

# 一般的な確率変数に対する Chow-Liu アルゴリズム

鈴木讓

2009 年 12 月 3 日 (木)

## 研究のねらい

まず、Chow-Liu アルゴリズムを一般の確率変数で  
情報理論というと、離散分布と連続分布ばかり

さらに、サンプルから学習する場合の一般化

Chow-Liu アルゴリズムを MDL 基準に適用  
(鈴木, 大嶽, 平澤, 情報処理学会論文誌 1992 年 11 月号)  
有限の確率変数を仮定

## 無向グラフ

$V$ : 有限集合

$E \subseteq \mathcal{E} := \{\{X, Y\} \mid X, Y \in V, X \neq Y\}$

$G = (V, E)$ : 無向グラフ

$V$   $G$  の頂点集合 (要素:  $G$  の頂点)

$E$   $G$  の辺集合 (要素:  $G$  の辺)

### $G$ は森

無向グラフ  $G$  に巡回経路が存在しない

### $G$ は木

森であって連結されている

## Chow-Liu アルゴリズム

$X := (X^{(1)}, \dots, X^{(N)})$ ,  $X^{(j)}$ : 有限の値をとる

### Kullback-Leibler 情報量

$$D(P||Q) := \sum_{x^{(1)}, \dots, x^{(N)}} P(x^{(1)}, \dots, x^{(N)}) \log \frac{P(x^{(1)}, \dots, x^{(N)})}{Q(x^{(1)}, \dots, x^{(N)})}$$

$$Q(x^{(1)}, \dots, x^{(N)}) := \prod_{\pi(j)=0} P_j(x^{(j)}) \prod_{\pi(i) \neq 0} P_{i|\pi(i)}(x^{(i)}|x^{(\pi(i))})$$

### Dendroid 分布 $Q$ への近似 (木への近似)

$D(P||Q)$  最小の  $\pi : \{1, \dots, N\} \rightarrow \{0, 1, \dots, N\}$

$$\pi^k(j) \neq j, \quad k \geq 1, \quad j \in \{1, \dots, N\}$$

# 相互情報量

## $X, Y$ 間の相互情報量

$$I(X, Y) := \sum_{x,y} \mu_{XY}(x, y) \log \frac{P_{XY}(x, y)}{P_X(x)P_Y(y)}$$

$$D(P||Q) = - \sum_{\pi(i) \neq 0} I(X^{(i)}, X^{(\pi(i))}) + (\pi \text{ によらない定数})$$

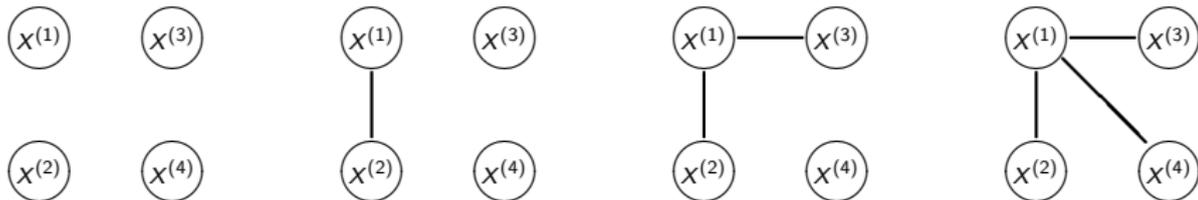
## Chow-Liu アルゴリズム (近似)

$\sum_{\pi(i) \neq 0} I(X^{(i)}, X^{(\pi(i))})$  最大の木を生成する問題に帰着

## Chow-Liu アルゴリズム: 例

1.  $I(1, 2)$  が最大なので、 $X^{(1)}, X^{(2)}$  を結ぶ。
2. それ以外では  $I(1, 3)$  が最大なので、 $X^{(1)}, X^{(3)}$  を結ぶ。
3. それ以外では  $I(2, 3)$  が最大だが、結ぶと巡回経路。
4. それ以外では  $I(1, 4)$  が最大なので、 $X^{(1)}, X^{(4)}$  を結ぶ。
5. これ以上辺を結ぶと巡回経路。

$i$	1	1	2	1	2	3
$j$	2	3	3	4	4	4
$I(i, j)$	12	10	8	6	4	2



## Chow-Liu アルゴリズム: 手順

$$V = \{1, \dots, N\}$$

$I(i, j) := I(X^{(i)}, X^{(j)})$  ( $i \neq j$ ) 相互情報量

1.  $E := \{\}$ ;
2.  $\mathcal{E} := \{\{i, j\} | i \neq j\}$ ;
3.  $I_{ij}$  を最大にする  $\{i, j\} \in \mathcal{E}$  について、 $\mathcal{E} := \mathcal{E} \setminus \{\{i, j\}\}$ ;
4.  $(V, E \cup \{\{i, j\}\})$  が巡回経路を含まないなら、  
 $E := E \cup \{\{i, j\}\}$ ;
5.  $\mathcal{E} \neq \{\}$  なら 3. へ、そうでなければ終わる;

### Chow-Liu アルゴリズム (木の近似)

$G = (V, E)$  から得られる  $Q$  は、 $D(P||Q)$  を最小

## サンプルからはじめたとき、尤度を最大にする

$$P(x^{(1)}, \dots, x^{(N)} | \theta, \pi), \quad \theta = (\theta_1, \dots, \theta_k)$$

$$x^n := \{(x_i^{(1)}, \dots, x_i^{(N)})\}_{i=1}^n$$

$\hat{\theta}(x^n)$ : 最尤推定量 ( $\log P(x^n | \theta, \pi)$  最大の  $\theta$ )

$$\begin{aligned} I_n(i, j) &:= \sum_{x, y} P_{i,j}(x, y | \hat{\theta}, \pi) \log \frac{P_{i,j}(x, y | \hat{\theta}, \pi)}{P_i(x | \hat{\theta}, \pi) P_j(y | \hat{\theta}, \pi)} \\ &= \frac{1}{n} \sum_{x, y} c_{i,j}(x, y) \log \frac{c_{i,j}(x, y)}{c_i(x) c_j(y)} \end{aligned}$$

$$H(\pi, x^n) := -\log P(x^n | \hat{\theta}(x^n), \pi) = - \sum_{\pi(i) \neq 0} I_n(i, \pi(i)) + (\text{const})$$

Chow-Liu アルゴリズム: 尤度最大 (経験的エントロピー最小)

$I(i, \pi(i))$  を  $I_n(i, \pi(i))$  におきかえるだけ

## サンプルからはじめたとき、記述長を最大にする

$$Q(x) := \int P(x|\theta, \pi) w(\theta) d\theta, \quad \int w(\theta) d\theta = 1$$

$\alpha^{(i)}$ :  $X^{(i)}$  のとりうる値の数 ( $i = 1, \dots, N$ ), ( $\alpha^{(0)} := 1$ )

$$k = \sum_{\pi(i) \neq 0} (\alpha^{(i)} - 1)(\alpha^{(\pi(i))} - 1)$$

$$J_n(i, j) := I_n(i, j) - \frac{1}{2}(\alpha^{(i)} - 1)(\alpha^{(j)} - 1) \log n$$

$$\begin{aligned} L(\pi, x^n) &:= -\log Q(x^n) \\ &= -\log P(x^n | \hat{\theta}(x^n), \pi) + \frac{k(\pi)}{2} \log n + (\text{const}) \\ &\quad - \sum_{\pi(i) \neq 0} \left\{ I_n(i, \pi(i)) - \frac{1}{2}(\alpha^{(i)} - 1)(\alpha^{(\pi(i))} - 1) \right\} \\ &= - \sum_{\pi(i) \neq 0} J_n(i, \pi(i)) \end{aligned}$$

## サンプルからはじめたとき、記述長を最大にする (続)

1.  $E = \{\}$ ;
  2.  $\mathcal{E} := \{\{i, j\} | i \neq j\}$ ;
  3.  $J_n(i, j)$  を最大にする  $\{i, j\} \in \mathcal{E}$  について  $\mathcal{E} := \mathcal{E} \setminus \{\{i, j\}\}$ ;
  4.  $J_n(i, j) \geq 0$  and  $(V, E \cup \{\{i, j\}\})$  がループを含まなければ,  
 $E := E \cup \{\{i, j\}\}$ ;
  5.  $\mathcal{E} \neq \{\}$  であれば 3. へ, そうでなければ終わる
- ▶ 木でなく森をつくる ( $J_n < 0$  で停止)
  - ▶ 各辺を結ぶか否かで、適合度だけでなく、辺の複雑さを考慮

(鈴木 大嶽 平澤, 1992)

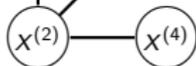
### 辺を選択する順序

$\{I_n(i, j)\}_{i \neq j}, \{J_n(i, j)\}_{i \neq j}$  で辺を選択する順序が異なる

## サンプルからはじめたとき、記述長を最大にする (続)

- $J_n(1, 2) = 8$  が最大なので、 $X^{(1)}, X^{(2)}$  を結ぶ。
- $J_n(2, 3) = 6$  が最大なので、 $X^{(2)}, X^{(3)}$  を結ぶ。
- $X^{(1)}, X^{(3)}$  を結ぶと巡回経路が出来る。
- $I_n(2, 4) = 1$  が最大なので、 $X^{(2)}, X^{(4)}$  を結ぶ。
- $J_n < 0$  となる辺、巡回経路ができる辺は結ばない。

$i$	$j$	$I_n(i, j)$	$\alpha^{(i)}$	$\alpha^{(j)}$	$J_n(i, j)$
1	2	12	5	2	8
1	3	10	5	3	2
2	3	8	2	3	6
1	4	6	5	4	-6
2	4	4	2	4	1
3	4	2	3	4	-4



## 離散や連続は、むしろ特殊ケース

確率  $1/2$  で  $X = -1$

確率  $1/2$  で  $X = x \geq 0$  ( $\int_0^\infty f(x)dx = 1$ )

$$F_X(x) = \begin{cases} 0 & x < -1 \\ \frac{1}{2} & -1 \leq x < 0 \\ \int_0^x \frac{1}{2} f(t) dt & 0 \leq x \end{cases}$$

$F_X$  には確率密度関数は存在しないし、離散分布でもない

## 一般的な確率変数

$(\Omega, \mathcal{F}, \mu)$ : 確率空間

$\mathcal{B}$ :  $\mathbb{R}$  の Borel 集合族

$X : \Omega \rightarrow \mathbb{R}$  が  $(\Omega, \mathcal{F}, \mu)$  における確率変数

$$D \in \mathcal{B} \implies \{\omega \in \Omega \mid X(\omega) \in D\} \in \mathcal{F}$$

$X$  の確率測度  $\mu_X : \mathcal{B} \rightarrow \mathbb{R}$

$$\mu_X(D) := \mu(\{\omega \in \Omega \mid X(\omega) \in D\})$$

# 一般的な確率変数に対する Chow-Liu アルゴリズム

## Kullback-Leibler 情報量

$\mu \ll \nu$  のとき

$$D(\mu||\nu) := \int_{\Omega} d\mu \log \frac{d\mu}{d\nu}$$

$$\frac{d\mu}{d\nu} := f \text{ s.t. } \mu = \int f d\nu \text{ (Radon-Nykodim)}$$

## $X, Y$ の相互情報量

$$I(X, Y) := \int_{\Omega} d\mu_{XY} \log \frac{d^2\mu_{XY}}{d\mu_X d\mu_Y}$$

$$\frac{d\mu_{XY}}{d\mu_X d\mu_Y} := g \text{ s.t. } \mu_{XY} = \int g d\mu_X d\mu_Y \text{ (Radon-Nykodim)}$$

## 一般的な Dendoroid 分布近似

### 一般の Dendoroid 分布

任意の  $D_1, \dots, D_N \in \mathcal{B}$  について

$$\nu(D_1, \dots, D_N) = \prod_{\pi(i) \neq 0} \frac{\mu_{i, \pi(i)}(D_i, D_{\pi(i)})}{\mu_i(D_i) \mu_{\pi(i)}(D_{\pi(i)})} \cdot \prod_{i=1}^N \mu_i(D_i)$$

$\eta(D_1, \dots, D_N) := \prod_{i=1}^N \mu_i(D_i)$  とおくと、 $\mu \ll \eta$  より

$$\frac{d\nu}{d\eta} = \prod_{\pi(i) \neq 0} \frac{d^2 \mu_{i, \pi(i)}}{d\mu_i d\mu_{\pi(i)}}$$

と同値になる (証明略)

## 一般的な確率変数にも Chow-Liu アルゴリズムは適用できる

スケッチ:

$$\frac{d\mu}{d\nu} = \frac{d\mu}{d\eta} / \frac{d\nu}{d\eta} = \left[ \prod_{\pi(i) \neq 0} \frac{d^2 \mu_{i, \pi(i)}}{d\mu_i d\mu_{\pi(i)}} \right]^{-1} \frac{d\mu}{d\eta}$$

$$\begin{aligned} E \log \frac{d\mu}{d\nu}(X^{(1)}, \dots, X^{(N)}) &= - \sum_{\pi(i) \neq 0} E \log \frac{d^2 \mu_{i, \pi(i)}}{d\mu_i d\mu_{\pi(i)}}(X^{(i)}, X^{(\pi(i))}) \\ &\quad + E \log \frac{d\mu}{d\eta}(X^{(1)}, \dots, X^{(N)}) \end{aligned}$$

$$D(\mu || \nu) = - \sum_{\pi(i) \neq 0} I(X^{(i)}, X^{(\pi(i))}) + (\text{const})$$

例: すべての確率変数が Gauss 分布の場合

$$X^{(i)} \sim N(0, \sigma^2)$$

$$(X^{(i)}, X^{(j)}) \sim N(0, \Sigma), \Sigma = \begin{bmatrix} \sigma_{ii} & \sigma_{ij} \\ \sigma_{ji} & \sigma_{jj} \end{bmatrix}$$

$$\rho_{ij} := \frac{\sigma_{ij}}{\sqrt{\sigma_{ii}\sigma_{jj}}} \text{ (相関関数)}$$

$$\begin{aligned} I(i, j) &= \int \int f_{i,j}(x^{(i)}, x^{(j)}) \log \frac{f_{i,j}(x^{(i)}, x^{(j)})}{f_i(x^{(i)})f_j(x^{(j)})} dx^{(i)} dx^{(j)} \\ &= \log \frac{\sqrt{\sigma_{ii}\sigma_{jj}}}{|\Sigma|^{\frac{1}{2}}} = -\frac{1}{2} \log(1 - \rho_{ij}^2) \end{aligned}$$

Chow-Liu アルゴリズムへの適用

$\rho_{ij}$  から  $I(i, j)$  を求めればよい

## 記述長最小: 2 確率変数が Gauss 分布の場合

$$\bar{x}^{(i)} = \frac{1}{n} \sum_{h=1}^n x_h^{(i)}, \hat{\sigma}_{ij} := \frac{1}{n} \sum_{h=1}^n (\bar{x} - x_h^{(i)})(\bar{x} - x_h^{(j)}), \hat{\rho}_{ij} := \frac{\hat{\sigma}_{ij}}{\sqrt{\hat{\sigma}_{ii}\hat{\sigma}_{jj}}}$$

$$l_n(i, j) := -\frac{1}{2} \log(1 - \hat{\rho}_{ij}^2)$$

$$H(\pi, x^n) = - \sum_{\pi(i) \neq 0} l_n(i, \pi(i)) + (\text{const})$$

## 記述長最小: 2 確率変数が Gauss 分布の場合 (続)

$$J_n(i, j) = I_n(i, j) - \frac{1}{2} \log n$$

$$\begin{aligned} L(\pi, x^n) &= - \sum_{\pi(i) \neq 0} I_n(i, \pi(i)) + \frac{k}{2} \log n + (\text{const}) \\ &= - \sum_{\pi(i) \neq 0} \{I_n(i, \pi(i)) - \frac{1}{2} \log n\} + (\text{const}) \\ &= - \sum_{\pi(i) \neq 0} J_n(i, \pi(i)) + (\text{const}) \end{aligned}$$

2 確率変数が Gauss 分布: 確率パラメータは 1 個増える

$$J_n(i, j) := I_n(i, j) - \frac{1}{2} \log n$$

$\{I_n(i, j)\}_{i \neq j}, \{J_n(i, j)\}_{i \neq j}$  で辺を選択する順序は同じ

## 記述長最小: 2 確率変数が Gauss 分布と有限分布の場合

- ▶  $X^{(i)}$ : Gauss
- ▶  $X^{(j)}$ : 有限 ( $\alpha^{(j)}$  通り)

$$I(i, j) = \sum_{y \in X^{(j)}} \mu_j(y) \int_{x \in X^{(i)}} f_{i,j}(x|y) \log \frac{f_{i,j}(x|y)}{\sum_{z \in X^{(j)}} \mu_j(z) f_{i,j}(x|z)} dx$$

$$g : X^{(j)}(\Omega) \rightarrow \mathbb{R}$$

- ▶  $X^{(i)} = \epsilon_i \sim \mathcal{N}(g(X^{(j)}), \phi_i)$
- ▶  $Eg(X^{(j)}) = 0$  (パラメータ数 1 個少ない)

## 記述長最小: 2 確率変数が Gauss 分布と有限分布の場合 (続)

$\alpha^{(j)}$  個のパラメータ  $g(y)$ ,  $y \in X^{(j)}(\Omega)$  を推定  
 $\sum_{y \in X^{(j)}(\Omega)} \mu_j(y)g(y) = 0$  の制約

確率パラメータは  $\alpha^{(j)} - 1$  個だけ増える

$$J_n(i, j) := I_n(i, j) - \frac{(\alpha^{(j)} - 1)}{2} \log n$$

$\{I_n(i, j)\}_{i \neq j}, \{J_n(i, j)\}_{i \neq j}$  で辺を選択する順序は異なる

## 記述長最小: まとめ

$d_n := \log n$  は任意の非負実数列  $\{d_n\}$  でよい

$X^{(i)}, X^{(j)}$ : 有限  $J_n(i, j) = I_n(i, j) - \frac{1}{2}(\alpha^{(i)} - 1)(\alpha^{(j)} - 1)d_n$

$X^{(i)}, X^{(j)}$ : Gauss  $J_n(i, j) = I_n(i, j) - \frac{1}{2}d_n$

$X^{(i)}$ : Gauss,  $X^{(j)}$ : 有限  $J_n(i, j) = I_n(i, j) - \frac{1}{2}(\alpha^{(j)} - 1)d_n$

### 辺を選択する順序

有限分布にしたがう確率変数が存在すれば、  
 $\{I_n(i, j)\}_{i \neq j}, \{J_n(i, j)\}_{i \neq j}$  で辺を選択する順序が異なる

## 本講演のまとめ

### 一般的な Chow-Liu アルゴリズム

相互情報量  $I = (I_{ij})_{i \neq j}$

$$I_{ij} = \int d\mu_{ij} \log \frac{d^2 \mu_{ij}}{d\mu_i d\mu_j}$$

Dendroid 測度が得られる

### 一般的な Chow-Liu アルゴリズム (記述長最小バージョン)

- ▶ 有限分布のみ
- ▶ Gauss 分布のみ
- ▶ 有限と Gauss が混在

将来的に、おもしろいバリエーションが得られそう