


非凸スパース正則化によるモデル選択

坂田 綾香 数理・推論研究系 助教

【導入: スパース正則化つき推定】

$$\hat{\theta} = \arg \min_{\theta} \left\{ \frac{1}{2} (\mathbf{w} - \theta)^2 + J(\theta) \right\}$$



入力データに応じて推定値がゼロ成分を取りうるような正則化Jをスパース正則化と呼ぶ。

- 変数選択(モデル選択)と推定が同時にできる。
- どういったモデルを選べば良いの？ → 今回の研究

【問題設定】

スパース正則化つき線形回帰

$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2^2 + J(\mathbf{x}) \right\}$$

➤ $\mathbf{y} \in \mathbb{R}^M$: 応答変数
➤ $\mathbf{A} \in \mathbb{R}^{M \times N}$: 説明変数
➤ $\mathbf{x} \in \mathbb{R}^N$: 回帰係数

スパース正則化

今回考える正則化... **非凸スパース正則化**

- SCAD (Smoothly Clipped Absolute Deviation)

$$J_{\lambda,a}(x) = \begin{cases} \frac{\lambda|x|}{2} & (|x| \leq \lambda) \\ -\frac{x^2 - 2a\lambda|x| + \lambda^2}{2(a-1)} & (\lambda < |x| \leq a\lambda) \\ \frac{(a+1)\lambda^2}{2} & (|x| > a\lambda) \end{cases}$$

- MCP (Minimax Concave Penalty)

$$J_{\lambda,a}(x) = \begin{cases} \lambda|x| - \frac{x^2}{2a} & (|x| \leq a\lambda) \\ \frac{a\lambda^2}{2} & (|x| > a\lambda) \end{cases}$$

- これらの正則化の特徴 ... **推定値が連続で不偏** (一番上の図参照)

- 正則化パラメータ λ, a によって非ゼロ要素の位置・値が変わる

→ 正則化パラメータの選び方を提案します。

【方針】

予測誤差を最小化するように正則化パラメータを選ぶ

$$(1) \text{ In sample error: } \varepsilon_{\text{in}}(\mathbf{y}) \equiv \frac{1}{N} E_{\mathbf{z}} [\|\mathbf{z} - \mathbf{A}\hat{\mathbf{x}}(\mathbf{y})\|_2^2]$$

※ $\hat{\mathbf{x}}(\mathbf{y})$: データ \mathbf{y} のもとでの推定値
 \mathbf{z} : \mathbf{y} と同じ分布に従うデータ

$$(2) \text{ Extra sample error: } \varepsilon_{\text{ext}}(\mathbf{y}) \equiv E_{\mathbf{z}, \mathbf{a}_z} [(z - \mathbf{a}_z \hat{\mathbf{x}}(\mathbf{y}))^2]$$

※ $\hat{\mathbf{x}}(\mathbf{y})$: データ \mathbf{y} のもとでの推定値
 \mathbf{a}_z : 応答変数 \mathbf{z} に付随した説明変数

真の分布を知らなければ厳密評価できないので
推定量を構成する

(1) In sample errorについて

次の関係が成立する

$$E[\varepsilon_{\text{in}}(\mathbf{y})] = E[\varepsilon_{\text{train}}(\mathbf{y})] + 2\sigma_y^2 \text{df}$$

ここで $\varepsilon_{\text{train}}(\mathbf{y}) = \frac{1}{M} [\|\mathbf{y} - \mathbf{A}\hat{\mathbf{x}}(\mathbf{y})\|_2^2]$... 訓練誤差(観測可)

$$\text{df} = \frac{1}{M\sigma_y^2} \sum_{\mu} \text{cov}[y_{\mu}, \hat{y}_{\mu}] \quad \dots \text{一般化自由度(観測不可)}$$

Stein's Lemmaから推定量を構成する(データがGaussianのときは不偏)

$$\text{df} = \frac{1}{M} \sum_{\mu} E \left[\frac{d\hat{y}_{\mu}}{dy_{\mu}} \right] \rightarrow \widehat{\text{df}} = \frac{1}{M} \sum_{\mu} \frac{d\hat{y}_{\mu}}{dy_{\mu}}$$

In sample errorの推定量


$$\hat{\varepsilon}_{\text{in}}(\mathbf{y}) = \varepsilon_{\text{train}}(\mathbf{y}) + 2\sigma_y^2 \widehat{\text{df}}$$

一般化自由度の推定量を、確率伝搬法を使って評価する。[参考文献1参照]

Communities and Crime Unnormalized Data Set

Our estimator

AIC



- Solid line: Model with minimum true prediction error
- Circles: Models with minimum estimator

真の予測誤差最小のモデルと近いモデルを選択する。

(2) Extra sample errorについて

推定量: Leave-one-out cross validation error


$$\hat{\varepsilon}_{\text{ext}}(\mathbf{y}) \equiv \frac{1}{M} \sum_{\mu} (y_{\mu} - \mathbf{a}_{\mu}^T \hat{\mathbf{x}}(\mathbf{y}_{\setminus \mu}))^2$$

$\hat{\mathbf{x}}(\mathbf{y}_{\setminus \mu})$... μ 番目のデータがない時の推定値


- 定義通りの評価にかかる計算コストが大きい。
- そこで非凸正則化にも使える近似公式を導出。
- また、モデル候補は「RS phase」と呼ばれる領域に制限すべき。

[参考文献2参照]

CV errorの理論値と数値計算結果の比較



RS領域では、
理論値と近似公式の結果が一致する。



ROC curve上で(0,1)と最も近い点と
CV error最小点は非常に近い。
(L1等には見られない性質)

【参考文献】

- A. Sakata, Journal of Statistical Mechanics: Theory and Experiment, vol. 2018, 063404 (2018).
- T. Obuchi & A. Sakata, arXiv:1902.10375.