


冪密度ダイバージェンスの最小化 およびそのパッケージ化の近況

奥野彰文^{1,2}

¹統計数理研究所, ²理研AIP

何をしたのか



▶ 一般の確率モデル p_θ でのロバスト推定

$$\min_{\theta} \left\{ -\frac{1}{\beta} \frac{1}{n} \sum_{i=1}^n p_\theta(x_i)^\beta + \frac{1}{1+\beta} \int p_\theta(x)^{1+\beta} dx \right\}$$

一般の確率モデルでのロバスト推定 (Okuno, AISM2024)

分布の推定

- ▶ 観測値 x_1, x_2, \dots, x_n が従う分布 Q を知りたい。

経験分布 $\hat{Q}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}(x_i \leq x)$ と確率モデル P_θ のKLダイバージェンス (=乖離度)

$$D(\hat{Q}_n, P_\theta) = -\frac{1}{n} \sum_{i=1}^n \log p_\theta(x_i) + \text{Const.}$$

を最小化して P_θ が求まる。最尤推定と等価。




Figure: 最尤推定が外れ値に影響を受けるという典型的な図

ロバストな分布の推定

冪密度ダイバージェンス (Density power divergence, DPD; Basu et al. 1998):

$$D_{\beta}(\hat{Q}, P_{\theta}) = -\frac{1}{\beta} \frac{1}{n} \sum_{i=1}^n p_{\theta}(x_i)^{\beta} + \frac{1}{1+\beta} \int p_{\theta}(x)^{1+\beta} dx + \text{Const.}$$

を最小化するとよい.

特に $\beta \searrow 0$ のときKLダイバージェンス(\Leftrightarrow 最尤推定)になる.

正規分布の場合, $\xi = 0.1$.




Figure: 外れ値の影響を軽減できた

研究を始める前の Q & A

Q. 外れ値を目視で外せばよいのでは

A. 私もそう思います. 希望があるとすれば高次元*や時系列, 自動化の文脈など...

Q. 本当に「ロバスト」な推定なんですか

A. ロバストって結局何なんでしょうか ⇒ <https://arxiv.org/abs/2407.10418>

Q. Huberみたいな昔ながらのロバスト推定ではダメですか

A. 平均等だけでなく, 分布そのものを推定できることが強みです.

Q. 計算コストはどうですか

A. 正規分布など**特定の分布以外での最適化は厳しい**です.

最適化のボトルネック

$$D_\beta(\hat{Q}, P_\theta) = -\frac{1}{\beta} \frac{1}{n} \sum_{i=1}^n p_\theta(x_i)^\beta + \underbrace{\frac{1}{1+\beta} \int p_\theta(x)^{1+\beta} dx}_{=: r_\theta^{(\beta)}} + \text{Const.}$$


- ▶ $P_\theta = N(\mu, \sigma^2)$ とすると, $r_\theta^{(\beta)} = (2\pi\sigma^2)^{-\beta/2}(1+\beta)^{-3/2}$.
- ▶ 計算できる: 正規, 一般化指数, 一般化パレート, ワイブルモデル.
- ▶ それ以外で計算できない. 例えば**一般の指数型分布モデルで計算できない**
 - ▶ 混合正規モデルでの近似最適化 (Fujisawa and Eguchi, 2006),
 - ▶ ポアソンモデルでの近似最適化 (Kawashima and Fujisawa, 2019),
 - ▶ 歪正規モデルでの近似最適化 (Nandy et al., 2022).

分布推定できることが強みなのに, 最適化できる確率モデルが少ない矛盾


雑談：かつて1本だけ書いたロバスト推定論文

- ▶ ポアソン回帰のような設定 (Okuno and Shimodaira, AISTATS2019): 確率分布 $P(y | \mathbf{x})$ ではなく, 平均関数 $\mu(\mathbf{x}) = \mathbb{E}(y | \mathbf{x})$ を推定する.


$$L_{\beta,n}(\boldsymbol{\theta}) := \sum_{(i,j) \in \mathcal{I}_n} \left\{ -w_{ij} \frac{\mu_{\boldsymbol{\theta}}(\mathbf{x}_i, \mathbf{x}_j)^{\beta} - 1}{\beta} + \frac{\mu_{\boldsymbol{\theta}}(\mathbf{x}_i, \mathbf{x}_j)^{1+\beta}}{1+\beta} \right\}.$$



$\beta = 0$



$\beta = 0.5$



$\beta = 1$

- ▶ …という逃げ方もあるが, 解く問題が変わっている.

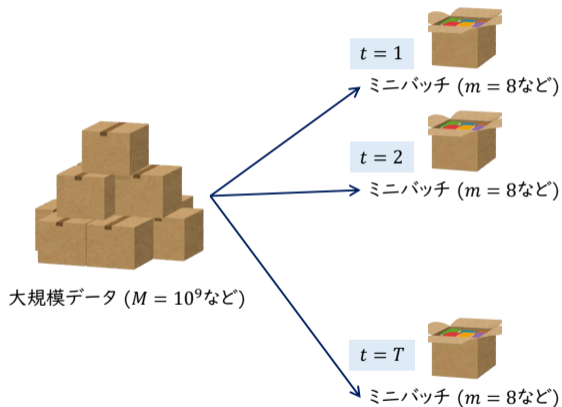
数値積分ではダメなのか

- ▶ 勾配法+数値積分: $y_1^{(t)}, y_2^{(t)}, \dots \sim p_{\theta^{(t)}}$ について


$$\begin{aligned}\theta^{(t+1)} &\leftarrow \theta^{(t)} - \gamma \nabla D_{\beta}(\hat{Q}, P_{\theta^{(t)}}) \\ &= \theta^{(t)} - \gamma \left\{ -\frac{1}{\beta} \frac{1}{n} \sum_{i=1}^n \nabla \{p_{\theta^{(t)}}(x_i)^{\beta}\} + \frac{1}{1+\beta} \underset{M \rightarrow \infty}{p \lim} \frac{1}{M} \sum_{j=1}^M \nabla \{p_{\theta^{(t)}}(y_j^{(t)})^{\beta}\} \right\}\end{aligned}$$

- ▶ 各反復で数値積分が必要: 次元 d が増えると必要な M は大きくなる ($M \sim \varepsilon^{1/d}$)
- ▶ 学習率 γ は固定, 数値積分のサンプルサイズ M は可能な限り大きくする.
- ▶ 計算量 $O(TM)$, 近似誤差は $T \rightarrow \infty$ でも $O_p(1/\sqrt{M}) > 0$.

ところで、深層学習で使われるミニバッチ最適化 ($M = \text{巨大}$)



積分 $\Leftrightarrow M = \infty$




提案法

$y_1^{(t)}, y_2^{(t)}, \dots \sim P_{\theta^{(t)}}$ について

$$\theta^{(t+1)} \leftarrow \theta^{(t)} - \gamma^{(t)} \left\{ -\frac{1}{\beta} \frac{1}{n} \sum_{i=1}^n \nabla \{p_{\theta^{(t)}}(x_i)^\beta\} + \frac{1}{1+\beta} \frac{1}{m} \sum_{j=1}^m \nabla \{p_{\theta^{(t)}}(y_j^{(t)})^\beta\} \right\}$$

- ▶ 学習率を下げるのがポイント $\gamma^{(t)} \rightarrow 0$ ($t \rightarrow \infty$).
- ▶ m は何でもよい. 例えば $m = 8$. $m = 1$ でもよい!
- ▶ 近似誤差 $O_p(1/\sqrt{M}) > 0$ のある数値積分と違い, **真値に収束する!** $\hat{\theta}^{(t)} \rightarrow \theta_*$.
- ▶ 最適化分野ではよく知られている: **確率的最適化** (Robbins and Monro, 1951).
- ▶ Contrastive divergence (Hinton et al., 2002).

逆ガウス分布の場合, $\xi = 0.1$.



$$p_{\theta}(x) = \sqrt{\frac{\lambda}{2\pi x^3}} \exp\left(-\frac{\lambda(x - \mu)^2}{2\mu^2 x}\right)$$

(*逆ガウス分布は積分項が明示的に計算できない)




Figure: Gompertz分布のフィッティング




Figure: 混合ガウス分布のフィッティング

$$\text{Gompertz: } p_{\theta}(x) = \lambda \exp\left(\omega x + \frac{\lambda}{\omega} \{1 - \exp(\omega x)\}\right), \quad (x \geq 0).$$

(*Gompertz分布も混合ガウス分布も積分項が明示的に計算できない)

sgdspdパッケージ



Overview

This repository offers a user-friendly `sgdspd` package for an optimizer minimizing the density power divergence proposed by [Basu et al. \(1998\)](#):

$$L_{\alpha}(\theta) = -\frac{1}{\alpha} \frac{1}{n} \sum_{i=1}^n f_{\theta}(x_i)^{\alpha} + \frac{1}{1+\alpha} \int f_{\theta}(x)^{1+\alpha} dx.$$

This optimizer needs minimal effort for users to obtain the optimal parameter, to estimate general parametric models. To cite this package, please cite the following manuscript:

```
@article{okuno2024DPD,  
  year = {2024},  
  volume = {},  
  number = {},  
  pages = {},  
  author = {Akifumi Okuno},  
  title = {Minimizing robust density power-based divergences for general parametric densit},  
  journal = {Annals of the Institute of Statistical Mathematics},  
  note = {To appear.}  
}
```

Quickstart

Install

Please enter and execute the following command to install our `sgdspd` package.

```
install.packages("https://okuno.net/R-packages/sgdspd-1.0.0.zip", repos=NULL, type="win.binary")
```

Figure: <https://github.com/oknakfm/sgdspd>

▶ “sgdspd”をyoutubeで検索!

実は課題が山積み

- ▶ 提案分布 $p_{\theta(t)}$ から乱数を生成できると限らない.
 - ▶ 提案分布 \tilde{p}_t に分離した場合の一般の収束条件を求めているない.
 - ▶ p_{θ} が混合ガウスなら $\mathbb{E}(\{p_{\theta(t)}(y)/\tilde{p}_t(y)\}^4) < \infty$ で収束.
- ▶ sgdpd パッケージでは、標本平均/標本分散を用いた正規分布が提案分布 \tilde{p}_t .
 - ▶ 設定によっては著しく収束が悪い. 特に回帰などは提案分布が退化して絶望的.
 - ▶ 自己回帰での共同研究が進行中 (with Nandy, Pyne, and Basu from ISI)




Figure: 多項式回帰の例. 苦肉の策として “conditions=c(1)” という命令を実装.

まとめ

- ▶ Akifumi Okuno. Minimizing robust density power-based divergences for general parametric density models. AISM. 2024.
(一般の確率モデルでのロバストダイバージェンス最小化)
- ▶ sgdpdパッケージ: <https://github.com/oknakfm/sgdpd>
- ▶ 日本語での解説: Jxiv.642

質問やコメントは okuno@ism.ac.jp まで.