

# 実数値と角度の観測が混在するデータのためのベイジアンネットワーク

加藤 昇吾 数理・推論研究系 准教授

はじめに

## ベイジアンネットワーク

ベイジアンネットワーク ... グラフィカルモデルの1つ。有向非巡回グラフを通して変数間の依存構造を表す。




図. ベイジアンネットワーク.

それぞれの変数は、実数値や離散値など様々な種類の観測がありうる。

## 研究の目的

変数として、**角度**  $[-\pi, \pi)$  の観測が得られることがある。

(例. 風向, 鳥の移動方向, 銃犯罪が起こる時刻, など.)

本研究では、**実数値と角度の観測が混在するデータのための木構造のベイジアンネットワーク**を提案する。

なお本研究は、Ignacio Leguey氏, Concha Bielza教授, Pedro Larrañaga教授 (Technical University of Madrid, Spain) との共同研究である。

## ベイジアンネットワーク

## モデル

$X_1, \dots, X_p$  を実数値の確率変数,  $\Theta_1, \dots, \Theta_q$  を角度  $[-\pi, \pi)$  の確率変数,

とする。親ノードと子ノードの同時分布に以下を仮定する:

$$(X_j, X_k) \sim 2\text{変量正規分布 } N(\mu_j, \mu_k, \sigma_j^2, \sigma_k^2, \rho_{jk}),$$

$$(\Theta_j, \Theta_k) \sim \text{Kato \& Pewsey (2015) の分布},$$

$$(X_j, \Theta_k) \sim \text{Johnson \& Wehrly (1978) の分布の特別な場合}.$$

ただし, Kato & Pewsey (2015) の分布は密度関数

$$f(\theta_j, \theta_k) = C \left\{ c_0 + c_1 \cos(\theta_j - \eta_j) + c_2 \cos(\theta_k - \eta_k) + c_3 \cos(\theta_j - \eta_j) \cos(\theta_k - \eta_k) + c_4 \sin(\theta_j - \eta_j) \sin(\theta_k - \eta_k) \right\}^{-1},$$

$$-\pi \leq \theta_j, \theta_k, \eta_j, \eta_k < \pi, \quad 0 \leq \xi_j, \xi_k < 1, \quad -1 < \gamma_{jk} < 1,$$

で与えられる。  $C, c_0, \dots, c_4$  は,  $\xi_j, \xi_k, \gamma_{jk}$  の関数として陽に表される。

また, Johnson & Wehrly (1978) の分布の特別な場合は,

$$f(x_j, \theta_k) = 2\pi f_j(x_j) g_k(\theta_k) h[2\pi \{F_j(x_j) - G_k(\theta_k)\}], \quad x_j \in \mathbb{R}, \quad -\pi \leq \theta_k < \pi,$$

である。ここで,  $f_j, F_j$  はそれぞれ正規分布  $N(\mu_j, \sigma_j^2)$  の密度関数と分布関数,  $g_k, G_k$  はそれぞれ Wrapped Cauchy 分布  $WC(\eta_k, \xi_k)$  の密度関数と分布関数,  $h$  は  $WC(0, \delta_{jk})$  の密度関数,  $WC(\eta, \xi)$  の密度関数は,

$$f(\phi) = \frac{1}{2\pi} \frac{1 - \xi^2}{1 + \xi^2 - 2\xi \cos(\phi - \eta)}, \quad -\pi \leq \phi, \eta < \pi, \quad 0 \leq \xi < 1.$$

## 相互情報量

確率変数  $Z_j(Z_k)$  が  $\mathcal{M}_j(\mathcal{M}_k)$  に値をとるとする。このとき, 2つの確率変数  $(Z_j, Z_k)$  間の相互情報量を以下で定義する。

$$MI(Z_j, Z_k) = \int_{\mathcal{M}_j} \int_{\mathcal{M}_k} f(z_j, z_k) \log \left\{ \frac{f(z_j, z_k)}{f_j(z_j) f_k(z_k)} \right\} dz_k dz_j.$$

ただし,  $f(z_j, z_k)$  は  $(Z_j, Z_k)$  の同時密度関数,  $f_j(z_j)$  は  $Z_j(Z_k)$  の周辺密度関数をあらわす。

このとき, 提案したモデルの相互情報量は以下で与えられる:

$$MI(X_j, X_k) = -\frac{1}{2} \log(1 - \rho_{jk}^2), \quad MI(\Theta_j, \Theta_k) = -\log(1 - \gamma_{jk}^2),$$

$$MI(X_j, \Theta_k) = -\log(1 - \delta_{jk}^2).$$

## 周辺分布と条件付分布

$$X_j \sim N(\mu_j, \sigma_j^2), \quad \Theta_j \sim WC(\eta_j, \xi_j),$$

$$X_j | X_k = x_k \sim N(\mu_j + \sigma_j \sigma_k^{-1} \rho_{jk} (x_k - \mu_k), (1 - \rho_{jk}^2) \sigma_j^2),$$

$$2\pi F_j(X_j) | \Theta_k = \theta_k \sim WC(2\pi G_k(\theta_k), \delta_{jk}),$$

$$\Theta_j | \Theta_k = \theta_k \sim WC(\eta(\theta_k), \xi(\theta_k)), \quad \Theta_k | X_j = x_j \sim WC(\eta'(x_j), \xi'(x_j)).$$

ここで,  $\eta(\theta_k), \xi(\theta_k)$  は  $\theta_k$  の関数として,  $\eta'(x_j), \xi'(x_j)$  は  $x_j$  の関数として, それぞれ陽に表すことができる。

## モデルの推定

よく知られているように, 2変量正規分布のパラメータの最尤推定量は, 陽な形で表現できる。

Kato & Pewsey (2015) の分布と Johnson & Wehrly (1978) の分布のパラメータについては, 最尤推定値は数値的に求めることになるが, モーメント推定量は陽な形で表すことができる。

これらの結果を利用し, 提案したベイジアンネットワークを下記の Chow Liu アルゴリズムにより推定する。

## アルゴリズム

1. 確率変数  $X_1, \dots, X_p, \Theta_1, \dots, \Theta_q$  に対して, すべての周辺分布のパラメータと, すべての2変量同時分布の相関パラメータを推定する。
2. 推定されたすべての2変量同時分布に対して, 相互情報量をエッジの重みとして計算する。
3. 最も大きい重みのエッジを木に含める。
4. 次に大きい重みを持つエッジを, ループが起こらない場合は木に含める。
5. ステップ4を  $p + q - 1$  のエッジが選ばれるまで繰り返す。
6. 根ノードを選択し, それをもとに有向グラフを構成する。

## References

- [1] JOHNSON, R.A. & WEHRLY, T.E. (1978). Some angular-linear distributions and related regression models. *Journal of the American Statistical Association* **73**(363), 602-606.
- [2] KATO, S. & PEWSEY, A. (2015). A Möbius transformation-induced distribution on the torus. *Biometrika* **102**(2), 359-370.