=2}^T a_{q_{t-1}, q_t} \prod_{t=1}^T b_{q_t, o_t} \end{aligned}$$

- 記号列のみが与えられた時

記号列: $o_1 o_2 \cdots o_T$

$$p(o_1 o_2 \cdots o_T) = \sum_{q_1 \in Q, q_2 \in Q, \cdots, q_T \in Q} p(q_1 o_1 q_2 o_2 \cdots q_T o_T) \quad (\text{生成確率})$$



推論(INFERENCE)
解析(ANALYSIS)
タグ付け(TAGGING)
復号化(DECODING)



解析

- 解析 (入力: $o_1o_2\dots o_T$)

$$\tilde{q}_1\tilde{q}_2\cdots\tilde{q}_T = \arg \max_{q_1 \in Q, q_2 \in Q, \dots, q_T \in Q} p(q_1o_1q_2o_2\cdots q_To_T)$$

しかし、計算量は $O(|Q|^T)$!




効率的な品詞解析: ビタビアルゴリズム

● 動的計画法

$\delta(t, q)$: 時刻 t (o_t が出力される時)に状態 q となる状態列の中で最大確率となる列の確率

$\max_{q \in Q} \delta(T, q)$ を求めれば良い




トレリス



効率的な品詞解析: ビタビアルゴリズム

$$\begin{aligned}
 \delta(t, q) &= \max_{q_1 \in Q, \dots, q_{t-1} \in Q} p(q_1 o_1 \dots q_{t-1} o_{t-1}) a_{q_{t-1}, q} b_{q, o_t} \\
 &= \max_{q_{t-1} \in Q} \left\{ \max_{q_1 \in Q, \dots, q_{t-2} \in Q} \left\{ p(q_1 o_1 \dots q_{t-2} o_{t-2}) a_{q_{t-2}, q_{t-1}} b_{q_{t-1}, o_{t-1}} \right\} a_{q_{t-1}, q} b_{q, o_t} \right\} \\
 &= \max_{q_{t-1} \in Q} \delta(t-1, q_{t-1}) a_{q_{t-1}, q} b_{q, o_t}
 \end{aligned}$$

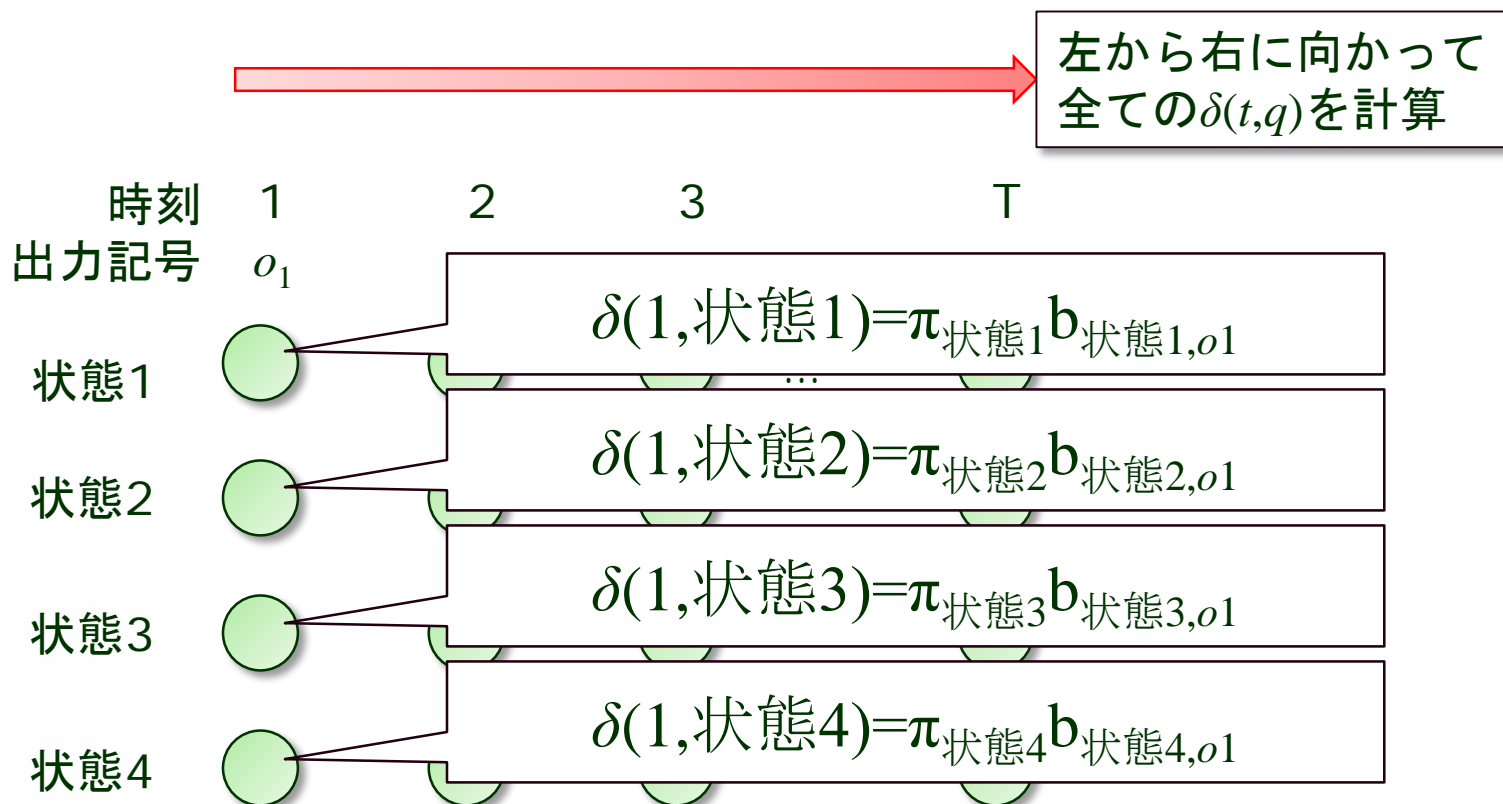
最大確率で遷移したパスをバックポインタで保存



効率的な品詞解析: ビタビアルゴリズム

● 動的計画法

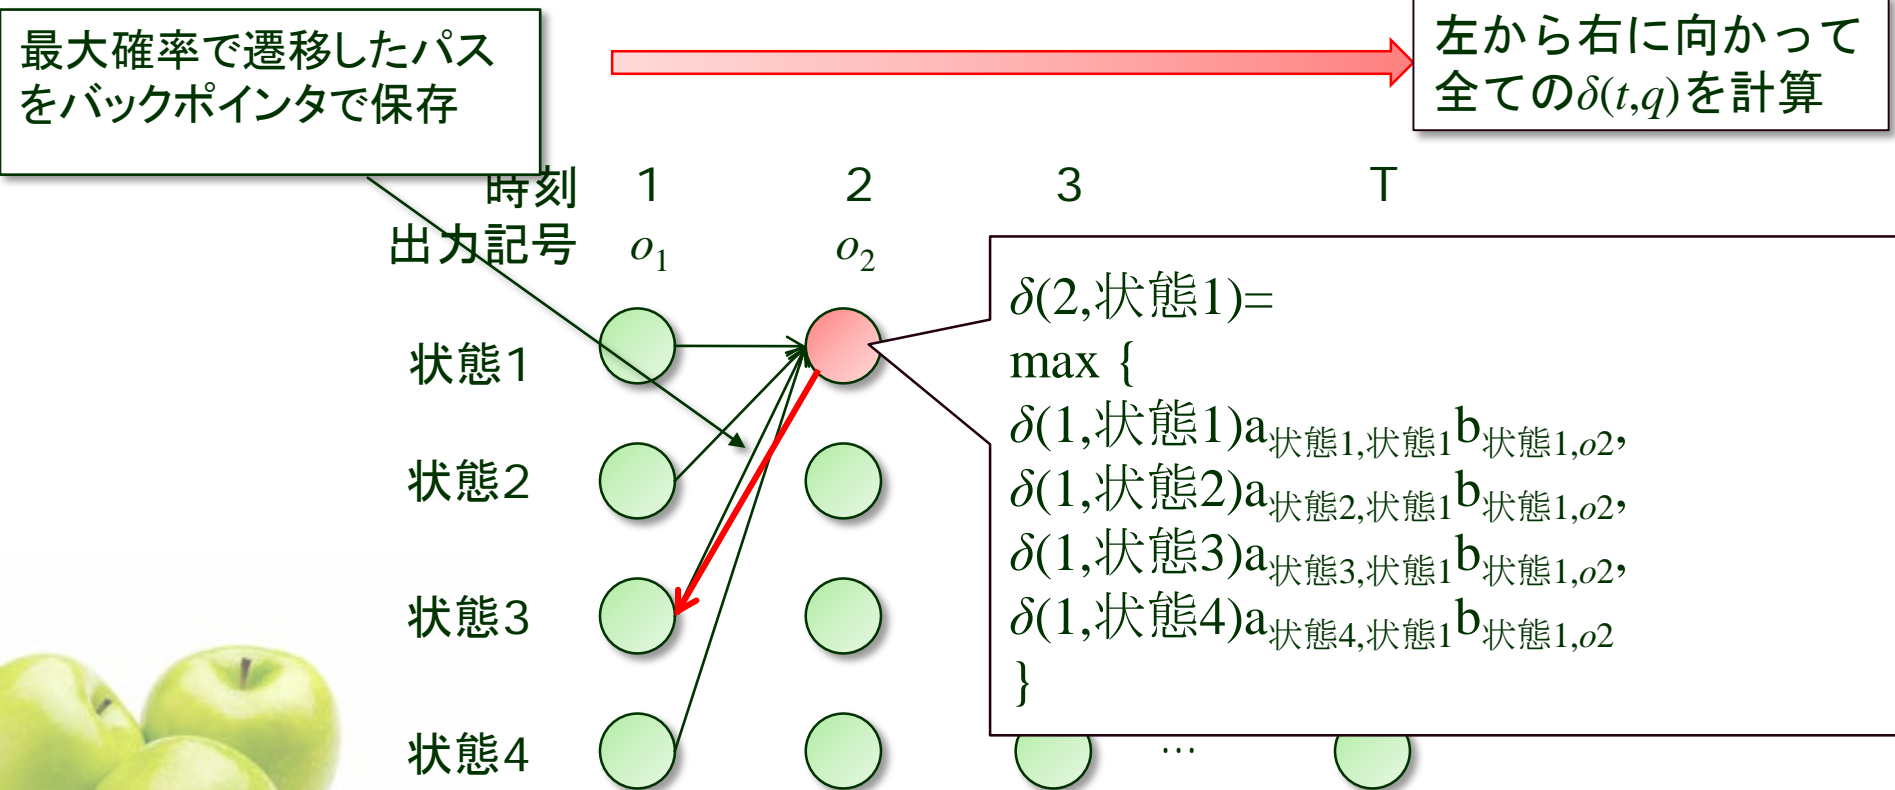
$\delta(t, q)$: 時刻 $t(o_t$ が出力される時)に状態 q となる状態列の中で最大確率となる列の確率



効率的な品詞解析: ビタビアルゴリズム

動的計画法

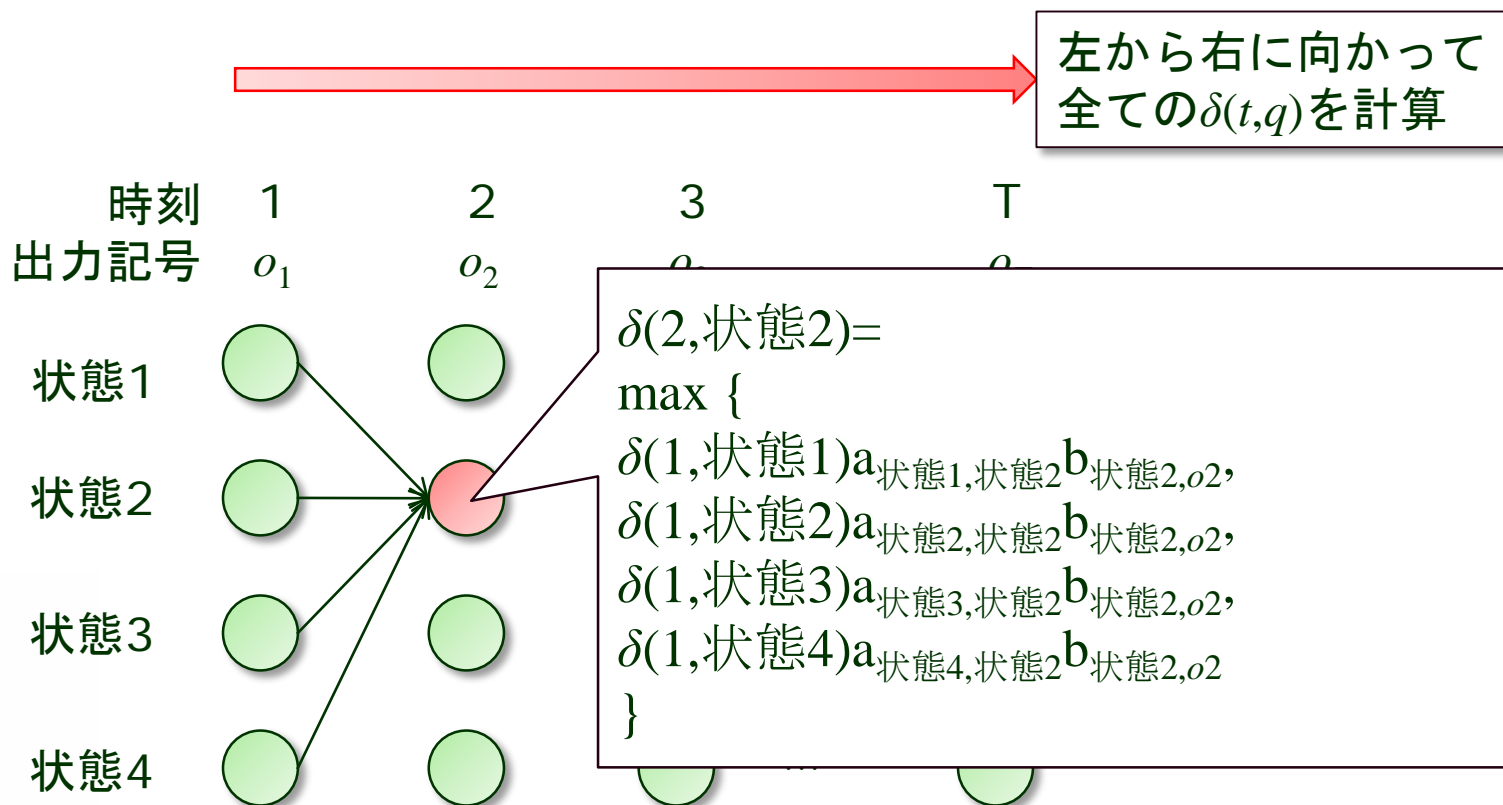
$\delta(t, q)$: 時刻 t (o_t が出力される時)に状態 q となる状態列の中で最大確率となる列の確率



効率的な品詞解析: ビタビアルゴリズム


● 動的計画法

$\delta(t, q)$: 時刻 t (o_t が出力される時)に状態 q となる状態列の中で最大確率となる列の確率



効率的な品詞解析: ビタビアルゴリズム

- 最後にバックポインタを辿ることで最大確率となる状態列が得られる



効率的な品詞解析: ビタビアルゴリズム

$\delta[1,q] := \pi[q]b[q, o_1]$ (for all q)

for $t = 2$ to T

for $q \in Q$

$\delta[t, q] := \max_{q' \in Q} \{\delta[t-1, q']a[q', q]b[q, o_t]\}$

$bp[t, q] := \operatorname{argmax}_{q' \in Q} \{\delta[t-1, q']a[q', q]b[q, o_t]\}$



学習 (パラメータ推定): 最尤推定



パラメータ推定: 最尤推定

- 最尤推定

- 文の集合を観測したとき、その文の集合がそこに出現したのは、その文の集合が最も確率が高かったから、と考えるやり方
- コインの例：表がでる確率 θ が未知のコインがある。100回投げたところ、62回表がでた。すると、その確率は $\theta^{62}(1-\theta)^{38}$ となる。この確率は $\theta=0.62$ で最大となるので、 θ は0.62であったのだろう、と考えるのが最尤推定の考え方である。



最尤推定

- 最尤推定

- 観測値 x_1, \dots, x_n が与えられた時、それぞれが独立に出現したと考えると、その確率はパラメータ θ の関数になる

$$p(x_1, \dots, x_n) = \prod_{i=1}^n p(x_i; \theta) = l(\theta)$$

- この $l(\theta)$ を尤度 (likelihood) もしくは尤度関数 (likelihood function) と呼ぶ
- 尤度関数を最大化する θ を求める

$$\tilde{\theta} = \arg \max_{\theta} l(\theta)$$



最尤推定

- 最大を求めるために尤度関数の極値を求める

$$\frac{\partial}{\partial \theta} l(\theta) = 0$$

- コインの例を解析的に解いてみよう
 - $l(\theta) = \theta^{62}(1 - \theta)^{38}$



最尤推定

- 対数尤度(log likelihood)を使うと計算が楽になる

$$\tilde{\theta} = \arg \max_{\theta} l(\theta) = \arg \max_{\theta} \log l(\theta)$$

- コインの例で解いてみよう
 - $\log l(\theta) = \log(\theta^{62}(1 - \theta)^{38})$



最尤推定

- 正規分布の最尤推定

- 正規分布 $N(\mu, \sigma^2)$ から抽出された標本を x_1, \dots, x_n とする

- 尤度
$$l(\mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x_i - \mu)^2}{2\sigma^2}\right]$$

- 対数尤度

$$\begin{aligned} \log l(\mu, \sigma^2) &= \sum_{i=1}^n \log \frac{1}{\sqrt{2\pi}\sigma} + \sum_{i=1}^n \left[-\frac{(x_i - \mu)^2}{2\sigma^2} \right] \\ &= -n \log(\sqrt{2\pi}\sigma) - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2} \end{aligned}$$



ラグランジュの未定乗数法

- ラグランジュの未定乗数法

$$\arg \max_{\boldsymbol{\theta}} f(\boldsymbol{\theta}) \text{ ただし } g_1(\boldsymbol{\theta}) = 0, \dots, g_m(\boldsymbol{\theta}) = 0$$

⇒

$$L(\boldsymbol{\theta}) = f(\boldsymbol{\theta}) - \lambda_1 g_1(\boldsymbol{\theta}) - \dots - \lambda_m g_m(\boldsymbol{\theta})$$

$$\frac{\partial L}{\partial \theta_1} = 0, \frac{\partial L}{\partial \theta_2} = 0, \dots, \frac{\partial L}{\partial \theta_n} = 0$$

- $L(\boldsymbol{\theta})$ はラグランジュ関数と呼ばれる



まとめ

- HMM
 - 解析
 - ビタビアルゴリズム
 - 学習
 - 最尤推定
- 資料

<http://aiweb.cs.ehime-u.ac.jp/~ninomiya/ai2/>

