

# 欠損データがあっても最適なベイズ Chow-Liu アルゴリズム

鈴木讓

大阪大学

2012年10月16日

# Road Map

- ① はじめに
- ② ベイズ型 Chow-Liu アルゴリズム
- ③ 欠損データを含む場合の対応

## おわび

PGM 2012

- 整数計画法を利用した BN の構造推定  
(今回は、成果に関する話がむずかしい)
- 欠損データがあっても最適なベイズ Chow-Liu アルゴリズム

# 研究のねらい

## 機械学習への応用

例から、属性間の確率的依存関係を見出す

- Bayesian Network: 非巡回有向グラフによる表現
- Markov Network: 無向グラフによる表現

## 応用上の要請

- 属性数  $N$  の多項式時間でないと、リアルタイムは無理
- EM とかではなく、不完全データの扱いを容易に扱えないか

## Chow-Liu: 木への近似 (1968)

$X^{(1)}, \dots, X^{(N)}$ :  $N (\geq 1)$  離散 確率変数

$P_{1, \dots, N}(x^{(1)}, \dots, x^{(N)})$ :  $X^{(1)} = x^{(1)}, \dots, X^{(N)} = x^{(N)}$  の分布

$V := \{1, \dots, N\}$  と  $E \subseteq \{\{i, j\} | i \neq j, i, j \in V\}$  が木を構成することを仮定

$$Q_{1, \dots, N}(x^{(1)}, \dots, x^{(N)} | E) = \prod_{\{i, j\} \in E} \frac{P_{ij}(x^{(i)}, x^{(j)})}{P_i(x^{(i)})P_j(x^{(j)})} \prod_{i \in V} P_i(x^{(i)})$$

$D(P_{1, \dots, N} || Q_{1, \dots, N}) \rightarrow \min$


ループができない限り、相互情報量  $I(i, j)$  を最大にする  $\{i, j\}$  を結ぶ

$$I(i, j) := \sum_{x^{(i)}, x^{(j)}} P_{ij}(x^{(i)}, x^{(j)}) \log \frac{P_{ij}(x^{(i)}, x^{(j)})}{P_i(x^{(i)})P_j(x^{(j)})}$$

## 例

$l(i, j)$  を重みにもつ Kruscal のアルゴリズム

|           |    |    |   |   |   |   |
|-----------|----|----|---|---|---|---|
| $i$       | 1  | 1  | 2 | 1 | 2 | 3 |
| $j$       | 2  | 3  | 3 | 4 | 4 | 4 |
| $l(i, j)$ | 12 | 10 | 8 | 6 | 4 | 2 |



## Chow-Liu: 木を仮定した最尤推定

## 推定

分布  $P_{1,\dots,N}$  ではなく、 $n$  個の例  $x^n = \{(x_i^{(1)}, \dots, x_i^{(N)})\}_{i=1}^n$  が利用可

$x^n$  の**相対頻度**から得られる:

- $\hat{H}^n(x^n|E)$ : 木を仮定した経験的エントロピー
- $\hat{I}(i,j)$ : 木を仮定した  $\{i,j\}$  の経験的相互情報量

$$\hat{H}^n(x^n|E) \rightarrow \min$$

ループができない限り、 $\hat{I}(i,j)$  を最大にする  $\{i,j\}$  を結ぶ

## Chow-Liu: 木を仮定した Baye 推定 (Suzuki, 1993)

$$R^n(x^n|E) := \prod_{\{i,j\} \in E} \frac{R^n(i,j)}{R^n(i)R^n(j)} \prod_{i \in V} R^n(i)$$

$$R^n(i) := \frac{\Gamma(n + \alpha^{(i)} a) \Gamma(a)^{\alpha^{(i)}}}{\Gamma(\alpha^{(i)} a) \prod_{x^{(i)}} \Gamma(c_i[x^{(i)}] + a)}$$

$$R^n(i,j) := \frac{\Gamma(n + \alpha^{(i)} \alpha^{(j)} a) \Gamma(a)^{\alpha^{(i)} \alpha^{(j)}}}{\Gamma(\alpha^{(i)} \alpha^{(j)} a) \prod_{x^{(i)}, x^{(j)}} \Gamma(c_{i,j}[x^{(i)}, x^{(j)}] + a)}$$

( $a > 0$ ,  $c_i[x^{(i)}], c_{i,j}[x^{(i)}, x^{(j)}]$ : 頻度,  $\alpha^{(i)}$ :  $X^{(i)}$  が何個の値を取るか)

$$\sum_{\{x_k^{(i)}\}_{k=1}^n} R^n(i) = 1, \quad \sum_{\{x_k^{(i)}\}_{k=1}^n, \{x_k^{(j)}\}_{k=1}^n} R^n(i,j) = 1$$



## Chow-Liu: 木を仮定した Baye 推定 (Suzuki, 1993)

$\pi(E)$ : 木  $(V, E)$  の事前確率

$$J(i, j) := \frac{1}{n} \log \frac{R^n(i, j)}{R^n(i)R^n(j)}$$

$\pi(E)R^n(x^n|E) \rightarrow \max$  ( $\pi$ : 木の事前分布、一様とする)

ループができず、 $J(i, j) \geq 0$  である限り、  
 $J(i, j)$  を最大にする  $\{i, j\}$  を結ぶ

## Chow-Liu: 木を仮定した MDL 推定 (Suzuki, 1993)

$$a = 1/2$$

$$L(x^n|E) := -\log R^n(x^n|E) \approx \hat{H}^n(x^n|E) + \frac{1}{2}k(E) \log n$$

$k(E)$ : 木  $(V, E)$  におけるパラメータの個数

$$J(i, j) \approx \hat{l}(i, j) - \frac{1}{2n}(\alpha^{(i)} - 1)(\alpha^{(j)} - 1) \log n$$

$\alpha^{(i)}$ :  $X^{(i)}$  が何個の値を取りうるか

$$L(x^n|E) - \log \pi(E) \rightarrow \min$$

ループができない限り、 $J(i, j)$  を最大にする  $\{i, j\}$  を結ぶ

## ML と MDL

|                   | ML                       | MDL   |
|-------------------|--------------------------|---|
| $E$<br>の選択        | $\hat{H}^n(x^n E)$<br>最小 | $\hat{H}^n(x^n E) + \frac{1}{2}k(E) \log n$<br>最小                               |
| $\{i, j\}$<br>の選択 | $\hat{l}(i, j)$<br>最大    | $\hat{l}(i, j) - \frac{1}{2n}(\alpha^{(i)} - 1)(\alpha^{(j)} - 1) \log n$<br>最大 |
| 基準                | $x^n$ の $E$ での適合性        | $x^n$ の $E$ での適合性<br>$E$ の簡潔性   |

## 欠損データを含む (一般的な) 場合の定式化

 $(V, E)$ (木ではなく) 一般的な森、 $\pi(E)$ : 一定

従来 (欠損データなし): 最大化すべきもの

$$R^n(x^n|E) := \prod_{\{i,j\} \in E} \frac{R^n(i,j)}{R^n(i)R^n(j)} \prod_{i \in V} R^n(i)$$

今回 (欠損データがあってもよい): 最大化すべきもの

$$S^n(x^n|E) := \sum R^n(x^n|E)$$

 $\sum$ : 欠損している値のすべての場合について和

$S^n(x^n|E)$  の性質

$$S^n(x^n|E) := \sum R^n(x^n|E) = \prod_{\{i,j\} \in E} \frac{S^n(i,j)}{S^n(i)S^n(j)} \prod_{i \in V} S^n(i)$$

$$S^n(i) = \sum R^n(i)$$

$$S^n(i,j) = \sum R^n(i,j)$$

$S^n(i, j)$  の計算

$$S^n(i, j) = R_{i \cap j}^n(i, j) R_{i \setminus j}^n(i) R_{j \setminus i}^n(j)$$

$$x^n = \{x_k\}_{k=1}^n, \quad x_k = (x_k^{(1)}, \dots, x_k^{(N)})$$

$$k = \underbrace{1, \dots, r}_{X^{(i)}, X^{(j)}}, \underbrace{r+1, \dots, r+s}_{X^{(i)}}, \underbrace{r+s+1, \dots, r+s+t}_{X^{(j)}}, \underbrace{r+s+t, \dots, n}_{\text{none}}$$

$R_{i \cap j}^n(i, j)$ :  $\{x_k^{(i)}\}_{k=1}^r, \{x_k^{(j)}\}_{k=1}^r$  の予測確率

$R_{i \setminus j}^n(i)$ :  $\{x_k^{(i)}\}_{k=1}^r$  のもとでの  $\{x_k^{(i)}\}_{k=r+1}^{r+s}$  の予測確率

$R_{j \setminus i}^n(j)$ :  $\{x_k^{(j)}\}_{k=1}^r$  のもとでの  $\{x_k^{(j)}\}_{k=r+s+1}^{r+s+t}$  の予測確率

$S^n(i)$  の計算

$$S^n(i) = R_{i \cap j}^n(i) R_{i \setminus j}^n(i)$$

$$x^n = \{x_k\}_{k=1}^n, \quad x_k = (x_k^{(1)}, \dots, x_k^{(N)})$$

$$k = \underbrace{1, \dots, r}_{X^{(i)}, X^{(j)}}, \underbrace{r+1, \dots, r+s}_{X^{(i)}}, \underbrace{r+s+1, \dots, r+s+t}_{X^{(j)}}, \underbrace{r+s+t, \dots, n}_{\text{none}}$$

$R_{i \cap j}^n(i)$ :  $\{x_k^{(i)}\}_{k=1}^r$  の予測確率

$R_{i \setminus j}^n(i)$ :  $\{x_k^{(i)}\}_{k=1}^r$  のもとでの  $\{x_k^{(i)}\}_{k=r+1}^{r+s}$  の予測確率

$S^n(x^n|E)$  の計算

$$S^n(x^n|E) = \prod_{\{i,j\} \in E} \frac{S^n(i,j)}{S^n(i)S^n(j)} \prod_{i \in V} S^n(i) = \prod_{\{i,j\} \in E} \frac{R_{i \cap j}^n(i,j)}{R_{i \cap j}^n(i)R_{i \cap j}^n(j)} \prod_{i \in V} S^n(i)$$

$$J(i,j) := \frac{1}{n} \log \prod_{\{i,j\} \in E} \frac{R_{i \cap j}^n(i,j)}{R_{i \cap j}^n(i)R_{i \cap j}^n(j)}$$



## 結論

- データが完全の場合:  $J(i, j) = \frac{1}{n} \log \frac{R^n(i, j)}{R^n(i)R^n(j)}$
- 一般の場合:  $J(i, j) = \frac{1}{n} \log \frac{R_{i \cap j}^n(i, j)}{R_{i \cap j}^n(i)R_{i \cap j}^n(j)}$

## ベイズ Chow-Liu アルゴリズム

- 欠損データがあっても、ベイズ最適な森を選択することが容易
- 同じ議論が、連続でも、離散と連続が混在でもできる (PGM 2012)