

Huber lossの共変量に対するロバスト性について

笹井 健行 総合研究大学院大学 統計科学専攻 博士課程(3年編入学)3年

1 問題設定と結果のサマリ

次のモデルからのスパースな回帰係数 $\beta^* \in \mathbb{R}^d$ を推定したい:

$$y_i = \mathbf{x}_i^\top \beta^* + \xi_i, \quad i = 1, \dots, n, \quad (1)$$

分析者はi.i.d.列 $\{y_i, \mathbf{x}_i\}_{i=1}^n$ を観測できるものとし、 $\{\xi_i\}_{i=1}^n$ は $\{\mathbf{x}_i\}_{i=1}^n$ とは独立なランダムノイズとする。 β^* の非0要素数を s とする。多くの研究では、 $\{\mathbf{x}_i\}_{i=1}^n$ は多変量正規分布に従う場合を扱っている。この時、さらに $\{\xi_i\}_{i=1}^n$ が分散 σ^2 の正規分布に従うと仮定ことで、通常のlassoの手続き

$$\hat{\beta} = \operatorname{argmin}_{\beta \in \mathbb{R}^d} \left\{ \sum_{i=1}^n \|y_i - \mathbf{x}_i^\top \beta\|_2^2 + \lambda_s \|\beta\|_1 \right\}, \quad (2)$$

により、(1)から β^* を

$$\mathbb{P} \left\{ \|\hat{\beta} - \beta^*\|_2 \lesssim \left(\sqrt{s \frac{\log(d/s)}{n}} + \sqrt{\frac{\log(1/\delta)}{n}} \right) \right\} \geq 1 - \delta, \quad (3)$$

と推定できる。いくつかの研究は、 $\{\mathbf{x}_i\}_{i=1}^n$ として、多変量正規分布を含むクラスである L -subGaussianを扱っている。また、 $\{\xi_i\}_{i=1}^n$ が裾が厚い分布に従っている場合は、lassoの二乗損失をHuber lossに変更した ℓ_1 -罰則付きHuber回帰により、(3)と定数を除いて同様の結果を得られることが、先行研究により判明している[4]。

ところで、 $\{\mathbf{x}_i\}_{i=1}^n$ が多変量正規分布や L -subGaussianよりも裾が厚い分布に従う場合を考察した論文は少ない[1, 3, 2]。特に、[3, 2]は、 L -subGaussianよりも一回り裾が厚い分布のクラスとして、 L -subexponentialと呼ばれる分布を仮定し、議論している。先行研究[3, 2]は(3)のような結果を出そうと試みているが、余分な条件として $s(\log(d/s))^2 \lesssim n$ が必要となる。本研究では、 $\{\mathbf{x}_i\}_{i=1}^n$ が L -subexponentialに従う場合であっても、これまで $\{\xi_i\}_{i=1}^n$ に対してのみロバスト性を発揮すると考えられてきた ℓ_1 -罰則付きHuber回帰により、実はこの余分な条件なしに(3)と定数を除いて同様な結果が得られることを示す。

2 定義・例

確率変数 f に対してOrliczノルムを次のように定義する:

$$\|f\|_{\psi_\alpha} := \inf \{ \eta > 0 : \mathbb{E} \exp |f/\eta|^\alpha \leq 2 \} < \infty. \quad (4)$$

ここで、任意の固定した $\mathbf{v} \in \mathbb{R}^d$ に対して、 d 次元確率変数 \mathbf{x} が、次の(5)を $\alpha = 1$ で満たす場合は L -subexponential、 $\alpha = 2$ で満たす場合は L -subGaussianという:

$$\|\langle \mathbf{x}, \mathbf{v} \rangle\|_{\psi_\alpha} \leq L \left(\mathbb{E} |\langle \mathbf{x}, \mathbf{v} \rangle|^2 \right)^{\frac{1}{2}}. \quad (5)$$

定義より、 L -subGaussianは L -subexponentialである。 L -subGaussianの例としては、多変量正規分布や各成分が独立なRademacher確率変数に従う分布などがあり、 L -subexponentialの例としては、各成分が独立なガンマ分布に従う分布などがある。

3 仮定・結果

Huber lossを以下のように定義する:

$$H(t) = \begin{cases} |t| - 1/2 & (|t| > 1) \\ t^2/2 & (|t| \leq 1) \end{cases}. \quad (6)$$

ノイズと共変量 $\{\xi_i, \mathbf{x}_i\}_{i=1}^n$ に以下の仮定をおく:

(i) \mathbf{x}_i は L -subexponential分布に従い、 $\mathbb{E} \mathbf{x}_i = 0$, $\mathbb{E} \mathbf{x}_i \mathbf{x}_i^\top = I$,

(ii) $\mathbb{E} \xi_i^2 \leq \sigma^2$.

上記の仮定の下、推定量

$$\hat{\beta} = \operatorname{argmin}_{\beta \in \mathbb{R}^d} \left\{ \sum_{i=1}^n \lambda_o^2 H \left(\frac{y_i - \mathbf{x}_i^\top \beta}{\lambda_o \sqrt{n}} \right) + \lambda_s \|\beta\|_1 \right\} \quad (7)$$

は、 $\lambda_o \asymp \sigma L^2 / \sqrt{n}$, $\lambda_s \asymp L^3 \sigma \left(\sqrt{s \frac{\log(d/s)}{n}} + \sqrt{\frac{\log(1/\delta)}{n}} \right)$ のもとで以下を満たす:

$$\mathbb{P} \left\{ \|\hat{\beta} - \beta^*\|_2 \lesssim L^3 \sigma \left(\sqrt{s \frac{\log(d/s)}{n}} + \sqrt{\frac{\log(1/\delta)}{n}} \right) \right\} \geq 1 - \delta. \quad (8)$$

4 なぜHuber lossでうまくいくのか?

今回の設定で ℓ_1 罰則付きHuber回帰が効果的な理由を標題的に述べると「ノイズ $\{\xi_i\}_{i=1}^n$ の挙動を抑えることで $\{\mathbf{x}_i\}_{i=1}^n$ が動く余裕を与えられるから」である。以下、詳しく解説する。

Huber lossの微分を次のように定義する:

$$h(t) = \frac{d}{dt} H(t) = \begin{cases} t & (|t| \leq 1) \\ \operatorname{sgn}(t) & (|t| > 1) \end{cases}. \quad (9)$$

通常のlassoの場合、以下のような量の評価が重要である(r_1, r_2 はパラメータ)

$$\sup_{\mathbf{v} \in r_1 \mathbb{B}_1^d \cap r_2 \mathbb{B}_2^d} \sum_{i=1}^n \frac{1}{n} \xi_i \mathbf{x}_i^\top \mathbf{v}. \quad (10)$$

一方で、(7)の場合は

$$\sup_{\mathbf{v} \in r_1 \mathbb{B}_1^d \cap r_2 \mathbb{B}_2^d} \sum_{i=1}^n \frac{1}{n} h(\xi_i) \mathbf{x}_i^\top \mathbf{v} \quad (11)$$

を評価すればよい。 \mathbf{x}_i が L -subGaussianかつ ξ_i が σ -subGaussianの場合、(10)における $\xi_i \mathbf{x}_i$ は $L\sigma$ -subexponentialとなる。しかし、 \mathbf{x}_i が L -subexponentialの場合、たとえ ξ_i がGaussianであっても $\xi_i \mathbf{x}_i$ は L -subexponentialとはならない。一方で、(11)における $h(\xi_i) \mathbf{x}_i$ は $h(\cdot)$ の有界性ゆえに L -subexponentialであり続ける。この現象により、多少の共変量の裾の厚さをHuber lossで吸収できる。

L -subGaussian L -subexponential $h(\xi_i) \mathbf{x}_i$ $\xi_i \mathbf{x}_i$

Huber lossにより分布が変化するイメージ

参考文献

- [1] J. Fan, W. Wang, and Z. Zhu. *Annals of statistics*, 49(3):1239, 2021.
- [2] M. Genzel and C. Kipp. *Sampling Theory, Signal Processing, and Data Analysis*, 20(2):15, 2022.
- [3] V. Sivakumar, A. Banerjee, and P. K. Ravikumar. *Advances in neural information processing systems*, 28, 2015.
- [4] Q. Sun, W. Zhou, and J. Fan. *Journal of the American Statistical Association*, 115(529):254–265, 2020.