



知的情報処理システム特論 第10回

二宮 崇

# 今日の講義の予定

- 系列ラベリングのためのHMM
  - 学習
    - 最尤推定
    - HMMの教師付き学習
- 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

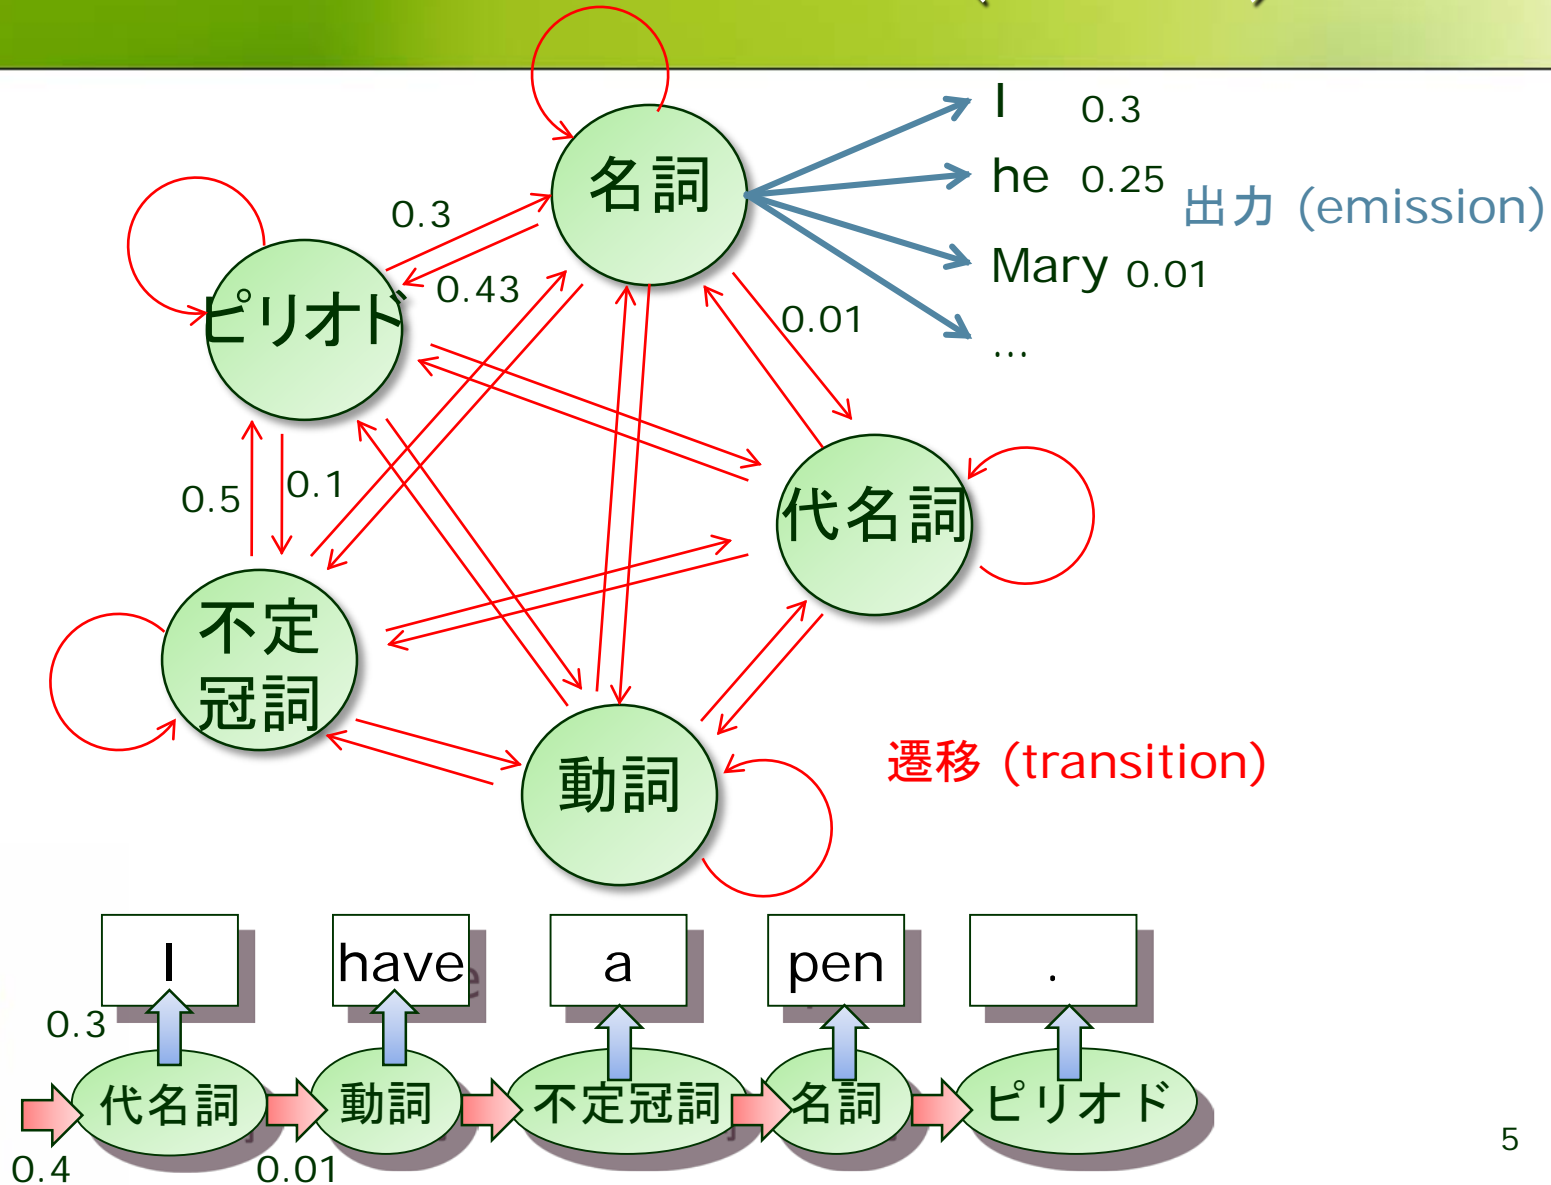
I have a pen .

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
- $\Sigma$ : 出力記号の有限集合
- $\pi_q$ : 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:  $o_1 o_2 \cdots o_T$

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



# 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 $\theta$ 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、 $\theta$ 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  $\theta$  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  $\theta$  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



# 学習 (パラメータ推定): HMMの 教師付学習



# HMMの教師付学習

## Supervised Learning of HMMs

- パラメータ推定

- 訓練データ (入力)

訓練データ:  $x_1 x_2 \cdots x_n, y_1 y_2 \cdots y_n$

$x_i$ : 文を表す記号列(単語列)。  $x_i = o_{i1} o_{i2} o_{i3} \cdots o_{iT_i}$  とする。

$T_i$ :  $x_i$  の記号列長

$y_i$ :  $x_i$  に対応する正解状態列(正解品詞列)。  $y_i = q_{i1} q_{i2} q_{i3} \cdots q_{iT_i}$  とする。

- パラメータ (出力)

$\pi_q$  ...  $|Q|$ 個の変数

$a_{q,r}$  ...  $|Q| \times |Q|$ 個の変数

$b_{q,o}$  ...  $|Q| \times |\Sigma|$ 個の変数



# HMMの教師付学習

## Supervised Learning of HMMs

- パラメータ推定

$$\begin{aligned}\pi, a, b &= \arg \max_{\pi, a, b} \prod_{i=1}^n p(x_i, y_i) \\ &= \arg \max_{\pi, a, b} \prod_{i=1}^n p(q_{i1} o_{i1} q_{i2} o_{i2} \cdots q_{iT_i} o_{iT_i}) \\ &= \arg \max_{\pi, a, b} \prod_{i=1}^n \pi_{q_{i1}} \prod_{t=2}^{T_i} a_{q_{i(t-1)}, q_{it}} \prod_{t=1}^{T_i} b_{q_{it}, o_{it}}\end{aligned}$$



# HMMの教師付学習

## Supervised Learning of HMMs

- パラメータ推定

$$l(\pi, a, b) = \prod_{i=1}^n \pi_{q_{i1}} \prod_{t=2}^{T_i} a_{q_{i(t-1)}, q_{it}} \prod_{t=1}^{T_i} b_{q_{it}, o_{it}}$$

$$\log l(\pi, a, b) = \sum_{i=1}^n \left( \log \pi_{q_{i1}} + \sum_{t=2}^{T_i} \log a_{q_{i(t-1)}, q_{it}} + \sum_{t=1}^{T_i} \log b_{q_{it}, o_{it}} \right)$$

制約付き最適化問題

$$\begin{aligned} & \arg \max_{\pi, a, b} \log l(\pi, a, b) \\ \text{s.t.} \quad & \sum_{q \in Q} \pi_q = 1 \\ & \sum_{r \in Q} a_{q,r} = 1 \quad (\text{for all } q) \\ & \sum_{o \in \Sigma} b_{q,o} = 1 \quad (\text{for all } q) \end{aligned}$$

# HMMの教師付学習

## Supervised Learning of HMMs

- ラグランジュの未定乗数法

ラグランジュ関数

$L(\pi, a, b)$

$$\begin{aligned} &= \log l(\pi, a, b) - \rho \left( 1 - \sum_{q \in Q} \pi_q \right) - \sum_{q \in Q} \alpha_q \left( 1 - \sum_{r \in Q} a_{q,r} \right) - \sum_{q \in Q} \beta_q \left( 1 - \sum_{o \in \Sigma} b_{q,o} \right) \\ &= \sum_{i=1}^n \left( \log \pi_{q_{i1}} + \sum_{t=2}^{T_i} \log a_{q_{i(t-1)}, q_{it}} + \sum_{t=1}^{T_i} \log b_{q_{it}, o_{it}} \right) - \rho \left( 1 - \sum_{q \in Q} \pi_q \right) - \sum_{q \in Q} \alpha_q \left( 1 - \sum_{r \in Q} a_{q,r} \right) - \sum_{q \in Q} \beta_q \left( 1 - \sum_{o \in \Sigma} b_{q,o} \right) \end{aligned}$$

ラグランジュ乗数

$\rho$  ... 1個の変数

$\alpha_q$  ...  $|Q|$ 個の変数

$\beta_q$  ...  $|Q|$ 個の変数



# HMMの教師付学習

## Supervised Learning of HMMs

- $\pi_q$ を求める

$$\frac{\partial L}{\partial \pi_q} = \frac{C_1(q)}{\pi_q} + \rho = 0$$

$$\text{ただし、} C_1(q) = \sum_{i=1}^n [q_{i1} = q]$$

$$\pi_q = \frac{C_1(q)}{-\rho} \quad \dots(1)$$

ところで  $\sum_{q \in Q} \pi_q = 1$  であるから

$$\sum_{q \in Q} \pi_q = \frac{\sum_{q \in Q} C_1(q)}{-\rho} = \frac{n}{-\rho} = 1$$

よって、 $\rho = -n$ 。これを式(1)に代入して、

$$\pi_q = \frac{C_1(q)}{n}$$

アイバーソンの記法  
(Iverson bracket)

$$[P] = \begin{cases} 1 & \text{if } P \text{ is true} \\ 0 & \text{otherwise} \end{cases}$$

$C_1(q)$ は訓練データ中で、文の先頭が $q$ になっている回数

# HMMの教師付学習

## Supervised Learning of HMMs

- $a_{q,r}$ を求める

$$\frac{\partial L}{\partial a_{q,r}} = \frac{C(q,r)}{a_{q,r}} + \alpha_q = 0$$

ただし、 $C(q,r) = \sum_{i=1}^n \sum_{t=2}^{T_i} [q_{i(t-1)} = q][q_{it} = r]$

$$a_{q,r} = \frac{C(q,r)}{-\alpha_q} \quad \dots(1)$$

ところで  $\sum_{r \in Q} a_{q,r} = 1$  であるから

$$\sum_{r' \in Q} a_{q,r'} = \frac{\sum_{r' \in Q} C(q,r')}{-\alpha_q} = 1$$

よって、 $\alpha_q = -\sum_{r' \in Q} C(q,r')$ 。これを式(1)に代入して、

$$a_{q,r} = \frac{C(q,r)}{\sum_{r' \in Q} C(q,r')}$$

$C(q,r)$ は訓練データ中で、状態 $q$ から状態 $r$ に遷移した回数

# HMMの教師付学習

## Supervised Learning of HMMs

- $b_{q,o}$ を求める

$$\frac{\partial L}{\partial b_{q,o}} = \frac{C(q,o)}{b_{q,o}} + \beta_q = 0$$

$$\text{ただし、 } C(q,o) = \sum_{i=1}^n \sum_{t=1}^{T_i} [q_{it} = q][o_{it} = o]$$

$$b_{q,o} = \frac{C(q,o)}{-\beta_q} \quad \dots(1)$$

ところで  $\sum_{o \in \Sigma} b_{q,o} = 1$  であるから

$$\sum_{o' \in \Sigma} b_{q,o'} = \frac{\sum_{o' \in \Sigma} C(q,o')}{-\beta_q} = 1$$

よって、 $\beta_q = -\sum_{o' \in \Sigma} C(q,o')$ 。式(1)に代入して、

$$b_{q,o} = \frac{C(q,o)}{\sum_{o' \in \Sigma} C(q,o')} = \frac{C(q,o)}{C(q)}$$

$$\text{ただし、 } C(q) = \sum_{i=1}^n \sum_{t=1}^{T_i} [q_{it} = q]$$

$C(q,o)$ は訓練データ中で、状態 $q$ から記号 $o$ を出力した回数

$C(q)$ は訓練データ中で、状態 $q$ が出現した回数

# HMMの教師付学習

## Supervised Learning of HMMs

- パラメータ推定

$$\pi_q = \frac{C_1(q)}{n} = \frac{\text{先頭の状態が}q\text{になっている文の数}}{\text{全文数}}$$

$$a_{q,r} = \frac{C(q,r)}{\sum_{r' \in Q} C(q,r')} = \frac{q\text{から}r\text{に遷移した回数}}{q\text{から任意の}r\text{に遷移した回数}}$$

$$b_{q,o} = \frac{C(q,o)}{\sum_{o' \in \Sigma} C(q,o')} = \frac{C(q,o)}{C(q)} = \frac{q\text{から}o\text{を出力した回数}}{q\text{の出現回数}}$$

ただし、 $C_1(q) = \sum_{i=1}^n [q_{i1} = q]$

$$C(q,r) = \sum_{i=1}^n \sum_{t=2}^{T_i} [q_{i(t-1)} = q][q_{it} = r]$$

$$C(q,o) = \sum_{i=1}^n \sum_{t=1}^{T_i} [q_{it} = q][o_{it} = o]$$

$$C(q) = \sum_{i=1}^n \sum_{t=1}^{T_i} [q_{it} = q]$$

# まとめ

- HMM
  - 学習
    - 最尤推定
    - 教師付き学習
- 資料

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

