

セルワイズな外れ値に対してロバストなスパースグラフィカルモデリング

片山翔太

東京工業大学

データ科学特別セミナー at 大阪大学
2018.6.13

Outline


- グラフィカルモデルとは
 - ▶ 無向独立グラフと条件付き独立性
 - ▶ Hammersley-Clifford Theorem
- ガウスグラフィカルモデル
 - ▶ スパースモデリング
 - ▶ 外れ値への対処 (row-wise)
- セルワイズ外れ値への対処[†]
- Discussion

[†] Joint work with Prof.Fujisawa and Prof.Drton (2018, *Stat*, vol.7)

グラフィカルモデル


確率変数間の「依存関係」をグラフで表現したもの

- グラフ $G = (V, E)$; 頂点集合 V と辺集合 E (無向)
- 頂点と確率変数 $\{X_v : v \in V\}$ が対応
- 辺 (u, v) の有無が X_u, X_v 間の「依存関係」の有無に対応



$$V = \{1, 2, 3, 4, 5\}$$

$$E = \{(1, 2), (1, 4), (2, 3), (3, 4), (4, 5)\}$$



「依存関係」とは

ペアワイズマルコフ

確率変数 $\{X_v : v \in V\}$ がグラフ $G = (V, E)$ に関してペアワイズマルコフであるとは、次が成立つときのことをいう:

$$X_u \perp\!\!\!\perp X_v \mid X_{V \setminus \{u,v\}} \text{ for all } (u, v) \notin E$$

- 依存関係 = 条件付き独立性
- どうやって確認? \Rightarrow Hammersley-Clifford Theorem

Remark

- 他にも局所 or 大域マルコフと呼ばれる関係性もある
- 詳しくは Lauritzen (1996) など

Hammersley-Clifford Theorem

確率変数 $\mathbf{X} = \{X_v : v \in V\}$ がグラフ $G = (V, E)$ に関してペアワイズマルコフであることと次は同値:

$$f(\mathbf{x}) = \prod_{C \in \mathcal{C}} \phi_C(\mathbf{x}_C), \quad \mathbf{x} \in \mathbb{R}^{|V|}$$


ここで $\phi_C : \mathbb{R}^{|C|} \rightarrow \mathbb{R}$ であり, \mathcal{C} は G の全ての (極大) クリークの集合

- \mathcal{C} の定義: $C \in \mathcal{C}$ if $(u, v) \in E$ for all $u, v \in C$
- 極大の意味: 他のクリークに含まれないこと


Remark

- $\{\phi_C : C \in \mathcal{C}\}$ は一意に定まらない
- ϕ_C が密度的な意味を持つ必要はない

Examples



(a)



(b)

Figure (a)

- $f(\mathbf{x}) = \phi_{12}(x_1, x_2)\phi_{14}(x_1, x_4)\phi_{23}(x_2, x_3)\phi_{34}(x_3, x_4)\phi_{45}(x_4, x_5)$

Figure (b)

- $f(\mathbf{x}) = \phi_{1234}(x_1, x_2, x_3, x_4)\phi_{45}(x_4, x_5)$

ガウスグラフィカルモデル

Goal : データに適合するグラフ G の推定

- 密度 $f(\mathbf{x})$ の情報が必要
- 一般的に推定が困難 \Rightarrow 分布族の特定 or グラフ構造に制約


ガウスグラフィカルモデル

$$f(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^p |\Sigma|}} \exp\left(-\frac{1}{2} \sum_{u,v=1}^p \omega_{uv} x_u x_v\right), \quad \mathbf{x} \in \mathbb{R}^p$$


- 正規分布 $N_p(\mathbf{0}, \Sigma)$ の密度. ただし $\Omega = \Sigma^{-1} = (\omega_{uv})$
- 平均が $\mu \neq \mathbf{0}$ でも OK

$$\omega_{uv} = \omega_{vu} = 0 \Leftrightarrow (u, v) \notin E$$

Examples



(a)



(b)

Figure (a)

- $f(\mathbf{x}) \propto e^{-\frac{\omega_{12} + \omega_{21}}{2} x_1 x_2} e^{-\frac{\omega_{14} + \omega_{41}}{2} x_1 x_4} \dots e^{-\frac{\omega_{45} + \omega_{54}}{2} x_4 x_5}$

Figure (b)

- $f(\mathbf{x}) \propto \exp\left(-\frac{1}{2} \sum_{u,v=1}^4 \omega_{uv} x_u x_v\right) \exp\left\{\frac{1}{2}(\omega_{45} + \omega_{54}) x_4 x_5\right\}$

ガウスグラフィカルモデル

Goal ⇒ 精度行列 $\Omega = \Sigma^{-1}$ の推定

- 特に精度行列 Ω の 0 要素を推定
- **スパースモデリング**に帰着!
 - ▶ 半自動的に幾つかのパラメータを 0 に推定可能

Famous methods

- Node-wise regression (Meinshausen and Bühlmann, 2006)
- Glasso (Friedman et al., 2008)
- CLIME (Cai et al., 2011)

スパースガウスグラフィカルモデリング

Lasso

- $\mathbf{y} \in \mathbb{R}^n$: 結果変数, $\mathbf{Z} \in \mathbb{R}^{n \times p}$: 説明変数行列
- (\mathbf{y}, \mathbf{Z}) は共に中心化しておく

$$\text{Lasso : } \operatorname{argmin}_{\boldsymbol{\theta} \in \mathbb{R}^p} \frac{1}{2n} \|\mathbf{y} - \mathbf{Z}\boldsymbol{\theta}\|_2^2 + \lambda \|\boldsymbol{\theta}\|_1$$

- 次のようにも書ける

$$\operatorname{argmin}_{\boldsymbol{\theta} \in \mathbb{R}^p} \frac{1}{2} \boldsymbol{\theta}^T \left(\frac{\mathbf{Z}^T \mathbf{Z}}{n} \right) \boldsymbol{\theta} - \left(\frac{\mathbf{Z}^T \mathbf{y}}{n} \right)^T \boldsymbol{\theta} + \lambda \|\boldsymbol{\theta}\|_1$$

- ▶ $\mathbf{Z}^T \mathbf{Z} / n$: 説明変数間の共分散行列
- ▶ $\mathbf{Z}^T \mathbf{y} / n$: 結果変数と各説明変数の共分散

Node-wise regression

Anderson (2003)

If $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ then

$$X_j | \mathbf{X}_{\setminus j} \sim N\left(\mu_j + \boldsymbol{\Sigma}_{j,\setminus j} \boldsymbol{\Sigma}_{\setminus j,\setminus j}^{-1} (\mathbf{X}_{\setminus j} - \boldsymbol{\mu}_{\setminus j}), \boldsymbol{\Sigma}_{jj} - \boldsymbol{\Sigma}_{j,\setminus j} \boldsymbol{\Sigma}_{\setminus j,\setminus j}^{-1} \boldsymbol{\Sigma}_{\setminus j,j}\right)$$

- 線形回帰問題に帰着

$$X_j = \beta_0^{(j)} + \mathbf{X}_{\setminus j}^T \boldsymbol{\beta}^{(j)} + \varepsilon_j, \quad j = 1, 2, \dots, p$$

where $\beta_0^{(j)} = \mu_j - \boldsymbol{\Sigma}_{j,\setminus j} \boldsymbol{\Sigma}_{\setminus j,\setminus j}^{-1} \boldsymbol{\mu}_{\setminus j}$ and $\boldsymbol{\beta}^{(j)} = \boldsymbol{\Sigma}_{\setminus j,\setminus j}^{-1} \boldsymbol{\Sigma}_{\setminus j,j}$

- 重要な関係式

$$\boldsymbol{\Omega}_{\setminus j,j} = -(\mathbb{V}(\varepsilon_j))^{-1} \boldsymbol{\beta}^{(j)}$$


Ω の 0 要素推定 \Rightarrow Lasso \times 次元数

- S : 標本共分散行列

$$\hat{\beta}^{(j)} = \operatorname{argmin}_{\beta \in \mathbb{R}^{p-1}} \frac{1}{2} \beta^T S_{\setminus j, \setminus j} \beta - S_{j, \setminus j} \beta + \lambda \|\beta\|_1, \quad j = 1, 2, \dots, p$$

- 辺集合の推定

- ▶ AND rule : $\hat{E} = \{(i, j) : \hat{\beta}_i^{(j)} \neq 0 \text{ and } \hat{\beta}_j^{(i)} \neq 0\}$
- ▶ OR rule : $\hat{E} = \{(i, j) : \hat{\beta}_i^{(j)} \neq 0 \text{ or } \hat{\beta}_j^{(i)} \neq 0\}$



Glasso (Graphical Lasso)

ℓ_1 制約付き対数尤度を最適化

$$\text{Glasso} : \underset{\Omega > \mathbf{O}}{\operatorname{argmin}} \operatorname{tr} \mathbf{S} \Omega - \log |\Omega| + \lambda \|\Omega\|_1$$

辺集合の推定

- 推定量の非 0 要素で OK : $\hat{E} = \{(i, j) : \hat{\Omega}_{ij} \neq 0\}$

最適化アルゴリズム

- Original (Friedman et al., 2008)
 - ▶ Ω^{-1} を更新 \Leftrightarrow 双対問題の解で更新 (Mazumder and Hastie, 2012)
- QUIC (Hsieh et al., 2011)
 - ▶ Ω を直接更新
 - ▶ R package QUIC

2次近似 + 座標降下法

- $g(\mathbf{\Omega}) = \text{tr} \mathbf{S} \mathbf{\Omega} - \log |\mathbf{\Omega}|$
- $\mathbf{\Omega}_{t+1} \leftarrow \mathbf{\Omega}_t + \alpha \mathbf{D}$ と更新. ただし,

$$\mathbf{D} = \underset{\mathbf{\Delta}}{\text{argmin}} \bar{g}_{\mathbf{\Omega}_t}(\mathbf{\Delta}) + \lambda \|\mathbf{\Omega}_t + \mathbf{\Delta}\|_1,$$

$$\bar{g}_{\mathbf{\Omega}_t}(\mathbf{\Delta}) = g(\mathbf{\Omega}_t) + \text{tr}\{(\mathbf{S} - \mathbf{\Omega}_t^{-1})\mathbf{\Delta}\} + \frac{1}{2} \text{tr}(\mathbf{\Omega}_t^{-1} \mathbf{\Delta} \mathbf{\Omega}_t^{-1} \mathbf{\Delta})$$

- $\mathbf{\Delta}$ の最適化は座標降下法

$$D_{ij} = D_{ji} = \underset{\mathbf{\Delta}_{ij} = \mathbf{\Delta}_{ji}}{\text{argmin}} \bar{g}_{\mathbf{\Omega}_t}(\mathbf{\Delta}) + \lambda \|\mathbf{\Omega}_t + \mathbf{\Delta}\|_1,$$


$$\text{given } \{\mathbf{\Delta}_{k\ell} : (k, \ell) \neq (i, j), (j, i)\}$$

CLIME

Idea : $S\Omega \simeq I$ なスペース Ω を見つける

$$\hat{\Omega}^0 = \operatorname{argmin} \|\Omega\|_1 \quad \text{subject to} \quad \|S\Omega - I\|_\infty \leq \lambda$$

- 右図は行列 $\begin{pmatrix} x & y \\ y & x \end{pmatrix}$ 上での最適化のイメージ
- 線形計画問題に帰着!



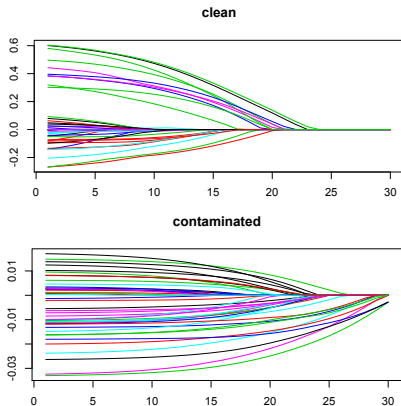
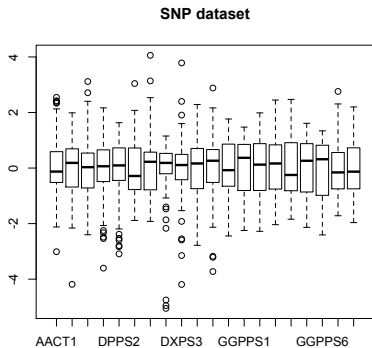
最後に対称化が必要

$$\hat{\Omega}^{\text{CLIME}} = \operatorname{argmin} \|\hat{\Omega}^0 - \Omega\|_F^2 \quad \text{on} \quad \{\Omega = \Omega^T\}$$

外れ値への対処

Motivation

- 裾が重いデータが**意外と多い**
- グラフの推定結果は外れ値に敏感



t-Glasso

正規分布よりも裾の重い分布に変更

- 多変量 t 分布を仮定 (Finegold and Drton, 2011)

$$\mathbf{X} = \boldsymbol{\mu} + \frac{1}{\sqrt{\tau}} \mathbf{Z}, \quad \mathbf{Z} \sim N_p(\mathbf{0}, \boldsymbol{\Sigma}), \quad \tau \sim \Gamma(\nu/2, \nu/2)$$

- \mathbf{X} のみ観測, それ以外は潜在変数

Remark

- Goal : グラフ構造 $\boldsymbol{\Omega} = \boldsymbol{\Sigma}^{-1}$ の推定
- \mathbf{X} のグラフィカルモデルを推定していない

t-Glasso

推定アルゴリズム

- Given $\boldsymbol{\mu}^t, \boldsymbol{\Omega}^t$, update

$$\tau_i^{t+1} \leftarrow \frac{\nu + p}{\nu + \delta(\mathbf{x}_i; \boldsymbol{\mu}^t, \boldsymbol{\Omega}^t)},$$

$$\delta(\mathbf{x}_i; \boldsymbol{\mu}^t, \boldsymbol{\Omega}^t) = (\mathbf{x}_i - \boldsymbol{\mu}^t)^T \boldsymbol{\Omega}^t (\mathbf{x}_i - \boldsymbol{\mu}^t)$$

- Update

$$\boldsymbol{\mu}^{t+1} \leftarrow \frac{\sum_{i=1}^n \tau_i^{(t+1)} \mathbf{x}_i}{\sum_{i=1}^n \tau_i^{t+1}}, \quad \boldsymbol{\Omega}^{t+1} \leftarrow \text{Glasso}(\mathbf{S}^{t+1}; \lambda)$$

where

$$\mathbf{S}^{t+1} = \frac{1}{n} \sum_{i=1}^n \tau_i^{t+1} (\mathbf{x}_i - \boldsymbol{\mu}^{t+1})(\mathbf{x}_i - \boldsymbol{\mu}^{t+1})^T$$

γ -Glasso

外れ値の影響を緩和するように Glasso の目的関数を変更

- KL divergence \Rightarrow γ -divergence (Hirose et al., 2017)

推定アルゴリズム

- Given $\gamma > 0, \boldsymbol{\mu}^t, \boldsymbol{\Omega}^t$, calculate

$$w_i^t = \frac{\exp \left\{ -\frac{\gamma}{2} (\mathbf{x}_i - \boldsymbol{\mu}^t)^T \boldsymbol{\Omega}^t (\mathbf{x}_i - \boldsymbol{\mu}^t) \right\}}{\sum_{k=1}^n \exp \left\{ -\frac{\gamma}{2} (\mathbf{x}_k - \boldsymbol{\mu}^t)^T \boldsymbol{\Omega}^t (\mathbf{x}_k - \boldsymbol{\mu}^t) \right\}}$$

- Update $\boldsymbol{\mu}^{t+1} \leftarrow \sum_{i=1}^n w_i^t \mathbf{x}_i$ and

$$\boldsymbol{\Omega}^{t+1} \leftarrow \underset{\boldsymbol{\Omega} > \mathbf{O}}{\operatorname{argmin}} \operatorname{tr}(\mathbf{S}^{t+1} \boldsymbol{\Omega}) - \frac{1}{1 + \gamma} \log |\boldsymbol{\Omega}| + \lambda \|\boldsymbol{\Omega}\|_1$$



where

$$\mathbf{S}^{t+1} = \sum_{i=1}^n w_i^t (\mathbf{x}_i - \boldsymbol{\mu}^{t+1})(\mathbf{x}_i - \boldsymbol{\mu}^{t+1})^T$$

外れ値の構造

t-Glasso と γ -Glasso の性質

- 観測ベクトルに重み \Rightarrow row-wise 外れ値の影響を緩和
- cell-wise 外れ値の場合はかなりの観測ベクトルが除外



セルワイズ外れ値への対処

Node-wise regression

$$\hat{\beta}^{(j)} = \operatorname{argmin}_{\beta \in \mathbb{R}^{p-1}} \frac{1}{2} \beta^T \mathbf{S}_{\setminus j, \setminus j} \beta - \mathbf{S}_{j, \setminus j} \beta + \lambda \|\beta\|_1, \quad j = 1, 2, \dots, p$$

Glasso

$$\operatorname{argmin}_{\mathbf{\Omega} > \mathbf{O}} \operatorname{tr} \mathbf{S} \mathbf{\Omega} - \log |\mathbf{\Omega}| + \lambda \|\mathbf{\Omega}\|_1$$

CLIME

$$\operatorname{argmin} \|\mathbf{\Omega}\|_1 \quad \text{subject to} \quad \|\mathbf{S} \mathbf{\Omega} - \mathbf{I}\|_{\infty} \leq \lambda$$


共分散行列 Σ がうまく推定できれば良さそう

Goal : Σ のロバスト推定 under セルワイズ外れ値

- 得られた $\hat{\Sigma}$ を Node-wise regression, Glasso, CLIME に入力

Katayama, Fujisawa and Drton (2017)

- γ -divergence を用いてペアワイズに Σ を推定



モデル

Cell-wise contamination model

- $\mathbf{X} \in \mathbb{R}^p$ with

$$\mathbf{X} = (\mathbf{I} - \mathbf{E})\mathbf{Y} + \mathbf{E}\mathbf{H}$$

- $\mathbf{Y} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$
- \mathbf{H} : 外れ値 with density $h(\mathbf{x})$
- $\mathbf{E} = \text{diag}(E_1, \dots, E_p)$: それぞれが $\{0, 1\}$ を取る 2 値確率変数
- $\mathbb{P}(E_j = 1) = \varepsilon_j$: 外れ値の混入率
- もし $E_1 = \dots = E_p$ ならば row-wise 外れ値

サンプル

- $\mathbf{X}_1, \dots, \mathbf{X}_n$ が独立に上記のモデルから生成


γ -divergence

記号の用意

- f : データの真の (周辺) 密度関数
 - ▶ ペアワイズ推定なので考えるのは高々 2 次元
- g_θ : パラメータ θ を持つ正規密度
 - ▶ 例えば 1 次元だと $\theta = (\mu_j, \sigma_{jj})$
- θ^* : 真のパラメータ
- 上記の記号を使うと $f = (1 - \varepsilon)g_{\theta^*} + \varepsilon h$

やりたいこと

- データから θ^* の推定
- f と g_θ を普通に近づけてもダメ
- γ -divergence を使って近づける!



γ -divergence

- Fujisawa and Eguchi (2008)
- 次の目的関数を最小化 ($\gamma > 0$) :

$$\begin{aligned}d_{\gamma}(f_n, g_{\theta}) &= -\frac{1}{\gamma} \log \int f_n(x) g_{\theta}(x)^{\gamma} dx + \frac{1}{1+\gamma} \log \int g_{\theta}(x)^{1+\gamma} dx \\ &= -\frac{1}{\gamma} \log \sum_{i=1}^n g_{\theta}(x_i)^{\gamma} + \frac{1}{1+\gamma} \log \int g_{\theta}(x)^{1+\gamma} dx\end{aligned}$$

- 重要な性質 :

$$\hat{\theta}_{\gamma} = \operatorname{argmin}_{\theta} d_{\gamma}(f_n, g_{\theta}) \rightarrow \theta_{\gamma}^* = \operatorname{argmin}_{\theta} d_{\gamma}(f, g_{\theta}) \simeq \operatorname{argmin}_{\theta} d_{\gamma}(g, g_{\theta})$$

外れ値の影響を自動的に除去!

トリック

$$\begin{aligned}d_\gamma(f, g_\theta) &= -\frac{1}{\gamma} \log \int f g_\theta^\gamma dx + \frac{1}{1+\gamma} \log \int g_\theta^{1+\gamma} dx \\&= -\frac{1}{\gamma} \log \int \{(1-\varepsilon)g + \varepsilon h\} g_\theta^\gamma dx + \frac{1}{1+\gamma} \log \int g_\theta^{1+\gamma} dx \\&= -\frac{1}{\gamma} \log \left\{ (1-\varepsilon) \int g g_\theta^\gamma dx + \varepsilon \int h g_\theta^\gamma dx \right\} + \frac{1}{1+\gamma} \log \int g_\theta^{1+\gamma} dx \\&\simeq -\frac{1}{\gamma} \log(1-\varepsilon) \int g g_\theta^\gamma dx + \frac{1}{1+\gamma} \log \int g_\theta^{1+\gamma} dx \\&\propto d_\gamma(g, g_\theta)\end{aligned}$$



$\nu(\theta; \gamma) := \int h(x) g_\theta^\gamma(x) dx$ が十分小さいときに成立

$\nu(\theta; \gamma) = \int h(x)g_\theta^\gamma(x)dx$ は小さくなるか?

- h が g_θ^γ の裾付近にあれば OK
- $h \sim N(\alpha, 1), g_\theta \sim N(\theta, 1) \Rightarrow \nu(\theta; \gamma) = c_{1,\gamma} \exp\{-c_{2,\gamma}(\alpha - \theta)^2\}$

理想的には

- θ を θ^* 近傍で最適化
 - ▶ 良い初期値を使って最適化



γ -divergence を用いた共分散行列推定

シンプルな 2 段階推定

- $\{X_{ij}\}_{i=1}^n$ から (μ_j, σ_{jj}) を推定
- 標準化 $Z_{ij} = (X_{ij} - \mu_j) / \sqrt{\sigma_{jj}}$ 後, $\rho_{jk} = \text{Corr}(X_{ij}, X_{ik})$ を推定

Step 1

- $g(\mu_j, \sigma_{jj}) \sim N(\mu_j, \sigma_{jj})$

$$(\hat{\mu}_j, \hat{\sigma}_{jj}) = \underset{\mu_j, \sigma_{jj}}{\text{argmin}} d_\gamma(f_n^{(j)}, g(\mu_j, \sigma_{jj}))$$

Step 2

- $g_{\rho_{jk}} \sim$ 相関 ρ_{jk} を持つ 2 次元標準正規分布

$$\hat{\rho}_{jk} = \underset{|\rho_{jk}| < 1}{\text{argmin}} d_\gamma(f_n^{(j,k)}, g_{\rho_{jk}})$$

Output : $\hat{\Sigma}_{jk} = \hat{\sigma}_{jj}^{1/2} \hat{\sigma}_{kk}^{1/2} \hat{\rho}_{jk}$

Step 1 の詳細

EM-like algorithm by Fujisawa and Eguchi (2008)

- 以下を収束するまで繰り返す：

$$\mu_j^{t+1} \leftarrow \sum_{i=1}^n w_{ij}^t X_{ij}, \quad \sigma_{jj}^{t+1} \leftarrow (1 + \gamma) \sum_{i=1}^n w_{ij}^t (X_{ij} - \mu_j^{t+1})^2$$

where

$$w_{ij}^t = \frac{\exp \left\{ -\frac{\gamma}{2\sigma_{jj}^t} (X_{ij} - \mu_j^t)^2 \right\}}{\sum_{\ell=1}^n \exp \left\{ -\frac{\gamma}{2\sigma_{jj}^t} (X_{\ell j} - \mu_j^t)^2 \right\}}$$

- 初期値はロバストなものを選ぶ

- ▶ $\mu_j^0 = \text{Med}(\{X_{ij}\}_{i=1}^n)$
- ▶ $(\sigma_{jj}^0)^{1/2} = \text{Mad}(\{X_{ij}\}_{i=1}^n) = 1.483 \text{Med}(\{|X_{ij} - \mu_j^0|\}_{i=1}^n)$

Step 2 の詳細

制約を閉区間に変更

$$\operatorname{argmin}_{|\rho_{jk}| \leq R} h(\rho_{jk}) := d_{\gamma}(f_n^{(jk)}, g_{\rho_{jk}}), \quad R < 1$$

以下を収束するまで繰り返す (射影勾配法)

- ϕ : step size

$$\rho_{jk}^{t+1} \leftarrow \begin{cases} \bar{\rho}_{jk}^t, & |\bar{\rho}_{jk}^t| \leq R \\ \operatorname{sgn}(\bar{\rho}_{jk}^t)R, & \text{otherwise} \end{cases}$$

where

$$\bar{\rho}_{jk}^t = \rho_{jk}^t - \phi^{-1} \nabla h(\rho_{jk}^t)$$

Remark

- 初期値は $\rho^0 = 0$ で OK (外れ値間に相関がない限り)

行列の負定値性について

Remark

- $\hat{\Sigma}$ は非負定値性が保証されない

Node-wise regression

- $\hat{\Sigma} \geq \mathbf{O} \Rightarrow$ 目的関数の凸性を保証

Gllasso

- Freedman のアルゴリズム $\Rightarrow \hat{\Sigma} + \lambda \mathbf{I} > \mathbf{O}$ が必要
- QUIC $\Rightarrow \hat{\Sigma} \geq \mathbf{O}$ のときのみ収束保証

CLIME

- $\hat{\Sigma} < \mathbf{O} \Rightarrow \hat{\Omega}$ が負の対角要素を持つ
- $\hat{\Sigma} = \mathbf{O} \Rightarrow$ 実行可能解が存在しないケースがある

基本的に $\hat{\Sigma} \geq O$ が必要

- 条件を満たすように射影 ($\delta \geq 0$)

$$\min \|S - \hat{\Sigma}\|_F \quad \text{subject to } S \geq \delta I$$

- $\hat{\Sigma}$ を固有値分解して固有値 λ_j を $\max(\lambda_j, \delta)$ で置き換えるだけ

推定手法のまとめ

Goal : グラフ G の推定 $\Leftrightarrow \Omega = \Sigma^{-1}$ の推定

- 全ての変数のペア (j, k) に対して $\hat{\Sigma}_{jk}$ を計算
- 行列 $\hat{\Sigma} = (\hat{\Sigma}_{jk})$ を構成し $\hat{\Sigma} \geq \delta \mathbf{I}$ となるように射影
- 射影した行列 $\hat{\Sigma}$ を入力として各スパースグラフ推定法を適用

Option : 各チューニングパラメータの選択

- Node-wise regression \Rightarrow Stability approach (Liu et al., 2010)
- Glasso と CLIME \Rightarrow クロスバリデーション

$$L(\lambda) = \text{tr} \left(\hat{\Sigma}_2 \hat{\Omega}_1(\lambda) \right) - \log \det \hat{\Omega}_1(\lambda)$$

パフォーマンス比較

比較対象

ランクに基づく相関の推定

- $\hat{\Sigma}_{jk} = \hat{\sigma}_{jj}^{1/2} \hat{\sigma}_{kk}^{1/2} \hat{\rho}_{jk}$ (スケールは Mad で推定)
- Kendall's tau (Spearman's rho)
- Gaussian rank correlation (Boudt et al., 2012)

$$\hat{\rho}_{jk} = \frac{\sum_{i=1}^n \Phi^{-1}\left\{\frac{R(X_{ij})}{n+1}\right\} \Phi^{-1}\left\{\frac{R(X_{ik})}{n+1}\right\}}{\sum_{i=1}^n \left\{\Phi^{-1}\left(\frac{i}{n+1}\right)\right\}^2}$$

Remark

- Gaussian rank のみ $\hat{\Sigma} \geq \mathbf{O}$ を保証
- **Nonparanormal** (Liu et al., 2009) モデルの下で最適
 - ▶ ある単調変換 f_1, \dots, f_p が存在して $(f_1(X_1), \dots, f_p(X_p)) \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$
 - ▶ Nonparanormal SKEPTIC (Liu et al., 2012)

比較対象

共分散の変形に基づくアプローチ (Tarr et al., 2016)

- Gnanadesikan and Kettenring (1972)

$$\text{Cov}(X, Y) = \frac{1}{4\alpha\beta} \{ \mathbb{V}(\alpha X + \beta Y) - \mathbb{V}(\alpha X - \beta Y) \}$$
$$\alpha^{-1} = \sqrt{\mathbb{V}(X)}, \quad \beta^{-1} = \sqrt{\mathbb{V}(Y)}$$


- $\mathbb{V}(\cdot)$ をロバスト推定
 - ▶ $Q_n = 2.222 \{ |Z_i - Z_j| : i < j \}_{(k)}, k \simeq \binom{n}{2} / 4$

Remark


- $\hat{\Sigma} \geq O$ は保証されない
- 経験的にスケールの推定はあまり上手くいかない

いろいろなグラフ ($p = 100$)


Chain




Hub



Scale-free



Random



	Chain	Hub	Scale-free	Random
Edges	99	95	99	156
Max. degree	2	19	15	4
Mean weight	0.57	0.43	0.28	0.25

その他の設定

データの生成

- $(n, p) = (200, 100)$, $\varepsilon_1 = \dots = \varepsilon_p \in \{0.05, 0.15, 0.25\}$

セルワイズな外れ値

- Asymmetric と Symmetric

評価指標

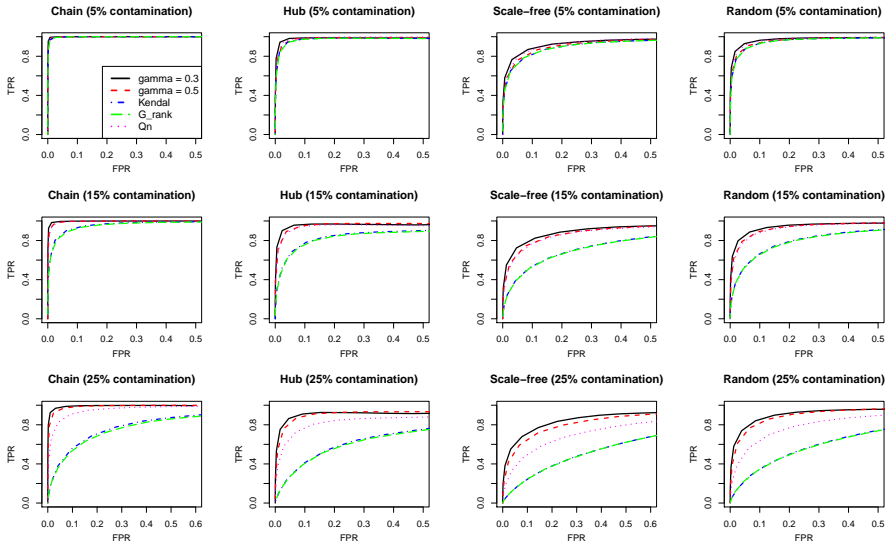
- ROC curve (FPR(λ), TPR(λ))

$$\text{FPR}(\lambda) = \frac{|\hat{E} \cap E^c|}{|E^c|}, \quad \text{TPR}(\lambda) = \frac{|\hat{E} \cap E|}{|E|}$$

- λ をチューニング \Rightarrow TPR, FPR, MSE ($\|\hat{\Omega} - \Omega\|_F/p$)

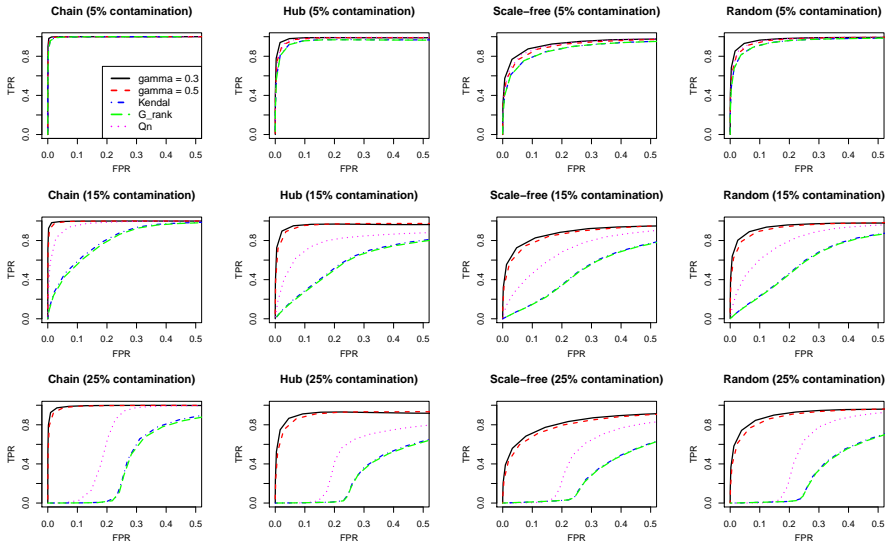
ROC curves for Glasso

Asymmetric



ROC curves for Glasso

Symmetric



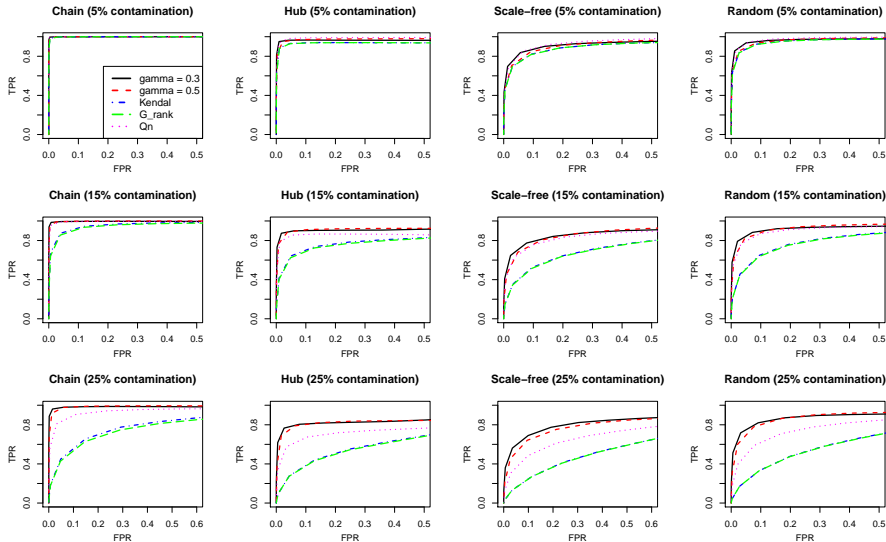
Tuned λ for Glasso

$$\varepsilon = 0.25$$

		Chain			Scale-free			Random		
		MSE	TPR	FPR	MSE	TPR	FPR	MSE	TPR	FPR
Asym.	$\gamma = 0.3$	0.074 (0.004)	0.992 (0.011)	0.106 (0.025)	0.053 (0.002)	0.584 (0.103)	0.044 (0.020)	0.049 (0.005)	0.753 (0.165)	0.063 (0.031)
	$\gamma = 0.5$	0.085 (0.003)	0.972 (0.026)	0.064 (0.023)	0.055 (0.002)	0.458 (0.114)	0.029 (0.017)	0.051 (0.002)	0.692 (0.079)	0.045 (0.021)
	Q_n	0.140 (0.001)	0.941 (0.028)	0.132 (0.035)	0.098 (0.001)	0.488 (0.090)	0.084 (0.028)	0.086 (0.001)	0.665 (0.080)	0.112 (0.037)
Sym.	$\gamma = 0.3$	0.046 (0.002)	0.821 (0.038)	0.079 (0.020)	0.053 (0.002)	0.595 (0.068)	0.047 (0.018)	0.046 (0.002)	0.825 (0.045)	0.078 (0.020)
	$\gamma = 0.5$	0.050 (0.002)	0.700 (0.082)	0.049 (0.021)	0.055 (0.002)	0.436 (0.102)	0.025 (0.014)	0.050 (0.002)	0.707 (0.083)	0.049 (0.022)
	Q_n	0.082 (0.002)	0.744 (0.073)	0.292 (0.028)	0.094 (0.001)	0.505 (0.096)	0.248 (0.025)	0.082 (0.002)	0.742 (0.065)	0.288 (0.027)

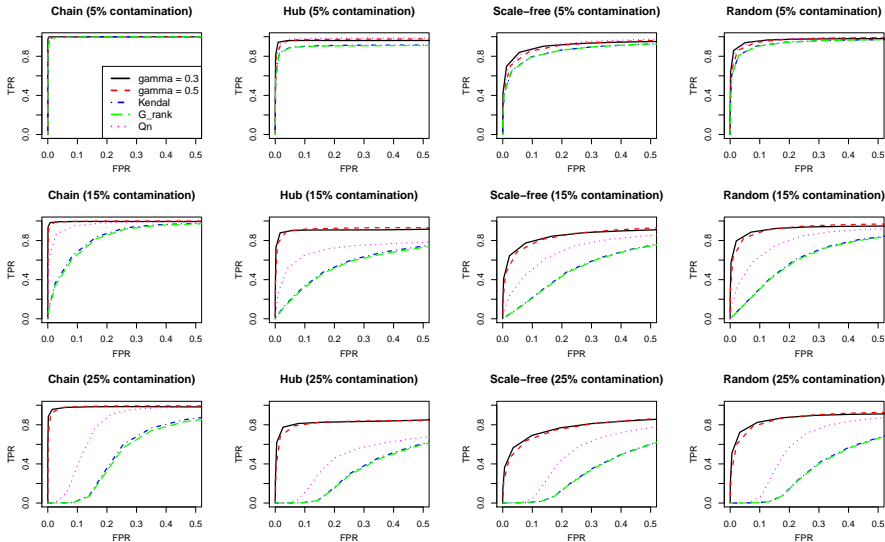
ROC curves for Node-wise regression

Asymmetric



ROC curves for Node-wise regression

Symmetric



Tuned λ for Node-wise regression

$$\varepsilon = 0.25$$

		Chain		Scale-free		Random	
		TPR	FPR	TPR	FPR	TPR	FPR
Asym.	$\gamma = 0.3$	0.978 (0.013)	0.059 (0.024)	0.614 (0.065)	0.057 (0.019)	0.776 (0.060)	0.062 (0.021)
	$\gamma = 0.5$	0.972 (0.019)	0.046 (0.016)	0.530 (0.090)	0.041 (0.019)	0.680 (0.075)	0.042 (0.017)
	Q_n	0.881 (0.043)	0.062 (0.022)	0.429 (0.069)	0.058 (0.019)	0.547 (0.069)	0.059 (0.020)
Sym.	$\gamma = 0.3$	0.977 (0.016)	0.063 (0.027)	0.622 (0.062)	0.059 (0.021)	0.782 (0.047)	0.066 (0.020)
	$\gamma = 0.5$	0.975 (0.018)	0.047 (0.016)	0.526 (0.084)	0.041 (0.016)	0.678 (0.067)	0.040 (0.017)
	Q_n	0.600 (0.116)	0.137 (0.018)	0.137 (0.066)	0.132 (0.015)	0.183 (0.094)	0.132 (0.019)

Real data analysis





シロイヌナズナの遺伝子データ

- Wille et al. (2004)
- $n = 118$, $p = 39$ (small dimension)
- 変数 (遺伝子) は 3 つのグループに分けられる
 - ▶ MEP パスウェイ, MVA パスウェイ, その他

Daily S&P 500 stocks


- $n = 1257$ (Jan. 2003 – Jan. 2008), $p = 452$ (large dimension)
- 変数は 10 のグループ (GICS) に分けられる
 - ▶ 金融, 公共事業, エネルギー, 素材, etc

シロイヌナズナの遺伝子データ (30 edges)




S&P 500 stocks (2,500 edges)


gamma=0.1




gamma=0.3




Kendall's tau



Gaussian rank



Qn



パフォーマンス比較の結果

Simulation

- $\gamma = 0.3, 0.5$ とともに混入率 ε からの影響をほとんど受けない
- Q_n の性能はグラフ推定法 (特にチューニング) に左右される

シロイヌナズナの遺伝子データ

- $\gamma = 0.3$ と Q_n はパスイェイ間の関連性を捉えることに成功

S&P 500

- どの方法でもグループ構造 (GICS) が観測される
- $\gamma = 0.1$ で公共事業 (青) と素材 (赤) 間にパス

Discussion

Theory?

- $\|\hat{\Sigma} - \Sigma\|_{\infty}$ の集中不等式が導出できるか?
- $\hat{\Sigma}$ が陽に書ける or 凸最適化問題の解 \Rightarrow OK
 - ▶ Miao (2010), Catoni (2012), Loh and Tan (2018+)
- 今回は非凸最適化問題

Extension?

- ガウス以外のグラフィカルモデルに適用できるか?
 - ▶ 特にカウントデータへの適用が重要
- 周辺分布が扱い易い形で与えられることが必須条件
 - ▶ 例えば Poisson-log normal (Aitchison and Ho, 1989) など

ありがとうございました!!

今日のスライド：私のホームページに後で置いておきます

R code : https://github.com/shkatayama/robust_graphical_model

参考文献

- Aitchison, J., & Ho, H. (1989), The multivariate Poisson-log normal distribution, *Biometrika*, **76**, 643–653
- Anderson, W. (2003), *An Introduction to Multivariate Statistical Analysis*, Wiley-Interscience
- Boudt, K., Cornelissen, J., & Croux, C. (2012), The Gaussian rank correlation estimator: robustness properties, *Statistics and Computing*, **22**, 471–483
- Cai, T., Liu, W. & Luo, X. (2011), A constrained ℓ_1 minimization approach to sparse precision matrix estimation, *Journal of the American Statistical Association*, **106**, 594–607
- Catoni, O. (2012), Challenging the empirical mean and empirical variance: a deviation study, *Annales de l'Institut Henri Poincaré, Probabilités et Statistiques*, **48**, 1148–1185
- Finegold, M. & Drton, M. (2011), Robust graphical modeling of gene networks using classical and alternative t -distributions, *The Annals of Applied Statistics*, **2A**, 1057–1080
- Friedman, H., Hastie, T. & Tibshirani, R. (2008), Sparse inverse covariance estimation with the graphical lasso, *Biostatistics*, **9**, 432–441

参考文献

- Fujisawa, H. & Eguchi, S. (2008), Robust parameter estimation with a small bias against heavy contamination, *Journal of Multivariate Analysis*, **99**, 2053–2081
- Hsieh, J., Sustik, A., Dhillon, S. & Ravikumar, P. (2011), Sparse inverse covariance matrix estimation using quadratic approximation, *In Advances in Neural Information Processing Systems*, 2330–2338
- Hirose, K., Fujisawa, H., & Sese, J. (2017), Robust sparse Gaussian graphical modeling, *Journal of Multivariate Analysis*, **161**, 172–190
- Katayama, S., Fujisawa, H. & Drton, M. (2018), Robust and sparse Gaussian graphical modeling under cell-wise contamination, *Stat*, **7**, e181
- Lauritzen, S. (1996), *Graphical models*, Clarendon Press
- Liu, H., Lafferty, J., & Wasserman, L. (2009), The nonparanormal: Semiparametric estimation of high dimensional undirected graphs, *Journal of Machine Learning Research*, **10**, 2295–2328
- Loh, P. & Tan, X. (2018+), High-dimensional robust precision matrix estimation: Cellwise corruption under epsilon-contamination, *Electronic Journal of Statistics*

参考文献

- Liu, H., Roeder, K. & Wasserman, L. (2010), Stability approach to regularization selection for high dimensional graphical models, *Advances in Neural Information Processing Systems*
- Liu, H., Han, F., Yuan, M., Lafferty, J., & Wasserman, L. (2012), High-dimensional semiparametric Gaussian copula graphical models, *The Annals of Statistics*, **40**, 2293–2326
- Gnanadesikan, R. & Kettenring, R. (1972), Robust estimates, residuals and outlier detection with multiresponse data, *Biometrics*, **28**, 81–124
- Meinshausen, N. & Bühlmann, P. (2006), High-dimensional graphs and variable selection with the lasso, *The Annals of Statistics*, **34**, 1436–1462
- Miao, O. (2010), Concentration inequality of maximum likelihood estimator, *Applied Mathematics Letters*, **23**, 1305–1309
- Tarr, G., Müller, S. & Weber C. (2016), Robust estimation of precision matrices under cellwise contamination, *Computational Statistics and Data Analysis*, **93**, 404–420