

低次元多様体上の Data Sharpening

島根大学総合理工学研究科 工藤 雅紀 島根大学総合理工学研究科 内藤 貴太

1. はじめに ノンパラメトリック核型回帰において、バイアス縮小を導く方法として Data Sharpening が知られている．本発表では，説明変数が低次元多様体に埋め込まれている設定で，Data Sharpening を構成し，その理論的・数値的検証について報告する．

2. **Data Sharpening** 推定量 p 変数の説明変数を X ，1 変数の目的変数を Y とし，その独立な n 個の観測値を $\{(X_i, Y_i) | 1 \leq i \leq n\}$ とする． $\varepsilon_1, \dots, \varepsilon_n$ を i.i.d の誤差とし，回帰モデル

$$Y_i = m(X_i) + v(X_i)\varepsilon_i, \quad E[\varepsilon_i] = 0, \quad \text{Var}[\varepsilon_i] = 1, \quad i = 1, \dots, n$$

を想定する．推定のターゲットは m である．Bickel & Li (2007) での設定を踏まえ，説明変数が d 次元多様体 $\mathcal{M}(d \leq p, \mathcal{M} \subset \mathbb{R}^p)$ に埋め込まれているとする．すなわち， $X_i \in \mathcal{M}$ を仮定する．このとき， $x \in \mathcal{M}$ に対して， d 次元のある開球から x の近傍へのなめらかな写像 φ が存在する．そこで，非退化な d 次元の密度関数 $f(z)$ が存在するとして， $f(\varphi^{-1}(x))$ を X の密度関数とする．

$\mathbb{R}^p \ni x$ における $m(x)$ の初期推定量 $\hat{m}_{LL}(x, h)$ は，局所線形推定量で構成する．ここで， $\hat{m}_{LL}(x, h) = e_1^T (X_x^T W_x X_x)^T X_x^T W_x \underline{Y}$ であり，

$$X_x = \begin{bmatrix} 1 & (X_1 - x)^T \\ \vdots & \vdots \\ 1 & (X_n - x)^T \end{bmatrix}, \quad \underline{Y} = \begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix}, \quad W_x = \text{diag}(K_h(X_1 - x), \dots, K_h(X_n - x)),$$

K は球状対称なカーネル関数， $h > 0$ はバンド幅， $K_h(U) = K(U/h^p)$ ， $e_1 = [1, 0, \dots, 0]^T$ である．

残差 $r_i := Y_i - \hat{m}_{LL}(X_i, h)$ から， $\{(X_i, r_i) | 1 \leq i \leq n\}$ の局所線形推定量として $\hat{r}_{LL}(x, h) = e_1^T (X_x^T W_x X_x)^T X_x^T W_x \underline{R}$ を構成する．ここで， $\underline{R} = [r_1, \dots, r_n]^T$ である．Data Sharpening 推定量は $\hat{m}(x, h) := \hat{m}_{LL}(x, h) + \hat{r}_{LL}(x, h)$ として得られる．

3. 漸近挙動 $x \in \mathcal{M}$ ， $n \rightarrow \infty$ ， $h \rightarrow 0$ ， $1/(nh^d) \rightarrow 0$ のもとで，

$$E[\hat{m}(x, h) - m(x) | X_1, \dots, X_n] = h^4 J_1(x | \varphi, \mathcal{H}_m, K) + o_p(h^4), \\ \text{Var}[\hat{m}(x, h) | X_1, \dots, X_n] = \frac{1}{nh^d} J_2(x | \varphi, v, f, K)(1 + o_p(1))$$

となる x の関数 J_1, J_2 が存在する．ここで， J_1 は m のヘッセ行列 \mathcal{H}_m と K および φ に依存し， J_2 は v, f, K, φ に依存する．Bickel & Li (2007) で議論された $\hat{m}_{LL}(x, h)$ はバイアスが $O(h^2)$ ，分散は $O(1/(nh^d))$ である．一方， $\hat{m}(x, h)$ のバイアスは $O(h^4)$ ，分散は $O(1/(nh^d))$ であり，バイアス縮小が生じていることがわかる．

参考文献

Bickel, P. and Li, B. (2007). Local polynomial regression on unknown manifolds. *In Complex Datasets and Inverse Problems: Tomography, Networks and Beyond. Institute of Mathematical Statistics Lecture Notes-Monograph Series, Vol. 54 177-186*.