

カーネルモード推定における最適カーネルの設計

京都大学大学院情報学研究科 山崎 遼也

京都大学大学院情報学研究科 田中 利幸

確率密度関数 f を持つ確率分布に従う i.i.d. サンプル $\{X_i \in \mathbb{R}\}_{i=1}^n$ が与えられたとする。カーネルモード推定 (Parzen, 1962) では、カーネル密度推定による密度推定結果 f_n が最大値をとる点 θ_n をモード θ の推定量 (カーネルモード推定量, KME) とする:

$$\theta_n := \arg \max_{x \in \mathbb{R}} f_n(x), \quad \text{ただし, } f_n(x) = \frac{1}{n} \sum_{i=1}^n K_{h_n}(x - X_i) = \frac{1}{nh_n} \sum_{i=1}^n K\left(\frac{x - X_i}{h_n}\right).$$

カーネル関数 K が q 次モーメント条件

$$B_i := \int x^i K(x) dx = 1 \quad (i = 0); \quad 0 \quad (i = 1, \dots, q); \quad \text{非ゼロの有限値} \quad (i = q)$$

を満たすとき、KME θ_n の漸近平均二乗誤差 (AMSE) は

$$E[(\theta_n - \theta)^2 | h_n] = \underbrace{\frac{h_n^{2q} \{f^{(q+1)}(\theta)\}^2 B_q^2}{(q!)^2 \{f^{(2)}(\theta)\}^2}}_{\text{漸近二乗バイアス由来}} + \underbrace{\frac{f(\theta)V}{nh_n^3 \{f^{(2)}(\theta)\}^2}}_{\text{漸近分散由来}} + O(h_n^{2q+2} + (nh_n)^{-1})$$

となる (ただし, $V := \int \{K^{(1)}(x)\}^2 du < \infty$ である). AMSE を最小化する最適な帯域幅 h_n^{opt} と, その帯域幅を用いたときの AMSE (の主要項) は

$$h_n^{\text{opt}} = \left[\frac{3(q!)^2 f(\theta)V}{2qn \{f^{(q+1)}(\theta)\}^2 B_q^2} \right]^{\frac{1}{2q+3}}; \quad E[(\theta_n - \theta)^2 | h_n^{\text{opt}}] \propto n^{-\frac{2q}{2q+3}} \cdot \left(B_q^6 \cdot V^{2q} \right)^{\frac{1}{2q+3}}$$

となる。従って、最適な帯域幅 h_n^{opt} に対する AMSE に現れるカーネル依存項 (汎関数) $B_q^6 \cdot V^{2q}$ を最小化するカーネル関数を用いることで、KME θ_n の AMSE を最大限最小化することができる。変分問題

$$\min_K B_q^6 \cdot V^{2q}, \quad \text{s.t. } K \text{ が } q \text{ 次モーメント条件を満たす}$$

はそのままでは解を持たないが、Granovsky and Müller (1991) はカーネル関数の符号の変化回数に制約を与えることで、偶数次数 q に対して最適なカーネルを与えた。

本研究では、(Granovsky and Müller, 1991) と同様の議論から、多変量カーネルモード推定に対する最適カーネルを導出した。また、同様の変分問題が他のカーネルベースのモード統計手法 (例えば、シンプルモード推定 (Abraham et al., 2004) やモード線形回帰 (Yao and Li, 2014)) にも現れることが分かった。これらを含む最適カーネルについて得られた結果を発表する予定である。

参考文献

- C. Abraham, G. Biau, and B. Cadre. On the asymptotic properties of a simple estimate of the mode. *ESAIM: Probability and Statistics*, 8:1–11, 2004.
- B. L. Granovsky and H.-G. Müller. Optimizing kernel methods: a unifying variational principle. *International Statistical Review/Revue Internationale de Statistique*, 59(3):373–388, 1991.
- E. Parzen. On estimation of a probability density function and mode. *The Annals of Mathematical Statistics*, 33(3):1065–1076, 1962.
- W. Yao and L. Li. A new regression model: modal linear regression. *Scandinavian Journal of Statistics*, 41(3): 656–671, 2014.