

スパース正則化における一般化自由度評価

坂田 綾香 モデリング研究系 助教

【スパース推定】

正則化付き二乗誤差最小化

$$\hat{x}_\eta(\mathbf{y}, \mathbf{A}) = \min_x \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2^2 + r(x; \eta)$$

- $\mathbf{y} \in R^M$: データベクトル
- $\mathbf{A} \in R^{M \times N}$: 説明変数
- $\mathbf{x} \in R^N$: 回帰係数
- $\alpha = M/N, \hat{x}$ の非ゼロ要素数 $M = \delta$
- $r(x; \eta)$: スパース正則化
- η : 正則化パラメータ(スパース度をコントロールする)

正則化パラメータにより異なるスパース表現 \hat{x}_η が得られる。

それを用いたデータ表現を $\hat{\mathbf{y}} = \mathbf{A}\hat{x}_\eta$ とする。

正則化パラメータをどのように選ぶか → モデル選択

【Mallows' Cpによるモデル選択】

$y_\mu \sim N(\mu_y, \sigma_y^2)$ の場合の 予測誤差の不偏推定量

(二乗誤差最小化問題の場合はAICと等価)

$$c_p(\mathbf{y}) = \text{err}_{\text{train}}(\mathbf{y}) + 2\sigma_y^2 \widehat{\text{df}}(\mathbf{y})$$

- $\widehat{\text{df}} = \text{cov}[\mathbf{y}, \hat{\mathbf{y}}(\mathbf{y})] / (2M\sigma_y^2)$ を一般化自由度と呼ぶ。
- 訓練誤差: $\text{err}_{\text{train}} = \frac{1}{M} \|\mathbf{y} - \hat{\mathbf{y}}(\mathbf{y})\|_2^2$
- 予測誤差: $\text{err}_{\text{pre}} = \frac{1}{M} E_w [\|\mathbf{w} - \hat{\mathbf{y}}(\mathbf{y})\|_2^2], w_\mu \sim N(\mu_y, \sigma_y^2)$

一般化自由度が評価できれば、モデル選択基準が得られる。

既存研究では ℓ_1 正則化、elastic net 正則化について評価されている。

→ 一般のスパース正則化に適用可能な枠組みを提案したい。

【レプリカ法による一般化自由度の評価】

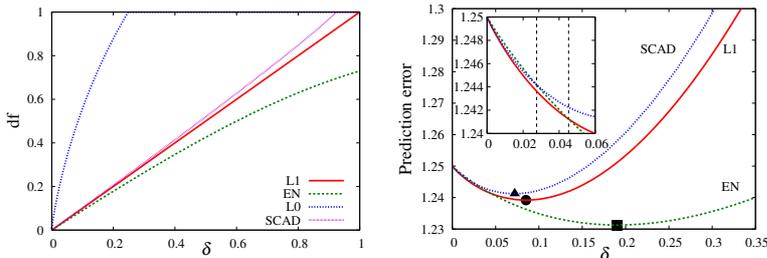
- 解析方法は参考文献参照
- 利点: 一般のスパース正則化に適用可能。
- 欠点: 解析の際に仮定をおく必要がある。
(レプリカ対称性仮定など)

レプリカ対称性仮定下での一般化自由度の表現

- $A_{\mu i} \sim N(0, M^{-1})$ の場合

$$\widehat{\text{df}} = \frac{\text{推定値周辺の揺らぎ}}{\text{非ゼロ成分の揺らぎ}}$$

ℓ_1 正則化、elastic net 正則化の先行研究の結果と一致する。



(左) ℓ_1 正則化(L1), elastic net 正則化(EN), ℓ_0 正則化(L0), SCAD正則化における一般化自由度の δ 依存性。 $\alpha = 0.5, \mu_y = 0, \sigma_y^2 = 1$ とした。
(右) 予測誤差(c_p の期待値)の δ 依存性。 $\alpha = 0.5, \mu_y = 0.5, \sigma_y^2 = 1$ とした。

任意のデータ \mathbf{y} , 説明変数 \mathbf{A} について一般化自由度を評価するには数値的手法が有用。しかし非凸正則化における評価は一般的に困難。

• SCAD正則化では、レプリカ対称性が存在する領域で

Approximate Message Passing(AMP)による一般化自由度評価が可能。

$$\text{SCAD正則化: } r(x; \eta) = \begin{cases} \eta\lambda|x|, & \text{for } |x| \leq \lambda \\ -\eta \left\{ \frac{x^2 - 2a\lambda|x| + \lambda^2}{2(a-1)} \right\}, & \text{for } \lambda < |x| \leq a\lambda \\ \frac{\eta(a+1)\lambda^2}{2}, & \text{for } |x| > a\lambda \end{cases}$$

【SCAD正則化に対するAMPアルゴリズム】

- ステップ t での i 番目要素の推定値を $x_i^{(t)}$ とする。
- ステップ t でのデータ表現を $\mathbf{y}^{(t)} = \mathbf{A}\hat{x}^{(t)}$ とする。

$$h_i^{(t)} = \hat{x}_i^{(t-1)} \sum_{\mu=1}^M \frac{A_{\mu i}^2}{1 + \sigma_\mu^{(t-1)^2}} + \sum_{\mu=1}^M A_{\mu i} R_\mu^{(t-1)}$$

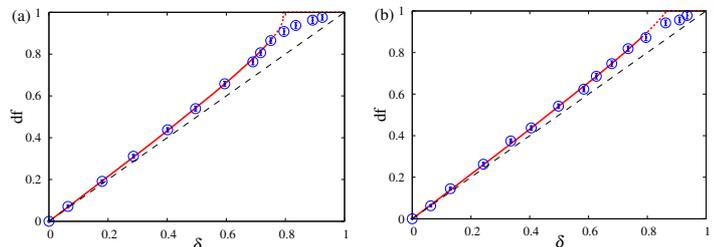
$$\hat{Q}_i^{(t)} = \sum_{\mu=1}^M \frac{A_{\mu i}^2}{1 + \sigma_\mu^{(t-1)^2}}$$

$$\hat{x}_i^{(t)} = \begin{cases} \frac{h_i^{(t)} - \lambda\eta \text{sgn}(h_i^{(t)})}{\hat{Q}_i^{(t)}}, & \text{for } \lambda\eta < |h_i^{(t)}| \leq \lambda(\hat{Q}_i^{(t)} + \eta) \\ \frac{h_i^{(t)}(a-1) - a\lambda \text{sgn}(h_i^{(t)})}{\hat{Q}_i^{(t)}(a-1) - \eta}, & \text{for } \lambda(\hat{Q}_i^{(t)} + \eta) < |h_i^{(t)}| \leq a\lambda\hat{Q}_i^{(t)} \\ \frac{h_i^{(t)}}{\hat{Q}_i^{(t)}}, & \text{for } |h_i^{(t)}| > a\lambda\hat{Q}_i^{(t)} \\ 0, & \text{otherwise} \end{cases}$$

ここで

$$R_\mu^{(t)} = \frac{y_\mu - \hat{y}_\mu^{(t)}}{1 + \sigma_\mu^{(t)^2}}, \quad \sigma_\mu^{(t)^2} = \sum_{i=1}^N A_{\mu i}^2 v_i^{(t)}$$

$$v_i^{(t)} = \begin{cases} \hat{Q}_i^{(t-1)}, & \text{for } \lambda\eta < |h_i^{(t)}| \leq \lambda(\hat{Q}_i^{(t)} + \eta) \text{ and } |h_i^{(t)}| > a\lambda\hat{Q}_i^{(t)} \\ \left(\hat{Q}_i^{(t)} - \frac{\eta}{a-1}\right)^{-1}, & \text{for } \lambda(\hat{Q}_i^{(t)} + \eta) < |h_i^{(t)}| \leq a\lambda\hat{Q}_i^{(t)} \\ 0, & \text{otherwise} \end{cases}$$



AMPによるSCAD正則化の一般化自由度の評価。
線はRS仮定による理論曲線を意味し、点線部分はRSB領域である。
○はAMPの結果で、 $N = 200$ で100通りの $\{\mathbf{y}, \mathbf{A}\}$ について平均化した。
(a) $\alpha = 0.5, a = 5, \lambda = 1$, (b) $\alpha = 0.8, a = 8, \lambda = 0.7$

【参考文献】

Ayaka Sakata

“Evaluation of Generalized Degrees of Freedom for Sparse Estimation by Replica Method”, arXiv:1602.06506