

# 一般化線形モデルにおける Group Lasso に対する情報量規準

総合研究大学院大学 複合科学研究科統計科学専攻 小松 慧

JA 共済連 山下 雄大

統計数理研究所 数理・推論研究系 二宮 嘉行

**概要:** 共変量がクラスター化されてグループになっているとき, group Lasso (Yuan and Lin [1]) はグループごと係数を 0 にする傾向があるのでよく利用される. group Lasso にはペナルティの強さを調節するチューニングパラメータが含まれており, その適切な値を選択するために真の予測誤差の不偏推定量が  $C_p$  型の情報量規準として与えられている. しかしながら, それは一般化線形モデルにおいては与えられていない. そこで本講演では, 一般化線形モデルの枠組みのもと group Lasso に対する AIC をその元来の定義に基づいて導き, 数値実験において cross-validation など他手法との性能比較を行う.

サンプル  $i$  ( $i = 1, \dots, n$ ) に対し  $\mathbf{y}_i, \mathbf{X}_i$  はそれぞれ  $r$  次元目的変数ベクトル,  $r \times p$  説明変数行列とする. 自然パラメータ  $\boldsymbol{\theta}$  を持つ密度が  $f(\mathbf{y}; \boldsymbol{\theta}) = \exp\{\mathbf{y}^T \boldsymbol{\theta} - a(\boldsymbol{\theta}) + b(\mathbf{y})\}$  となる指数型分布族を考える. そして自然リンク関数を用いた一般化線形モデルを考え,  $\mathbf{y}_i, \mathbf{X}_i$  に対する係数ベクトル  $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)^T$  の対数尤度を  $g_{\mathbf{y}_i, \mathbf{X}_i}(\boldsymbol{\beta}) = \log f(\mathbf{y}_i; \mathbf{X}_i \boldsymbol{\beta})$  と書くことにする. また,  $\mathcal{D}$  を添字集合の素な分割, つまり  $\bigcup_{d \in \mathcal{D}} d = \{1, \dots, p\}$  で  $d, d' \in \mathcal{D}$  ( $d \neq d'$ ) に対して  $d \cap d' = \emptyset$  とする. ここで  $\mathcal{D}$  における group Lasso 推定量として以下を考える.

$$\hat{\boldsymbol{\beta}}_\lambda \equiv \operatorname{argmin}_{\boldsymbol{\beta}} \left\{ - \sum_{i=1}^n g_{\mathbf{y}_i, \mathbf{X}_i}(\boldsymbol{\beta}) + n\lambda \sum_{d \in \mathcal{D}} \|\boldsymbol{\beta}_d\| \right\}$$

ただし  $\|\cdot\|$  は  $L_2$  ノルム,  $\boldsymbol{\beta}_d = (\beta_j)_{j \in d}$  は  $\boldsymbol{\beta}$  の部分ベクトルである. このとき正則化パラメータである  $\lambda$  の妥当な値を与えるための AIC を以下で与える (Komatsu et al [2]).

$$\text{AIC}_\lambda^{\text{GL}} = -2 \sum_{i=1}^n g_{\mathbf{y}_i, \mathbf{X}_i}(\hat{\boldsymbol{\beta}}_\lambda) + 2 \operatorname{tr} \{ \hat{\mathbf{J}}_n^{*(22)} (\hat{\mathbf{J}}_n^{** (22)} + \lambda \hat{\mathbf{L}}^{** (22)})^{-1} \}$$

ただし  $\hat{\boldsymbol{\beta}}_{\lambda, d}$  は  $\boldsymbol{\beta}_d$  の group Lasso 推定量であり,  $\hat{\mathcal{D}}^{(2)} = \{d \mid \hat{\boldsymbol{\beta}}_{\lambda, d} \neq \mathbf{0}\}$ ,  $\hat{\mathcal{J}}^{(2)} = \{j \in d \mid d \in \hat{\mathcal{D}}^{(2)}\}$  とする. また  $\mathbf{J}_n(\boldsymbol{\beta}) = \sum_{i=1}^n \mathbf{X}_i^T a''(\mathbf{X}_i \boldsymbol{\beta}) \mathbf{X}_i / n$ ,  $\mathbf{L}_d(\boldsymbol{\beta}) = (\|\boldsymbol{\beta}_d\|^2 I_{|d|} - \boldsymbol{\beta}_d \boldsymbol{\beta}_d^T) / \|\boldsymbol{\beta}_d\|^3$  に対し,  $|\hat{\mathcal{J}}^{(2)}| \times |\hat{\mathcal{J}}^{(2)}|$  行列  $\hat{\mathbf{J}}_n^{*(22)}$ ,  $\hat{\mathbf{J}}_n^{** (22)}$ ,  $\hat{\mathbf{L}}^{** (22)}$  をそれぞれ  $(\mathbf{J}_n(\hat{\boldsymbol{\beta}}_0)_{jk})_{j \in \hat{\mathcal{J}}^{(2)}, k \in \hat{\mathcal{J}}^{(2)}}$ ,  $(\mathbf{J}_n(\hat{\boldsymbol{\beta}}_\lambda)_{jk})_{j \in \hat{\mathcal{J}}^{(2)}, k \in \hat{\mathcal{J}}^{(2)}}$ ,  $\operatorname{diag}_{d \in \hat{\mathcal{D}}^{(2)}}(\mathbf{L}_d(\hat{\boldsymbol{\beta}}_\lambda))$  としている. ここで  $\mathcal{D}$  の要素が全て 1, つまり Lasso を考えると上記で与えた AIC は Ninomiya and Kawano [3] で与えられたものと一致する.

## 参考文献

- [1] Ming Yuan and Yi Lin. Model selection and estimation in regression with grouped variables. *Journal of the Royal Statistical Society: Series B*, Vol. 68, No. 1, pp. 49–67, 2006.
- [2] Satoshi Komatsu, Yuta Yamashita, and Yoshiyuki Ninomiya. AIC for the group Lasso in generalized linear models. *Japanese Journal of Statistics and Data Science*, 2019 (accepted).
- [3] Yoshiyuki Ninomiya and Shuichi Kawano. AIC for the Lasso in generalized linear models. *Electronic Journal of Statistics*, Vol. 10, No. 2, pp. 2537–2560, 2016.