

ブリッジ型正則化法におけるチューニングパラメータ選択のための AIC

九州大学 大学院数理学府 梅津 佑太

九州大学 マス・フォア・インダストリ研究所 二宮 嘉行

概要

L_γ 罰則を課したブリッジ型正則化法 (Frank and Friedman, 1993) において, $\gamma < 1$ の場合パラメータの推定と変数選択を同時に実行可能であることが知られている. 特に, $\gamma = 1$ のときは Lasso (Tibshirani, 1996) とよばれ, 統計解析や機械学習において広く研究されている. 罰則付き最尤推定では, チューニングパラメータの選択がしばしば問題になるが, Ninomiya and Kawano (2014) は, 一般化線形モデルにおける Lasso 推定量の漸近分布に基づき, AIC を導出してチューニングパラメータを選択することを提案している. ところが, 彼らのモデルではパラメータ推定の一致性が成立しない. 本報告では, パラメータ推定の一致性を保持するように, Ninomiya and Kawano (2014) とは異なる漸近論の枠組みで, ブリッジ型正則化法におけるチューニングパラメータ選択のための AIC の導出について述べる.

主結果 n 個の説明変数 $\mathbf{X}_i \in \mathcal{X} \subset \mathbb{R}^{r \times p}$ と目的変数 $\mathbf{y}_i \in \mathbb{R}^r$ に対して, 自然連結関数 $\boldsymbol{\theta}_i = \mathbf{X}_i \boldsymbol{\beta} \in \Theta$ (自然パラメータ空間) をもつ次の一般化線形モデルを考える.

$$g_i(\boldsymbol{\beta}) = \log f(\mathbf{y}_i; \mathbf{X}_i \boldsymbol{\beta}) = \mathbf{y}_i^T \mathbf{X}_i \boldsymbol{\beta} - a(\mathbf{X}_i \boldsymbol{\beta}) + b(\mathbf{y}_i)$$

真のパラメータ $\boldsymbol{\beta}^*$ はこのモデルに含まれているとし, $\boldsymbol{\beta} \in \mathcal{B} \subset \mathbb{R}^p$ は次で推定されるとする.

$$\hat{\boldsymbol{\beta}}_\lambda = \operatorname{argmin}_{\boldsymbol{\beta} \in \mathcal{B}} \left\{ -\sum_{i=1}^n g_i(\boldsymbol{\beta}) + \sqrt{n} \lambda \sum_{j=1}^p |\beta_j|^\gamma \right\}, \quad 0 < \gamma < 1$$

ここで, 説明関数に関して次の条件を仮定する.

(C1) \mathcal{X} はコンパクト, \mathcal{B} は開凸集合であり, 任意の $\mathbf{X} \in \mathcal{X}$ と $\boldsymbol{\beta} \in \mathcal{B}$ に対して, $\mathbf{X}\boldsymbol{\beta} \in \Theta^\circ$ である.

(C2) \mathcal{X} 上の不変分布が存在する. 特に, $\sum_{i=1}^n \mathbf{X}_i^T a''(\mathbf{X}_i \boldsymbol{\beta}) \mathbf{X}_i / n \rightarrow \mathbf{J}(\boldsymbol{\beta})$ は正定値行列である.

また, $\mathbf{s}_n = \sum_{i=1}^n g'(\boldsymbol{\beta}^*) / \sqrt{n}$ とする. (C1) および (C2) は, 一般化線形モデルにおける最尤推定量の一致性と, \mathbf{s}_n の漸近正規性を保証するための仮定である. このとき, $\mathcal{J}^{(1)} = \{j; \beta_j^* = 0\}$, $\mathcal{J}^{(2)} = \{j; \beta_j^* \neq 0\}$ に対して, ベクトル $(\beta_i)_{i \in \mathcal{J}^{(k)}}$ を $\boldsymbol{\beta}^{(k)}$, 行列 $(\mathbf{J}(\boldsymbol{\beta}^*)_{ij})_{i \in \mathcal{J}^{(k)}, j \in \mathcal{J}^{(l)}}$ を $\mathbf{J}^{(kl)}(\boldsymbol{\beta}^*)$ ($k, l \in \{1, 2\}$) などと表せば, 推定量の一致性および漸近分布

$$\sqrt{n}^{1/\gamma} \hat{\boldsymbol{\beta}}_\lambda^{(1)} = o_p(1), \quad \sqrt{n}(\hat{\boldsymbol{\beta}}_\lambda^{(2)} - \boldsymbol{\beta}^{*(2)}) = \mathbf{J}^{(22)}(\boldsymbol{\beta}^*)^{-1}(\mathbf{s}_n^{(2)} - \mathbf{p}_\lambda^{(2)}) + o_p(1)$$

を導出することができる. ただし, $\mathbf{s}_n^{(2)} \xrightarrow{d} N(\mathbf{0}, \mathbf{J}^{(22)}(\boldsymbol{\beta}^*))$ であり, $\mathbf{p}_\lambda^{(2)} = (\gamma \lambda \operatorname{sgn}(\beta_j^*) |\beta_j^*|^{\gamma-1})_{j \in \mathcal{J}^{(2)}}$ とする. さらに, Kullback-Leibler 情報量の漸近不偏推定量として, 情報量規準 AIC の漸近バイアスが $|\mathcal{J}^{(2)}|$ となることを示すことができる. $\mathcal{J}^{(2)}$ は未知の量なので, その一致推定量 $\hat{\mathcal{J}}^{(2)} = \{j; \hat{\beta}_{\lambda, j} \neq 0\}$ を代用する. 結果, 次の値が最小となる λ を最適なものとして選べばよく, 簡単にモデル選択することができる.

$$\operatorname{AIC}_\lambda = -2 \sum_{i=1}^n g_i(\hat{\boldsymbol{\beta}}_\lambda) + 2|\hat{\mathcal{J}}^{(2)}|$$

数値実験の結果は当日報告する.

参考文献

- Frank, L. and Friedman, J. H. (1993). A statistical view of some chemometrics regression tools. *Technometrics*, **35**, 109-135.
- Ninomiya, Y. and Kawano, S. (2014). AIC for the LASSO in generalized linear models. *ISM Research Memorandum*, 1187.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *J. R. Stat. Soc. Ser. B Stat. Methodol.*, **58**, 267-288.