

第4章 誤特定された線型モデル

前章まででおいた仮定は強いものであった。すなわち、回帰関数 $f(x)$ は線型性をもつとした。

$$f(x) = x^\top \beta.$$

この仮定がみたされない場合はどうなるであろうか？ 現実には、線型性を信じたりはしない。よい統計手法は、このモデルからの乖離に対して頑強であることが期待される。線型性の誤特定にかかわる問題である。

この章では、次のモデルを仮定する。

$$Y_j = f(\mathbf{X}_j) + \epsilon_j \quad (j = 1, 2, \dots, n). \quad (4.1)$$

ただし、 $\epsilon := (\epsilon_1, \epsilon_2, \dots, \epsilon_n)^\top$ は交代分散 σ^2 ($\sigma > 0$) の劣 Gauss 分布とし、 $\mathbf{X}_i \in \mathbb{R}^d$ とする。任意の関数 $f: \mathbb{R}^d \rightarrow \mathbb{R}$ に対して、 \mathbf{X}_j ($j = 1, 2, \dots, n$) における f の値を集めたベクトルを

$$\mathbf{f} = (f(\mathbf{X}_1), f(\mathbf{X}_2), \dots, f(\mathbf{X}_n))^\top \in \mathbb{R}^n$$

と書くことにする。固定デザインの場合

$$\text{MSE}(\hat{\mathbf{f}}) = \frac{1}{n} \|\mathbf{f} - \hat{\mathbf{f}}\|_{2,n}^2 = \frac{1}{n} \sum_{j=1}^n \{f(\mathbf{X}_j) - \hat{f}(\mathbf{X}_j)\}^2$$

として、 f の推定量 $\hat{\mathbf{f}}$ の精度を評価する。ただし

$$\hat{\mathbf{f}} = (\hat{f}(\mathbf{X}_1), \hat{f}(\mathbf{X}_2), \dots, \hat{f}(\mathbf{X}_n))^\top \in \mathbb{R}^n$$

である。

真のモデルは線型性をみたしていないとき、前章で考えた推定量 $\hat{\beta}^{\text{LS}}$, $\hat{\beta}^{\text{BIC}}$, $\hat{\beta}^{\text{L}}$ の精度を議論する。これらの推定量について何らかの主張をする。

4.1 オラクル不等式

オラクルとは、興味ある量（ここでは、回帰関数）の事前の知識なしでは、構成できない量のことをいう。ここでは、データを無限個観察したときの推定量のことをいう。

最小 2 乗推定量を採用するとき、関数 f が線型性をみたしているかどうかに関わらず、考察を関数

$$\boldsymbol{x} \mapsto \boldsymbol{\beta}^\top \boldsymbol{x} \quad (\boldsymbol{x} \in \mathbb{R}^d)$$

に限定していることになる。したがって、オラクル \hat{f} は f にもっとも近い線型関数である。線型関数 $\boldsymbol{\beta}^\top \boldsymbol{x} \approx f$ で f を近似するより、もうすこし一般的なモデルを考える。関数 $\varphi_j : \mathbb{R}^d \rightarrow \mathbb{R}$ ($j = 1, 2, \dots, M; M \in \mathbb{N}$) の集まりである (これを辞書と呼ぼう。) $\{\varphi_1, \varphi_2, \dots, \varphi_M\}$ を考える。実際、目標は、辞書の中の関数の線型結合

$$\varphi_\beta(\boldsymbol{x}) = \sum_{j=1}^M \beta_j \varphi_j(\boldsymbol{x}) \quad (\beta_j \in \mathbb{R}; \boldsymbol{x} \in \mathbb{R}^d)$$

を用いて、 f の推定を考える。

注意 4.1. $M = d$ とし、 $\varphi_j(X) = X^{(j)}$ ($j = 1, 2, \dots, d$) とする。ただし、 $X^{(j)}$ は X の第 j 要素とする。このとき、 $f(\boldsymbol{x})$ を $\boldsymbol{\beta}^\top \boldsymbol{x}$ で近似することになる。辞書を使用することで、より広い枠組みを考えることができる。
□

辞書をもちいても最小 2 乗推定量や制約付き最小 2 乗推定量は変化しない。

$$\begin{aligned} \varphi_\beta(\boldsymbol{x}) &= \sum_{j=1}^M \beta_j \varphi_j(\boldsymbol{x}) \quad (\boldsymbol{x} \in \mathbb{R}^d; \beta_1, \beta_2, \dots, \beta_M \in \mathbb{R}), \\ \boldsymbol{\varphi}_\beta &= (\varphi_\beta(\boldsymbol{X}_1), \varphi_\beta(\boldsymbol{X}_2), \dots, \varphi_\beta(\boldsymbol{X}_n))^\top \in \mathbb{R}^n \end{aligned}$$

とする。

1. 最小 2 乗推定量

$$\hat{\boldsymbol{\beta}}^{\text{LS}} \in \arg \min_{\boldsymbol{\beta} \in \mathbb{R}^M} \frac{1}{n} \sum_{j=1}^n \{Y_j - \varphi_\beta(\boldsymbol{X}_j)\}^2. \quad (4.2)$$

2. $K \subset \mathbb{R}^M$ に制約した最小 2 乗推定量

$$\hat{\boldsymbol{\beta}}_K^{\text{LS}} \in \arg \min_{\boldsymbol{\beta} \in K} \frac{1}{n} \sum_{j=1}^n \{Y_j - \varphi_\beta(\boldsymbol{X}_j)\}^2.$$

3. BIC 推定量

$$\hat{\boldsymbol{\beta}}^{\text{BIC}} \in \arg \min_{\boldsymbol{\beta} \in \mathbb{R}^M} \left\{ \frac{1}{n} \sum_{j=1}^n \{Y_j - \varphi_\beta(\boldsymbol{X}_j)\}^2 + 2\tau |\boldsymbol{\beta}|_0 \right\}. \quad (4.3)$$

ただし, $\tau > 0$ で $|\beta|_0$ は β の零でない要素の個数である.

4. Lasso 推定量

$$\hat{\beta}^L \in \arg \min_{\beta \in \mathbb{R}^M} \left\{ \frac{1}{n} \sum_{j=1}^n \{Y_j - \varphi_{\beta}(\mathbf{X}_j)\}^2 + \tau^2 |\beta|_1 \right\}. \quad (4.4)$$

ただし, $\tau > 0$ で $|\beta|_1 = \sum_{j=1}^M |\beta_j|$ ($\beta = (\beta_1, \beta_2, \dots, \beta_M)^\top$) である.

定義 4.2. $M \in \mathbb{N}$ とし, $R(\cdot)$ をリスク関数とする. $\mathcal{H} = \{\varphi_1, \varphi_2, \dots, \varphi_M\}$ を \mathbb{R}^d 上で定義された \mathbb{R} 値関数の辞書とする. K を \mathbb{R}^M の部分集合とする. リスク関数 R に関する K 上のオラクル $\varphi_{\bar{\beta}}$ ($\bar{\beta} \in K$) を

$$R(\varphi_{\bar{\beta}}) \leq R(\varphi_{\beta}) \quad (\forall \beta \in K)$$

をみたすものと定義する. さらに, $R_K = R(\varphi_{\bar{\beta}})$ を K 上のオラクルリスクという. 推定量 \hat{f} は剰余項 ϕ の K 上のオラクル不等式をみたすとは, 次のいずれかが成立することをいう.

(1) ある定数 $C \geq 1$ が存在して

$$E[R(\hat{f})] \leq C \inf_{\beta \in K} R(\varphi_{\beta}) + \phi_{n,M}(K).$$

(2) または, $\forall \delta > 0$ に対して

$$\Pr \left(R(\hat{f}) \leq C \inf_{\beta \in K} R(\varphi_{\beta}) + \phi_{n,M}(K) \right) \geq 1 - \delta.$$

$C = 1$ のとき, 不等式は厳密という.

4.1.1 最小 2 乗推定量のオラクル不等式

モデルが誤特定された場合について, BIC 推定量と LASSO 推定量に対するスパース・オラクル不等式を証明するのが目的である. この拡張を証明する上で難しいところは, 最小 2 乗推定量を扱うときに現れる.

定理 4.3. $n > M$ とし, $\{\varphi_1, \varphi_2, \dots, \varphi_M\}$ を辞書とする. 回帰モデル (4.1) で $\epsilon \sim \text{subG}_n(\sigma^2)$ ($\sigma > 0$) を考える. このとき, 最小 2 乗推定量 $\hat{\beta}^{\text{LS}}$ は次をみたす. ある $C > 0$ が存在して, 任意の $\forall \delta > 0$ に対して,

$$\Pr \left(\text{MSE}(\varphi_{\hat{\beta}^{\text{LS}}}) \leq \inf_{\beta \in \mathbb{R}^M} \text{MSE}(\varphi_{\beta}) + C\sigma^2 \frac{M + \log(1/\delta)}{n} \right) \geq 1 - \delta$$

が成立する. ただし, $\hat{\beta}^{\text{LS}}$ は (4.2) で与えられ

$$\begin{aligned} \varphi_{\hat{\beta}^{\text{LS}}} &= (\varphi_{\hat{\beta}^{\text{LS}}}(\mathbf{X}_1), \varphi_{\hat{\beta}^{\text{LS}}}(\mathbf{X}_2), \dots, \varphi_{\hat{\beta}^{\text{LS}}}(\mathbf{X}_n))^\top \in \mathbb{R}^n, \\ \varphi_{\hat{\beta}^{\text{LS}}}(\mathbf{x}) &= \sum_{j=1}^M \hat{\beta}_j^{\text{LS}} \varphi_j(\mathbf{x}); \quad \hat{\beta}^{\text{LS}} = (\hat{\beta}_1^{\text{LS}}, \hat{\beta}_2^{\text{LS}}, \dots, \hat{\beta}_M^{\text{LS}})^\top \in \mathbb{R}^M \end{aligned}$$

である.

Proof. 最小 2 乗推定量 $\hat{\beta}^{\text{LS}}$ の定義より,

$$|\mathbf{Y} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 \leq |\mathbf{Y} - \varphi_{\bar{\beta}}|_{2,n}^2$$

である. ただし, $\varphi_{\bar{\beta}}$ は $\varphi_1, \varphi_2, \dots, \varphi_M$ の張る線型部分空間 $\text{span}\{\varphi_1, \varphi_2, \dots, \varphi_M\}$ への f の直交射影である. $\mathbf{Y} = f + \epsilon$ なので

$$\begin{aligned} |\mathbf{f} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 &= |\mathbf{Y} - \varphi_{\hat{\beta}^{\text{LS}}} - \epsilon|_{2,n}^2 \\ &= |\mathbf{Y} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 - 2\epsilon^\top (\mathbf{Y} - \varphi_{\hat{\beta}^{\text{LS}}}) + |\epsilon|_{2,n}^2 \\ &\leq |\mathbf{Y} - \varphi_{\bar{\beta}}|_{2,n}^2 - 2\epsilon^\top (\mathbf{Y} - \varphi_{\hat{\beta}^{\text{LS}}}) + |\epsilon|_{2,n}^2 \\ &= |\mathbf{f} + \epsilon - \varphi_{\bar{\beta}}|_{2,n}^2 - 2\epsilon^\top (\mathbf{Y} - \varphi_{\hat{\beta}^{\text{LS}}}) + |\epsilon|_{2,n}^2 \\ &= |\mathbf{f} - \varphi_{\bar{\beta}}|_{2,n}^2 + 2\epsilon^\top (\mathbf{f} - \varphi_{\bar{\beta}}) + |\epsilon|_{2,n}^2 - 2\epsilon^\top (\mathbf{Y} - \varphi_{\hat{\beta}^{\text{LS}}}) + |\epsilon|_{2,n}^2 \\ &= |\mathbf{f} - \varphi_{\bar{\beta}}|_{2,n}^2 + 2\epsilon^\top \{\mathbf{f} - \varphi_{\bar{\beta}} + \epsilon - \mathbf{Y} + \varphi_{\hat{\beta}^{\text{LS}}}\} \\ &= |\mathbf{f} - \varphi_{\bar{\beta}}|_{2,n}^2 + 2\epsilon^\top \{\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}\} \end{aligned}$$

となる. よって

$$|\mathbf{f} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 \leq |\mathbf{f} - \varphi_{\bar{\beta}}|_{2,n}^2 + 2\epsilon^\top \{\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}\} \quad (4.5)$$

を得る. さらに, Pythagoras の定理より

$$\begin{aligned} |\mathbf{f} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 &= |\mathbf{f} - \varphi_{\bar{\beta}} + \varphi_{\bar{\beta}} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 \\ &= |\mathbf{f} - \varphi_{\bar{\beta}}|_{2,n}^2 + 2 \underbrace{(\mathbf{f} - \varphi_{\bar{\beta}})}_{\in \text{span}\{\varphi_1, \dots, \varphi_M\}^\perp} \underbrace{(\varphi_{\bar{\beta}} - \varphi_{\hat{\beta}^{\text{LS}}})}_{\in \text{span}\{\varphi_1, \dots, \varphi_M\}} + |\varphi_{\bar{\beta}} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 \\ &= |\mathbf{f} - \varphi_{\bar{\beta}}|_{2,n}^2 + |\varphi_{\bar{\beta}} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 \end{aligned}$$

から

$$|\mathbf{f} - \varphi_{\hat{\beta}^{\text{LS}}}|_{2,n}^2 - |\mathbf{f} - \varphi_{\bar{\beta}}|_{2,n}^2 = |\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}|_{2,n}^2 \quad (4.6)$$

がわかる. (4.5) と (4.6) を合わせると

$$|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}|_{2,n}^2 \leq 2\epsilon^\top (\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}) = 2|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}|_{2,n} \cdot \frac{\epsilon^\top (\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}})}{|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}|_{2,n}}$$

いま, $\Psi \in \mathbb{R}^{n \times M}$ を

$$\begin{bmatrix} \varphi_1(\mathbf{X}_1) \\ \varphi_1(\mathbf{X}_2) \\ \vdots \\ \varphi_1(\mathbf{X}_n) \end{bmatrix}, \begin{bmatrix} \varphi_2(\mathbf{X}_1) \\ \varphi_2(\mathbf{X}_2) \\ \vdots \\ \varphi_2(\mathbf{X}_n) \end{bmatrix}, \dots, \begin{bmatrix} \varphi_M(\mathbf{X}_1) \\ \varphi_M(\mathbf{X}_2) \\ \vdots \\ \varphi_M(\mathbf{X}_n) \end{bmatrix}$$

の張る線型部分空間の正規直交基底とする. すると, $\nu \in \mathbb{R}^M$ が存在して,

$$\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}} = \Phi \nu$$

と書ける. よって

$$\frac{\epsilon^\top (\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}})}{|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}|_{2,n}} = \frac{\epsilon^\top \Phi \nu}{|\Phi \nu|_{2,n}} = \frac{\epsilon^\top \Phi \nu}{|\nu|_{2,M}} = \tilde{\epsilon}^\top \frac{\nu}{|\nu|_{2,M}} \leq \sup_{\mu \in B_2} \tilde{\epsilon}^\top \mu.$$

ただし, $B_2 := \{\mu \in \mathbb{R}^M; |\mu|_{2,M} = 1\}$ は \mathbb{R}^M の単位球で, $\tilde{\epsilon} = \Phi^\top \epsilon$ である. したがって

$$|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\bar{\beta}}|_2^2 \leq 4 \sup_{\mu \in B_2} (\tilde{\epsilon}^\top \mu)^2. \quad (4.7)$$

次に, Φ の列は正規直交基底なので, $v \in \mathbb{S}^{M-1}$ に対して

$$|\Phi v|_{2,n}^2 = v^\top \underbrace{\Phi^\top \Phi}_{=I_M} v = v^\top v = 1$$

となることがわかる. よって, $\epsilon \sim \text{subG}_n(\sigma^2)$ から, $\forall s \in \mathbb{R}$ に対して,

$$\mathbb{E}[\exp\{s \tilde{\epsilon}^\top v\}] = \mathbb{E}[\exp\{s(\Phi v)^\top \epsilon\}] \leq \exp\left\{\frac{s^2}{2} \sigma^2\right\}$$

がわかる. したがって, $\tilde{\epsilon} \sim \text{subG}_M(\sigma^2)$ となる. 期待値の上限を得るために, 補題 2.10 から

$$\tilde{\epsilon}_j \sim \text{subG}(\sigma^2) \Rightarrow \Pr(\tilde{\epsilon}_j > t) \leq \exp\left(-\frac{t^2}{2\sigma^2}\right)$$

がわかる. さらに, 2.11 から

$$\Pr(\tilde{\epsilon}_j > t) \leq \exp\left(-\frac{t^2}{2\sigma^2}\right) \Rightarrow \mathbb{E}[\tilde{\epsilon}_j^2] \leq 2\sigma^2 \times 2 \times \Gamma(1) = 4\sigma^2$$

がわかる. よって

$$4\mathbb{E}\left[\sup_{\mu \in B_2} (\tilde{\epsilon}^\top \mu)^2\right] = 4 \sum_{j=1}^M \mathbb{E}[\tilde{\epsilon}_j^2] \leq 16\sigma^2 M$$

を得る. ただし, $\tilde{\epsilon} = (\tilde{\epsilon}_1, \tilde{\epsilon}_2, \dots, \tilde{\epsilon}_M)$ である. さらに, $\tilde{\epsilon} \sim \text{subG}_M(\sigma^2)$ に注意して, (2.5) の議論を繰り返すと

$$\Pr\left(\sup_{\mu \in B_2} (\tilde{\epsilon}^\top \mu)^2 > t^2\right) = \Pr\left(\sup_{\mu \in B_2} \tilde{\epsilon}^\top \mu > t\right) \leq 6^M \exp\left(-\frac{t^2}{8\sigma^2}\right)$$

となるので

$$1 - 6^M \exp\left(-\frac{t^2}{8\sigma^2}\right) \leq \Pr\left(\sup_{\mu \in B_2} (\tilde{\epsilon}^\top \mu)^2 \leq t^2\right)$$

となる. すると $t > 0$ を以下の不等式を満たすように定めると

$$6^M \exp\left(-\frac{t^2}{8\sigma^2}\right) \leq \delta \Leftrightarrow t^2 \geq 8\sigma^2 M \log 6 + 8\sigma^2 \log\left(\frac{1}{\delta}\right)$$

となる. $\sqrt{8 \log 6} < 4$ なので

$$t := 4\sigma\sqrt{M} + 2\sigma\sqrt{2 \log\left(\frac{1}{\delta}\right)}$$

とおけば

$$t^2 \geq 8\sigma^2 M \log 6 + 8\sigma^2 \log\left(\frac{1}{\delta}\right)$$

となる. したがって

$$\begin{aligned} & \Pr\left(\sup_{\boldsymbol{\mu} \in B_2} (\boldsymbol{\mu}^\top \tilde{\boldsymbol{\epsilon}})^2 > 8\sigma^2 M \log 6 + 8\sigma^2 \log\left(\frac{1}{\delta}\right)\right) \\ & \leq \Pr\left(\sup_{\boldsymbol{\mu} \in B_2} (\boldsymbol{\mu}^\top \tilde{\boldsymbol{\epsilon}})^2 > t^2\right) \\ & \leq 6^M \exp\left(-\frac{t^2}{8\sigma^2}\right) \\ & \leq \exp\left(-\frac{t^2}{8\sigma^2} + M \log 6\right) \\ & \leq \delta \end{aligned}$$

から

$$\Pr\left(\sup_{\boldsymbol{\mu} \in B_2} (\tilde{\boldsymbol{\epsilon}}^\top \boldsymbol{\mu})^2 \leq 8 \log(6) \sigma^2 M + 8\sigma^2 \log\left(\frac{1}{\delta}\right)\right) \geq 1 - \delta$$

がわかる. ここで

$$\sup_{\boldsymbol{\mu} \in B_2} (\tilde{\boldsymbol{\epsilon}}^\top \boldsymbol{\mu})^2 \geq \frac{1}{4} |\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{LS}}} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 = \frac{1}{4} \left\{ |\mathbf{f} - \boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{LS}}}|_{2,n}^2 - |\mathbf{f} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 \right\}$$

を思い出すと

$$\begin{aligned} & \Pr\left(\frac{1}{4} \left\{ |\mathbf{f} - \boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{LS}}}|_{2,n}^2 - |\mathbf{f} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 \right\} \leq 8 \log(6) \sigma^2 M + 8\sigma^2 \log\left(\frac{1}{\delta}\right)\right) \\ & \geq \Pr\left(\sup_{\boldsymbol{\mu} \in B_2} (\tilde{\boldsymbol{\epsilon}}^\top \boldsymbol{\mu})^2 \leq 8 \log(6) \sigma^2 M + 8\sigma^2 \log\left(\frac{1}{\delta}\right)\right) \\ & \geq 1 - \delta \end{aligned}$$

がわかる. 上式を整理すると

$$\begin{aligned} & \Pr\left(\frac{1}{n} |\mathbf{f} - \boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{LS}}}|_{2,n}^2 \leq \frac{1}{n} |\mathbf{f} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 + \frac{32\sigma^2 \{M \log 6 + \log(\delta^{-1})\}}{n}\right) \\ & \geq 1 - \delta \end{aligned}$$

を得る. よって, 定理は証明された. \square

4.1.2 BIC 推定量のスパース・オラクル不等式

定理 4.4. 回帰モデル (4.1) と $\epsilon \sim \text{subG}_n(\sigma^2)$ ($\sigma > 0$) を仮定する. このとき, 調整パラメータ

$$\tau^2 = 32 \log(12) \frac{\sigma^2}{n} + 32 \frac{\sigma^2 \log(Me)}{n} \quad (4.8)$$

をもつ BIC 推定量 $\hat{\beta}^{\text{BIC}}$ は次をみたす. $\forall \delta > 0$ とする. ある定数 $C > 0$ が存在して,

$$\Pr \left(\text{MSE}(\varphi_{\hat{\beta}^{\text{BIC}}}) \leq \inf_{\beta \in \mathbb{R}^M} \left\{ 3\text{MSE}(\varphi_{\beta}) + \frac{C\sigma^2}{n} |\beta|_{0,M} \log(eM) \right\} + \frac{C\sigma^2}{n} \log \left(\frac{1}{\delta} \right) \right) \geq 1 - \delta$$

が成立する. ただし, $\hat{\beta}^{\text{BIC}}$ は (4.4) で与えられ

$$\begin{aligned} \varphi_{\hat{\beta}^{\text{BIC}}} &= (\varphi_{\hat{\beta}^{\text{BIC}}}(\mathbf{X}_1), \varphi_{\hat{\beta}^{\text{BIC}}}(\mathbf{X}_2), \dots, \varphi_{\hat{\beta}^{\text{BIC}}}(\mathbf{X}_n))^{\top} \in \mathbb{R}^n, \\ \varphi_{\hat{\beta}^{\text{BIC}}}(\mathbf{x}) &= \sum_{j=1}^M \hat{\beta}_j^{\text{BIC}} \varphi_j(\mathbf{x}); \quad \hat{\beta}^{\text{BIC}} = (\hat{\beta}_1^{\text{BIC}}, \hat{\beta}_2^{\text{BIC}}, \dots, \hat{\beta}_M^{\text{BIC}})^{\top} \in \mathbb{R}^M \end{aligned}$$

である.

Proof. BIC 推定量の定義より

$$\frac{1}{n} |\mathbf{Y} - \varphi_{\hat{\beta}^{\text{BIC}}}|_{2,n}^2 + \tau^2 |\hat{\beta}^{\text{BIC}}|_{0,M} \leq \frac{1}{n} |\mathbf{Y} - \varphi_{\beta}|_{2,n}^2 + \tau^2 |\beta|_{0,M}$$

が成立することに注意する. これより

$$\begin{aligned} |\mathbf{f} - \varphi_{\hat{\beta}^{\text{BIC}}}|_{2,n}^2 + n\tau^2 |\hat{\beta}^{\text{BIC}}|_{0,M} &\leq |\mathbf{f} - \varphi_{\beta}|_{2,n}^2 + 2\epsilon^{\top} (\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}) \\ &\quad + n\tau^2 |\beta|_{0,M} \end{aligned} \quad (4.9)$$

を得る. $\hat{\beta}^{\text{BIC}} = \beta$ のとき, 主張は自明なので, $\hat{\beta}^{\text{BIC}} \neq \beta$ と仮定する. このとき, $\alpha > 0$ に対して

$$2\epsilon^{\top} (\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}) \quad (4.10)$$

$$\begin{aligned} &= 2\epsilon^{\top} \left(\frac{\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}} \right) (|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}) \\ &\leq \frac{2}{\alpha} \left[\epsilon^{\top} \left(\frac{\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}} \right) \right]^2 + \frac{\alpha}{2} |\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 \end{aligned} \quad (4.11)$$

が成立する. これは Young の不等式

$$2ab \leq \frac{2}{\alpha}a^2 + \frac{\alpha}{2}b^2 \quad (\forall a, b \in \mathbb{R}; \alpha > 0)$$

よりわかる. 次に, $(a+b)^2 \leq 2a^2 + 2b^2$ ($a, b \in \mathbb{R}$) から

$$\frac{1}{4}|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 \leq \frac{1}{2}|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 + \frac{1}{2}|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 \quad (4.12)$$

となることに注意する. (4.9) に (4.11) を代入し, さらに (4.12) を用いると

$$\begin{aligned} |\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 &\leq |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 2\epsilon^\top \frac{(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}} \\ &\leq |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 4\left[\epsilon^\top \frac{(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}}\right]^2 + \frac{1}{4}|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 \\ &\leq \frac{3}{2}|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 4\left[\epsilon^\top \frac{(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}}\right]^2 + \frac{1}{2}|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 \\ &\leq \frac{3}{2}|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + 2n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}} - \beta|_{0,M} \\ &\quad + 4\left[\epsilon^\top \frac{(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}}\right]^2 + \frac{1}{2}|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 \end{aligned}$$

を得る. これを整理すれば

$$\begin{aligned} |\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 &\leq 3|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + 4n\tau^2|\beta|_{0,M} - 2n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 8\left[\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})\right]^2 \end{aligned} \quad (4.13)$$

を得る. ただし, $\mathcal{U}(z) = z/|z|_{2,n}$ である. $S \subset \{1, 2, \dots, M\}$ に対して

$$\Phi_{r_{S,*}} = [\phi_1, \phi_2, \dots, \phi_{r_{S,*}}]$$

を集合 $\{\varphi_j(\mathbf{x}); j \in S \cup \text{supp}(\beta)\}$ の張る線型部分空間の正規直交基底とする. ただし

$$\varphi_j(\mathbf{x}) = (\varphi_j(\mathbf{X}_1), \varphi_j(\mathbf{X}_2), \dots, \varphi_j(\mathbf{X}_n))^\top; \quad (j = 1, 2, \dots, M)$$

で, $r_{S,*} \leq \#(S) + |\beta|_{0,M}$ である. このとき

$$\begin{aligned} &4\left[\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})\right]^2 - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &= \max_{1 \leq k \leq M} \left\{ \max_{\#(S)=k} \left\{ \sup_{\text{supp}(\hat{\beta})=S} \left\{ 4\left[\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}} - \varphi_{\beta})\right]^4 - n\tau^2k \right\} \right\} \right\} \end{aligned}$$

となる. よって, $\forall t > 0$ に対して

$$\begin{aligned} & \Pr \left(\max_{\#(S)=k} \left\{ \max_{\#(S)=k} \left\{ 4 \sup_{\text{supp}(\hat{\beta})=S} [\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}} - \varphi_{\beta})]^4 - n\tau^2 k \right\} \right\} > \frac{t}{2} \right) \\ & \leq \sum_{k=1}^M \sum_{\#(S)=k} \Pr \left(\sup_{\mathbf{u} \in \mathbb{B}_{r_{S,*}}} [\epsilon^\top \Phi_{r_{S,*}} \mathbf{u}]^2 > \frac{t}{8} + \frac{1}{4} n\tau^2 k \right) \end{aligned}$$

がわかる. 次に, 定理 2.30 の ϵ 網論法を用いれば

$$\begin{aligned} & \Pr \left(\sup_{\mathbf{u} \in \mathbb{B}_{r_{S,*}}} [\epsilon^\top \Phi_{r_{S,*}} \mathbf{u}]^2 > \frac{t}{8} + \frac{1}{4} n\tau^2 k \right) \\ & \leq 2 \cdot 6^{r_{S,*}} \exp \left(-\frac{\frac{t}{8} + \frac{1}{4} n\tau^2 k}{8\sigma^2} \right) \\ & \leq 2 \exp \left(-\frac{t}{64\sigma^2} - \frac{n\tau^2 k}{32\sigma^2} + (k + |\beta|_0) \log 6 \right) \\ & = 2 \exp \left(-\frac{t}{64\sigma^2} - k \log 6 - k \log(eM) + (k + |\beta|_0) \log 6 \right) \\ & = \exp \left(\log 2 - \frac{t}{64\sigma^2} - k \log(eM) + |\beta|_{0,M} \log 6 \right) \\ & \leq \exp \left(-\frac{t}{64\sigma^2} - k \log(eM) + |\beta|_{0,M} \log(12) \right) \end{aligned}$$

がわかる. さらに, (4.13) より

$$|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 > 3|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + 2n\tau^2 |\beta|_{0,M} + t$$

ならば

$$4[\epsilon^\top (\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})]^2 - n\tau^2 |\hat{\beta}^{\text{BIC}}|_{0,M} \geq \frac{t}{2}$$

である. したがって

$$\begin{aligned} & \Pr \left(|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 > 2n\tau^2 |\beta|_{0,M} + t + 3|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 \right) \\ & \leq \Pr \left(4[\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})]^2 - n\tau^2 |\hat{\beta}^{\text{BIC}}|_{0,M} \geq \frac{t}{2} \right) \\ & \leq \sum_{k=1}^M \sum_{\#(S)=k} \exp \left(-\frac{t}{64\sigma^2} - k \log(eM) + |\beta|_{0,M} \log(12) \right) \\ & \leq \sum_{k=1}^M \left(\frac{eM}{k} \right)^k \exp \left(-\frac{t}{64\sigma^2} - k \log(eM) + |\beta|_{0,M} \log(12) \right) \\ & \quad (\because \text{補題 3.10 より}) \\ & \leq \exp \left(-\frac{t}{64\sigma^2} + |\beta|_{0,M} \log(12) \right) \end{aligned}$$

を得る. ここで

$$t := 64\sigma^2|\boldsymbol{\beta}|_{0,M} \log(12) + 64\sigma^2 \log\left(\frac{1}{\delta}\right)$$

と取れば

$$\begin{aligned} & \Pr\left(|\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \boldsymbol{f}|_{2,n}^2 > 2n\tau^2|\boldsymbol{\beta}|_{0,M} + 64\sigma^2|\boldsymbol{\beta}|_{0,M} \log(12) + 64\sigma^2 \log\left(\frac{1}{\delta}\right) \right. \\ & \quad \left. + 3|\boldsymbol{\varphi}_{\boldsymbol{\beta}} - \boldsymbol{f}|_{2,n}^2\right) \\ & \leq \Pr\left(|\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \boldsymbol{f}|_{2,n}^2 > 64\sigma^2|\boldsymbol{\beta}|_{0,M} \{\log(6) + \log(Me)\} \right. \\ & \quad \left. + 64\sigma^2 \log\left(\frac{1}{\delta}\right) + 3|\boldsymbol{\varphi}_{\boldsymbol{\beta}} - \boldsymbol{f}|_{2,n}^2\right) \\ & \leq \delta \end{aligned}$$

を得る. よって

$$\begin{aligned} 1 - \delta & \leq \Pr\left(\frac{1}{n}|\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 \leq 3\text{MSE}(\boldsymbol{\varphi}_{\boldsymbol{\beta}}) + |\boldsymbol{\beta}|_{0,M} \frac{C\sigma^2}{n} \log(eM) \right. \\ & \quad \left. + \frac{C\sigma^2}{n} \log\left(\frac{1}{\delta}\right)\right) \end{aligned}$$

より

$$\begin{aligned} & \Pr\left(\text{MSE}(\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}}) \leq \inf_{\boldsymbol{\beta} \in \mathbb{R}^M} \left\{ 3\text{MSE}(\boldsymbol{\varphi}_{\boldsymbol{\beta}}) + |\boldsymbol{\beta}|_{0,M} \frac{C\sigma^2}{n} \log(eM) \right\} \right. \\ & \quad \left. + \frac{C\sigma^2}{n} \log\left(\frac{1}{\delta}\right)\right) \geq 1 - \delta \end{aligned}$$

を得る. □

注意 4.5. BIC 推定量は関数空間の近似誤差と母数 $\boldsymbol{\beta}$ の複雑さのトレード・オフを一番うまく行っている. このことをスパース・オラクル不等式ということもある. いま, $\bar{\boldsymbol{\beta}} \in \mathbb{R}^M$ を

$$\text{MSE}(\boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}) = \inf_{\boldsymbol{\beta} \in \mathbb{R}^M} \text{MSE}(\boldsymbol{\varphi}_{\boldsymbol{\beta}})$$

をみたまものとする. このとき, $\forall \delta > 0$ に対して

$$\begin{aligned} & \Pr\left(\text{MSE}(\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}}) \leq 3\text{MSE}(\boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}) + \frac{C\sigma^2}{n} \left\{ |\bar{\boldsymbol{\beta}}|_0 \log(eM) + \log\left(\frac{1}{\delta}\right) \right\} \right) \\ & \geq 1 - \delta \end{aligned}$$

が成り立つ. 真のモデルが線型性をもてば,

$$\text{MSE}(\boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}) = 0$$

である. □

4.1.3 LASSO に対するスパースオラクル不等式

LASSO に対するオラクル不等式を証明するために, incoherence 条件のようなデザイン行列に対する仮定が必要になってくる. $n \times M$ のデザイン行列 Ψ の (i, j) 要素と第 j 列を以下のように書く. すなわち

$$\begin{aligned}\Psi_{ij} &= \varphi_j(\mathbf{X}_i) \quad (i = 1, 2, \dots, n; j = 1, 2, \dots, M) \\ \varphi_j &= (\varphi_j(\mathbf{X}_1), \varphi_j(\mathbf{X}_2), \dots, \varphi_j(\mathbf{X}_n))^\top\end{aligned}$$

である.

定理 4.6. 一般の回帰モデル (4.1) を仮定し, $\epsilon \sim \text{subG}_n(\sigma^2)$ ($\sigma > 0$) とする. さらに, ある正の整数 k があって, デザイン行列 Ψ は, $\text{INC}(k)$ 条件をみたすとする. このとき, 調整パラメータ τ は, $\delta > 0$ としたとき,

$$2\tau := 8\sigma\sqrt{\frac{2\log(2M)}{n}} + 8\sigma\sqrt{\frac{2\log(1/\delta)}{n}}$$

で与えられる LASSO 推定量 $\hat{\beta}^\mathcal{L}$ は次をみたす. $\forall \delta > 0$ とある定数 (a generic constant) があって

$$\Pr\left(\text{MSE}(\varphi_{\hat{\beta}^\mathcal{L}}) \leq \inf_{\beta \in \mathbb{R}^M; |\beta|_0 \leq k} \left\{ \text{MSE}(\varphi_\beta) + \frac{C\sigma^2}{n} |\beta|_{0,M} \log\left(\frac{2M}{\delta}\right) \right\}\right) \geq 1 - \delta$$

が成り立つ. ただし, $\hat{\beta}^\mathcal{L}$ は (??) で与えられ

$$\begin{aligned}\varphi_{\hat{\beta}^\mathcal{L}} &= (\varphi_{\hat{\beta}^\mathcal{L}}(\mathbf{X}_1), \varphi_{\hat{\beta}^\mathcal{L}}(\mathbf{X}_2), \dots, \varphi_{\hat{\beta}^\mathcal{L}}(\mathbf{X}_n))^\top \in \mathbb{R}^n, \\ \varphi_{\hat{\beta}^\mathcal{L}}(\mathbf{x}) &= \sum_{j=1}^M \hat{\beta}_j^\mathcal{L} \varphi_j(\mathbf{x}); \quad \hat{\beta}^\mathcal{L} = (\hat{\beta}_1^\mathcal{L}, \hat{\beta}_2^\mathcal{L}, \dots, \hat{\beta}_M^\mathcal{L})^\top \in \mathbb{R}^M\end{aligned}$$

である.

Proof. LASSO 推定量 $\hat{\beta}^\mathcal{L}$ の定義より

$$\frac{1}{n} |\mathbf{Y} - \varphi_{\hat{\beta}^\mathcal{L}}|_{2,n}^2 \leq \frac{1}{n} |\mathbf{Y} - \varphi_\beta|_{2,n}^2 + 2\tau |\beta|_{1,M} - 2\tau |\hat{\beta}^\mathcal{L}|_{1,M} \quad (4.14)$$

が成立する. 2 次式の項を展開する.

$$\begin{aligned}|\mathbf{Y} - \varphi_{\hat{\beta}^\mathcal{L}}|_{2,n}^2 &= |\mathbf{Y} - \mathbf{f}|_{2,n}^2 + |\mathbf{f} - \varphi_{\hat{\beta}^\mathcal{L}}|_{2,n}^2 - 2\epsilon^\top (\varphi_{\hat{\beta}^\mathcal{L}} - \mathbf{f}) \\ |\mathbf{Y} - \varphi_\beta|_{2,n}^2 &= |\mathbf{Y} - \mathbf{f}|_{2,n}^2 + |\mathbf{f} - \varphi_\beta|_{2,n}^2 - 2\epsilon^\top (\varphi_\beta - \mathbf{f})\end{aligned}$$

となる. これらの式を (4.14) に代入して, 両辺に $\tau |\hat{\beta}^\mathcal{L} - \beta|_{1,M}$ を加えて, n 倍すれば

$$\begin{aligned}|\varphi_{\hat{\beta}^\mathcal{L}} - \mathbf{f}|_{2,n}^2 - |\varphi_\beta - \mathbf{f}|_{2,n}^2 + n\tau |\hat{\beta}^\mathcal{L} - \beta|_{1,M} \\ \leq 2\epsilon^\top (\varphi_{\hat{\beta}^\mathcal{L}} - \varphi_\beta) + n\tau |\hat{\beta}^\mathcal{L} - \beta|_{1,M} + 2n\tau |\beta|_{1,M} - 2n\tau |\hat{\beta}^\mathcal{L}|_{1,M}\end{aligned} \quad (4.15)$$

を得る. 任意の $k \geq 1$ に対する $\text{INC}(k)$ 条件より

$$|\varphi_j|_{2,n} \leq \sqrt{2n} \leq 2\sqrt{n} \quad (j = 1, 2, \dots, M)$$

が成立することに注意する. このことより,

$$\varphi_j^\top \epsilon \sim \text{subG}(4n\sigma^2) \quad (4.16)$$

がわかる. 次に, $\varphi_{\hat{\beta}^\mathcal{L}} = \Psi^\top \hat{\beta}^\mathcal{L}$ に注意して, Hölder の不等式を用いると

$$|\epsilon^\top (\varphi_{\hat{\beta}^\mathcal{L}} - \varphi_\beta)| \leq |\Psi^\top \epsilon|_\infty \cdot |\hat{\beta}^\mathcal{L} - \beta|_{1,M} \quad (4.17)$$

を得る. (4.16) と (4.17) を踏まえて, 補題 2.16 を用いると

$$\Pr\left(\max_{1 \leq j \leq M} |\varphi_j^\top \epsilon| > t\right) \leq 2M \exp\left(-\frac{t^2}{8n\sigma^2}\right)$$

を得る. よって

$$\begin{aligned} & \Pr\left(2\epsilon^\top (\varphi_{\hat{\beta}^\mathcal{L}} - \varphi_\beta) > \frac{n\tau}{2} |\hat{\beta}^\mathcal{L} - \beta|_{1,M}\right) \\ & \leq \Pr\left(2|\epsilon^\top (\varphi_{\hat{\beta}^\mathcal{L}} - \varphi_\beta)| > \frac{n\tau}{2} |\hat{\beta}^\mathcal{L} - \beta|_{1,M}\right) \\ & \leq \Pr\left(|\Psi^\top \epsilon|_\infty > \frac{n\tau}{4}\right) \\ & = \Pr\left(\max_{1 \leq j \leq M} |\varphi_j^\top \epsilon| > \frac{n\tau}{4}\right) \\ & \leq 2M \exp\left(-\frac{n\tau^2}{64\sigma^2}\right) \end{aligned}$$

を得る. したがって, $S = \text{supp}(\beta)$ とおけば

$$2\epsilon^\top (\varphi_{\hat{\beta}^\mathcal{L}} - \varphi_\beta) \leq \frac{n\tau}{2} |\hat{\beta}^\mathcal{L} - \beta|_{1,M}$$

のとき, 以下のような (4.15) の右辺の上限を得る.

$$\begin{aligned} & 2\epsilon^\top (\varphi_{\hat{\beta}^\mathcal{L}} - \varphi_\beta) + n\tau |\hat{\beta}^\mathcal{L} - \beta|_{1,M} + 2n\tau |\beta|_{1,M} - 2n\tau |\hat{\beta}^\mathcal{L}|_{1,M} \\ & \leq 2n\tau |\hat{\beta}^\mathcal{L} - \beta|_1 + 2n\tau |\beta|_{1,M} - 2n\tau |\hat{\beta}^\mathcal{L}|_{1,M} \\ & \leq 2n\tau |\hat{\beta}_S^\mathcal{L} - \beta_S|_{1,M} + 2n\tau |\hat{\beta}_{S^c}^\mathcal{L}|_{1,M} + 2n\tau |\beta_S|_{1,M} + 2n\tau |\beta_{S^c}|_{1,M} \\ & \quad - 2n\tau |\hat{\beta}_S^\mathcal{L}|_{1,M} - 2n\tau |\hat{\beta}_{S^c}^\mathcal{L}|_{1,M} \\ & \leq 2n\tau |\hat{\beta}_S^\mathcal{L} - \beta|_{1,M} + 2n\tau |\beta_S|_1 + 2n\tau |\beta_{S^c}|_{1,M} - 2n\tau |\hat{\beta}_S^\mathcal{L}|_{1,M} \\ & \leq 4n\tau |\hat{\beta}_S^\mathcal{L} - \beta_S|_{1,M} \\ & = 4n\tau |\hat{\beta}_S^\mathcal{L} - \beta_S|_{1,M}. \end{aligned}$$

したがって

$$\begin{aligned}
& \Pr\left(|\varphi_{\hat{\beta}^{\mathcal{L}}} - \mathbf{f}|_{2,n}^2 - |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau|\hat{\beta}^{\mathcal{L}} - \beta|_{1,M} \leq 4n\tau|\hat{\beta}_S^{\mathcal{L}} - \beta|_{1,M}\right) \\
& \geq \Pr\left(2|\epsilon^\top(\varphi_{\hat{\beta}^{\mathcal{L}}} - \varphi_{\beta})| \leq \frac{n\tau}{2}\right) \\
& \geq \Pr\left(\max_{1 \leq j \leq M} |\varphi_j^\top \epsilon| \leq \frac{n\tau}{4}\right) \\
& \geq 1 - 2M \exp\left(-\frac{n\tau^2}{64\sigma^2}\right) \tag{4.18}
\end{aligned}$$

となる. ここで

$$\begin{aligned}
|\hat{\beta}_{SC}^{\mathcal{L}} - \beta_{SC}|_{1,M} & \geq 3|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} \\
& \Leftrightarrow 0 \leq 3|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} - |\hat{\beta}_{SC}^{\mathcal{L}} - \beta_{SC}|_{1,M} \\
& = 4|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} - |\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} - |\hat{\beta}_{SC}^{\mathcal{L}} - \beta_{SC}|_{1,M} \\
& \leq 4|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} - |\hat{\beta}^{\mathcal{L}} - \beta|_{1,M}
\end{aligned}$$

となることから

$$\begin{aligned}
|\hat{\beta}_{SC}^{\mathcal{L}} - \beta_{SC}|_{1,M} & \geq 3|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} \\
& \Leftrightarrow 4|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} - |\hat{\beta}^{\mathcal{L}} - \beta|_{1,M} \tag{4.19}
\end{aligned}$$

がわかる. したがって

$$|\varphi_{\hat{\beta}^{\mathcal{L}}} - \mathbf{f}|_{2,n}^2 - |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau|\hat{\beta}^{\mathcal{L}} - \beta|_{1,M} \leq 4n\tau|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} \tag{4.20}$$

が起きたとき (4.19) から

$$|\hat{\beta}_{SC}^{\mathcal{L}} - \beta_{SC}|_{1,M} \geq 3|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} \Rightarrow \text{MSE}(\varphi_{\hat{\beta}^{\mathcal{L}}}) \leq \text{MSE}(\varphi_{\beta})$$

が成立する. これは, (4.20) が起きれば

$$\text{MSE}(\varphi_{\hat{\beta}^{\mathcal{L}}}) \leq \text{MSE}(\varphi_{\beta}) \tag{4.21}$$

または

$$|\hat{\beta}_{SC}^{\mathcal{L}} - \beta_{SC}|_{1,M} < 3|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} \tag{4.22}$$

のいずれかが起きることがわかる. よって, (4.20) と (4.19) が起これば

$$\text{MSE}(\varphi_{\hat{\beta}^{\mathcal{L}}}) \leq \inf_{\beta \in \mathbb{R}^M; |\beta|_0 \leq k} \left\{ \text{MSE}(\varphi_{\beta}) + \frac{C\sigma^2}{n} |\beta|_{0,M} \log\left(\frac{2M}{\delta}\right) \right\} \tag{4.23}$$

が明らかに成り立つので, (4.22) が起こったときに, (4.23) が成り立つことを示せばよい. そのために, $\tilde{\beta} := \hat{\beta}^{\mathcal{L}} - \beta$ に対して, 凸条件 (3.22)

をみたすことを用いる. Cauchy-Schwarz の不等式と補題 3.24 ($X\beta$ を $\varphi_{\hat{\beta}^{\mathcal{L}}} - \varphi_{\beta} = \Psi^{\top}(\hat{\beta}^{\mathcal{L}} - \beta)$ と読み替える) より

$$\begin{aligned} 4n\tau|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} &\leq 4n\tau\sqrt{\#(S)}|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{2,M} \\ &\leq 4n\tau\sqrt{\#(S)}|\hat{\beta}^{\mathcal{L}} - \beta|_{2,M} \\ &\leq 4n\tau\sqrt{\#(S)}\sqrt{\frac{2}{n}}|\varphi_{\hat{\beta}^{\mathcal{L}}} - \varphi_{\beta}|_{2,n} \\ &= 4\tau\sqrt{2n\#(S)}|\varphi_{\hat{\beta}^{\mathcal{L}}} - \varphi_{\beta}|_{2,n} \end{aligned}$$

を得る. ここで, Young の不等式

$$2ab \leq \frac{2}{\alpha}a^2 + \frac{\alpha}{2}b^2 \quad (a, b \in \mathbb{R}, \alpha > 0)$$

を用いると

$$\begin{aligned} 4n\tau|\hat{\beta}_S^{\mathcal{L}} - \beta|_{1,M} &\leq \frac{16\tau^2n|\beta|_{0,M}}{\alpha} + \frac{\alpha}{2}|\varphi_{\hat{\beta}^{\mathcal{L}}} - \varphi_{\beta}|_{2,n}^2 \\ &\leq \frac{16\tau^2n|\beta|_{0,M}}{\alpha} + \alpha|\varphi_{\hat{\beta}^{\mathcal{L}}} - \mathbf{f}|_{2,n}^2 + \alpha|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 \end{aligned}$$

を得る. この式と (4.15), (4.20) を合わせると

$$\begin{aligned} |\varphi_{\hat{\beta}^{\mathcal{L}}} - \mathbf{f}|_{2,n}^2 + |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 &\leq |\varphi_{\hat{\beta}^{\mathcal{L}}} - \mathbf{f}|_{2,n}^2 + |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau|\hat{\beta}^{\mathcal{L}} - \beta|_{1,M} \\ &\leq 4n\tau|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M} \\ &\leq \frac{16\tau^2n|\beta|_0}{\alpha} + \alpha|\varphi_{\hat{\beta}^{\mathcal{L}}} - \mathbf{f}|_{2,n}^2 + \alpha|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 \end{aligned}$$

を得る. この式を整理して, 辺々を n で割ると

$$(1 - \alpha)\text{MSE}(\varphi_{\hat{\beta}^{\mathcal{L}}}) \leq (1 + \alpha)\text{MSE}(\varphi_{\beta}) + \frac{16\tau^2|\beta|_{0,M}}{\alpha}$$

を得る. この式の両辺を $1 - \alpha$ で割り, $\alpha = 1/2$ とすれば

$$\text{MSE}(\varphi_{\hat{\beta}^{\mathcal{L}}}) \leq 3\text{MSE}(\varphi_{\beta}) + 32\tau^2|\beta|_{0,M}$$

を得る. 以上の議論を踏まえると

$$\begin{aligned} &1 - 2M \exp\left(-\frac{n\tau^2}{64\sigma^2}\right) \\ &< \Pr\left(|\varphi_{\hat{\beta}^{\mathcal{L}}} - \mathbf{f}|_{2,n}^2 - |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau|\hat{\beta}^{\mathcal{L}} - \beta|_{1,M} \leq 4n\tau|\hat{\beta}_S^{\mathcal{L}} - \beta_S|_{1,M}\right) \\ &\leq \Pr\left(\text{MSE}(\varphi_{\hat{\beta}^{\mathcal{L}}}) \leq 3\text{MSE}(\varphi_{\beta}) + 32\tau^2|\beta|_{0,M}\right) \\ &= \Pr\left(\text{MSE}(\varphi_{\hat{\beta}^{\mathcal{L}}}) \leq 3\text{MSE}(\varphi_{\beta}) + 128\frac{\sigma^2}{n}|\beta|_{0,M} \log\left(\frac{2M}{\delta}\right)\right) \end{aligned}$$

を得る. 最後に

$$\begin{aligned} \frac{n\tau^2}{64\sigma^2} &= \frac{n}{256\sigma^2} \left\{ 8\sigma \sqrt{\frac{2\log(2M)}{n}} + 8\sigma \sqrt{\frac{2\log(1/\delta)}{n}} \right\}^2 \\ &\leq \frac{n}{256\sigma^2} \left\{ 2 \times 64\sigma^2 \frac{2\log(2M)}{n} + 2 \times 64\sigma^2 \frac{2\log(1/\delta)}{n} \right\} \\ &= \log(2M) + \log\left(\frac{1}{\delta}\right) \end{aligned}$$

に注意すれば

$$\begin{aligned} 1 - 2M \exp\left(-\frac{n\tau^2}{64\sigma^2}\right) &= 1 - \exp\left(\log(2M) - \frac{n\tau^2}{64\sigma^2}\right) \\ &\geq 1 - \exp\left(-\log\left(\frac{1}{\delta}\right)\right) \\ &\geq 1 - \delta \end{aligned}$$

がわかり, 定理は証明された. □

4.1.4 Maurey の論法

$\text{MSE}(\varphi_\beta)$ が小さくなるようなスパース性を持つベクトル β はあるのだろうか? LASSO 推定量の収束のスピードは遅ければ, 定理 4.6 の主張は役に立たない. 現実では, スパースベクトル β の存在など確証を持ってない. むしろ, Zip の法則から期待できることは, β の要素の絶対値を取ったものを降順に並べたときに, 多項式のオーダーで減衰していくことである. そのような β に対しても, 定理 3.20 にある遅い収束レートの結果を誤特定の設定へ拡張できる. incoherence 条件が成立しているとき, LASSO 推定量は BIC 推定量よりも好ましい. なぜならば, LASSO 推定量は遅く収束レートであるが, BIC 推定量は早い収束レートである.

多項式のスピードで減衰するベクトル β は, 次 n 意味で, スパースベクトルで近似できる. 任意のベクトル $\beta \in \mathbb{R}^M$ で, $|\beta|_1 \leq 1$ なるものに対して, あるスパースベクトル $\beta' \in \mathbb{R}^M$ が存在して, $\text{MSE}(\varphi_{\beta'})$ は $\text{MSE}(\varphi_\beta)$ よりあまり大きくならないようにできる. 次の命題は, スパース性と MSE のトレード・オフを表現する主張である. これは, Maurey 論法と言われるが, Pisier (1981) によって知られるようになったが, 慣例に従い Maurey 論法ということにする.

命題 4.7. 集合 $\{\varphi_1, \varphi_2, \dots, \varphi_M\}$ を規準化された辞書とする.

$$\max_{1 \leq j \leq M} |\varphi_j|_{2,n} \leq D\sqrt{n} \quad (j = 1, 2, \dots, M).$$

ただし, D は generic 定数である. このとき, 任意の正の整数 $1 \leq \forall k \leq M$ と任意の正の数 R に対して

$$\min_{\beta \in \mathbb{R}^M; |\beta|_{0,M} \leq k} \text{MSE}(\varphi_\beta) \leq \min_{\beta \in \mathbb{R}^M; |\beta|_{1,M} \leq R} \text{MSE}(\varphi_\beta) + \frac{D^2 R^2}{k}$$

が成り立つ.

Proof. $\bar{\beta} \in \mathbb{R}^M$ を

$$\bar{\beta} \in \arg \min_{\beta \in \mathbb{R}^M; |\beta|_{1,M} \leq R} \|\varphi_\beta - \mathbf{f}\|_{2,n}^2$$

で定める. 一般性を失わず

$$|\bar{\beta}_1| \geq |\bar{\beta}_2| \geq \cdots \geq |\bar{\beta}_M|; \quad \bar{\beta} = (\bar{\beta}_1, \bar{\beta}_2, \dots, \bar{\beta}_M)^\top$$

としてよい.

いま, $\mathbf{U} \in \mathbb{R}^n$ を $\{0, \pm R\varphi_1, \pm R\varphi_2, \dots, \pm R\varphi_M\}$ に値を取る確率ベクトルとする. さらに, その確率を

$$\begin{aligned} \Pr(\mathbf{U} = R \text{sign}(\bar{\beta}_j)\varphi_j) &= \frac{|\bar{\beta}_j|}{R} \quad (j = 1, 2, \dots, M), \\ \Pr(\mathbf{U} = -R \text{sign}(\bar{\beta}_j)\varphi_j) &= 0, \\ \Pr(\mathbf{U} = \mathbf{0}_n) &= 1 - \frac{1}{R} \sum_{j=1}^M |\bar{\beta}_j| \end{aligned}$$

で与える. このとき

$$\begin{aligned} \mathbb{E}[\mathbf{U}] &= \sum_{j=1}^M R \text{sign}(\bar{\beta}_j)\varphi_j \frac{|\bar{\beta}_j|}{R} = \sum_{j=1}^M \bar{\beta}_j \varphi_j = \varphi_{\bar{\beta}}, \\ \|\mathbf{U}\|_{2,n} &\leq \sqrt{\max_{1 \leq j \leq M} R^2 \|\varphi_j\|_{2,n}^2} \leq RD\sqrt{n} \end{aligned}$$

となる. いま, $\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_k$ を \mathbf{U} の独立複製とし

$$\bar{\mathbf{U}} := \frac{1}{k} \sum_{j=1}^k \mathbf{U}_j$$

と定めると, あるランダムベクトル $\tilde{\beta} \in \mathbb{R}^M$ で $|\tilde{\beta}|_{0,M} \leq k$ なるものがあって

$$\bar{\mathbf{U}} = \varphi_{\tilde{\beta}}$$

と書ける. なぜならば, $\bar{\mathbf{U}}$ は $R \text{sign}(\bar{\beta}_j)\varphi_j$ に値を取る k 個の \mathbf{U}_i に基づく標本平均だからである. さらに

$$\mathbb{E}[(\mathbf{f} - \varphi_{\bar{\beta}})^\top (\varphi_{\bar{\beta}} - \bar{\mathbf{U}})] = (\mathbf{f} - \varphi_{\bar{\beta}})^\top (\varphi_{\bar{\beta}} - \mathbb{E}[\bar{\mathbf{U}}]) = 0$$

となるので

$$\begin{aligned}
E[|\mathbf{f} - \bar{\mathbf{U}}|_{2,n}^2] &= E[|\mathbf{f} - \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}} + \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}} - \bar{\mathbf{U}}|_2^2] \\
&= E[|\mathbf{f} - \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}|_2^2 + |\boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}} - \bar{\mathbf{U}}|_2^2] \\
&= |\mathbf{f} - \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}|_{2,n}^2 + E[|\bar{\mathbf{U}} - E[\bar{\mathbf{U}}]|_{2,n}^2] \\
&= |\mathbf{f} - \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}|_{2,n}^2 + \frac{E\{\{\mathbf{U} - E[\mathbf{U}]\}^2\}}{k} \\
&\leq |\mathbf{f} - \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}|_{2,n}^2 + \frac{(DR\sqrt{n})^2}{k}
\end{aligned}$$

を得る. よって

$$E[|\mathbf{f} - \bar{\mathbf{U}}|_{2,n}^2] = E[|\mathbf{f} - \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}|_{2,n}^2] \geq \min_{\boldsymbol{\beta} \in \mathbb{R}^M; |\boldsymbol{\beta}|_{0,M} \leq k} |\mathbf{f} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2$$

に注意すれば

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^M; |\boldsymbol{\beta}|_{0,M} \leq k} \frac{1}{n} |\mathbf{f} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 \leq \frac{1}{n} |\mathbf{f} - \boldsymbol{\varphi}_{\bar{\boldsymbol{\beta}}}|_{2,n}^2 + \frac{D^2 R^2}{k}$$

を得る. これから

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^M; |\boldsymbol{\beta}|_{0,M} \leq k} \frac{1}{n} |\mathbf{f} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 \leq \min_{\boldsymbol{\beta} \in \mathbb{R}^M; |\boldsymbol{\beta}|_{0,M} \leq k} \frac{1}{n} |\mathbf{f} - \boldsymbol{\varphi}_{\boldsymbol{\beta}}|_{2,n}^2 + \frac{D^2 R^2}{k}$$

がわかる. □

系 4.8. 定理 4.6 と同じ仮定をする. 辞書 $\{\varphi_1, \varphi_2, \dots, \varphi_M\}$ は規準化され,

$$\begin{aligned}
\max_{1 \leq j \leq M} |\varphi_j|_{2,n} &= \max_{1 \leq j \leq M} \sqrt{\sum_{i=1}^n \varphi_j(\mathbf{X}_i)^2} \leq \sqrt{n}, \\
\boldsymbol{\varphi}_j &= (\varphi_j(\mathbf{X}_1), \varphi_j(\mathbf{X}_2), \dots, \varphi_j(\mathbf{X}_n))^{\top} \quad (j = 1, 2, \dots, M)
\end{aligned}$$

をみたすとする. このとき, ある定数 C が存在して, 任意の $\delta > 0$ に対して, BIC 推定量は次をみたす.

$$\begin{aligned}
\Pr\left(\text{MSE}(\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}}) \leq \inf_{\boldsymbol{\beta} \in \mathbb{R}^M} \left\{ 2\text{MSE}(\boldsymbol{\varphi}_{\boldsymbol{\beta}}) + \frac{C\sigma^2 \log(1/\delta)}{n} \right. \right. \\
\left. \left. + C \left[\frac{\sigma^2 |\boldsymbol{\beta}|_{0,M} \log(eM)}{n} \wedge \sigma |\boldsymbol{\beta}|_{0,M} \sqrt{\frac{\log(eM)}{n}} \right] \right\} \right) \\
\geq 1 - \delta
\end{aligned}$$

が成り立つ.

Proof. $\hat{\beta}^{\text{BIC}}$ の定義より

$$|\mathbf{Y} - \varphi_{\hat{\beta}^{\text{BIC}}}|_{2,n}^2 + n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \leq |\mathbf{Y} - \varphi_{\beta}|_{2,n}^2 + n\tau^2|\beta|_{0,M}$$

を得る. これより

$$|\mathbf{f} - \varphi_{\hat{\beta}^{\text{BIC}}}|_{2,n}^2 + n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,N} \leq |\mathbf{f} - \varphi_{\beta}|_{2,n}^2 + n\tau^2|\beta|_{0,M} + 2\epsilon^\top(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}) \quad (4.24)$$

を得る. $\hat{\beta}^{\text{BIC}} = \beta$ のときは, 系の主張は自明なので, $\hat{\beta}^{\text{BIC}} \neq \beta$ とする. このとき, Young の不等式

$$2ab \leq \frac{2}{\alpha}a^2 + \frac{\alpha}{2}b^2 \quad (a, b \in \mathbb{R}, \alpha > 0)$$

において, $\alpha = 1/3$ とおけば

$$\begin{aligned} 2\epsilon^\top(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}) &= 2\epsilon^\top\left(\frac{\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}}\right)|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n} \\ &\leq 6\left[\epsilon^\top\left(\frac{\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}}\right)\right]^2 + \frac{1}{6}|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 \end{aligned}$$

を得る. 三角不等式より

$$\frac{1}{6}|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 \leq \frac{1}{3}|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 + \frac{1}{3}|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 \quad (4.25)$$

を得る. これらからの式を (4.24) に代入すれば

$$\begin{aligned} |\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 &\leq |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 2\epsilon^\top(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}) \\ &\leq |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 6\left[\epsilon^\top\left(\frac{\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}}{|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}}\right)\right]^2 + \frac{1}{6}|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 \\ &\quad + 2\epsilon^\top(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}) \\ &= |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 6[\epsilon^\top\mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})]^2 + \frac{1}{6}|\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta}|_{2,n}^2 \\ &= |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 6[\epsilon^\top\mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})]^2 + \frac{1}{3}|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 + \frac{1}{3}|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 \end{aligned}$$

を得る. これを整理すると

$$\frac{2}{3}|\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 \leq \frac{4}{3}|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} + 6[\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})]^2 \quad (4.26)$$

$$\begin{aligned} &\iff \\ |\varphi_{\hat{\beta}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 &\leq 2|\varphi_{\beta} - \mathbf{f}|_{2,n}^2 - 3n\tau^2|\hat{\beta}^{\text{BIC}} - \beta|_{0,M} + n\tau^2|\beta|_{0,M} - n\tau^2|\hat{\beta}^{\text{BIC}}|_{0,M} \\ &\quad + 18[\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})]^2 + 6n\tau^2|\beta|_{0,M} \end{aligned} \quad (4.27)$$

を得る. $S \subset \{1, 2, \dots, M\}$ に対して

$$\Psi_{S,*} = [\phi_1, \phi_2, \dots, \phi_{r_{S,*}}]$$

を集合

$$\{\varphi_j; j \in S \cup \text{supp}(\beta)\}$$

が張る線型部分空間の基底とする. ただし

$$\varphi_j = (\varphi_j(\mathbf{X}_1), \varphi_j(\mathbf{X}_2), \dots, \varphi_j(\mathbf{X}_n))^\top$$

であり,

$$r_{S,*} \leq \#(S) + |\beta|_{0,M}$$

である. このとき

$$\begin{aligned} &18[\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}^{\text{BIC}}} - \varphi_{\beta})]^2 - 3n\tau^2|\hat{\beta}^{\text{BIC}} - \beta|_{0,M} \\ &= \max_{1 \leq k \leq M} \left\{ \max_{\#(S)=k} \left\{ \sup_{\text{supp}(\hat{\beta})=S} [\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}} - \varphi_{\beta})]^2 - 3n\tau^2 k \right\} \right\} \end{aligned}$$

となる. これより, $\forall t > 0$ に対して,

$$\begin{aligned} &\Pr\left(\max_{1 \leq k \leq M} \left\{ \max_{\#(S)=k} \left\{ \sup_{\text{supp}(\hat{\beta})=S} [\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}} - \varphi_{\beta})]^2 - 3n\tau^2 k \right\} \right\} > t\right) \\ &\leq \sum_{k=1}^m \sum_{\#(S)=k} \Pr\left(\sup_{\text{supp}(\hat{\beta})=S} \left\{ [\epsilon^\top \mathcal{U}(\varphi_{\hat{\beta}} - \varphi_{\beta})]^2 \right\} > \frac{t}{18} + \frac{1}{6}n\tau^2 k\right) \end{aligned}$$

命題 2.30 の ϵ 網論法を用いる.

$$\begin{aligned} &\Pr\left(\sup_{\mathbf{u} \in \mathbb{B}_{r_{S,*}}} [\epsilon^\top \Psi_{r_{S,*}} \mathbf{u}]^2 > \frac{t}{18} + \frac{n\tau^2 k}{6}\right) \\ &\leq 2 \cdot 6^{r_{S,*}} \exp\left(-\frac{\frac{t}{18} + \frac{n\tau^2 k}{6}}{8\sigma^2}\right) \\ &\leq 2 \exp\left(-\frac{t}{8 \cdot 18\sigma^2} - \frac{n\tau^2 k}{48\sigma^2} + |k + |\beta|_{0,M}| \log 6\right) \\ &\leq 2 \exp\left(-\frac{t}{8 \cdot 18\sigma^2} - k \log(6) - 2k \log(eM) + (k + |\beta|_{0,M}) \log(6)\right) \\ &\leq 2 \exp\left(-\frac{t}{8 \cdot 18\sigma^2} - 2k \log(eM) + |\beta|_{0,M} \log(12)\right) \end{aligned}$$

を得る. (4.25) より

$$6n\tau^2|\boldsymbol{\beta}|_{0,M} + t + 2|\boldsymbol{\varphi}_\beta - \mathbf{f}|_{2,n}^2 \leq |\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2$$

が起これば

$$\begin{aligned} 6n\tau^2|\boldsymbol{\beta}|_{0,M} + t + 2|\boldsymbol{\varphi}_\beta - \mathbf{f}|_{2,n}^2 &\leq 2|\boldsymbol{\varphi}_\beta - \mathbf{f}|_{2,n}^2 - 3n\tau^2|\hat{\boldsymbol{\beta}}^{\text{BIC}} - \boldsymbol{\beta}|_{0,M} \\ &\quad + 18[\boldsymbol{\epsilon}^\top \mathcal{U}(\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \boldsymbol{\varphi}_\beta)]^2 + 6n\tau^2|\boldsymbol{\beta}|_{0,M} \end{aligned}$$

となる. よって

$$18[\boldsymbol{\epsilon}^\top \mathcal{U}(\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \boldsymbol{\varphi}_\beta)]^2 - 3n\tau^2|\hat{\boldsymbol{\beta}}^{\text{BIC}} - \boldsymbol{\beta}|_{0,M} \geq t$$

が起こる. よって

$$\begin{aligned} &\Pr\left(|\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \mathbf{f}|_2^2 > 2|\boldsymbol{\varphi}_\beta - \mathbf{f}|_2^2 + 6n\tau^2|\boldsymbol{\beta}|_{0,M} + t\right) \\ &\leq \Pr\left(18[\boldsymbol{\epsilon}^\top \mathcal{U}(\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \boldsymbol{\varphi}_\beta)]^2 - n\tau^2|\hat{\boldsymbol{\beta}}^{\text{BIC}} - \boldsymbol{\beta}|_{0,M} > t\right) \\ &\leq \sum_{k=1}^M \sum_{\#(S)=k} \Pr\left(-\frac{t}{8 \cdot 18\sigma^2} - 2k \log(eM) + |\boldsymbol{\beta}|_{0,M} \log(12)\right) \\ &\leq \sum_{k=1}^M \left(\frac{eM}{k}\right)^k \exp\left(-\frac{t}{8 \cdot 18\sigma^2} - 2k \log(eM) + |\boldsymbol{\beta}|_{0,M}\right) \\ &\quad (\text{補題 3.10 より}) \\ &= \sum_{k=1}^M \frac{1}{k^k} \exp\left(-\frac{t}{18 \cdot 8\sigma^2} - k \log(eM) + |\boldsymbol{\beta}|_{0,M} \log(12)\right) \\ &\leq \frac{M}{(keM)^k} \exp\left(-\frac{t}{8 \cdot 18\sigma^2} + |\boldsymbol{\beta}|_{0,M} \log(12)\right) \\ &\leq \exp\left(-\frac{t}{8 \cdot 18\sigma^2} + |\boldsymbol{\beta}|_{0,M} \log(12)\right) \end{aligned}$$

を得る. ここで

$$t := 8 \cdot 18\sigma^2|\boldsymbol{\beta}|_{0,M} \log(12) + 8 \cdot 18\sigma^2 \log\left(\frac{1}{\delta}\right)$$

とおけば

$$\begin{aligned} \Pr\left(|\boldsymbol{\varphi}_{\hat{\boldsymbol{\beta}}^{\text{BIC}}} - \mathbf{f}|_{2,n}^2 > 2|\boldsymbol{\varphi}_\beta - \mathbf{f}|_{2,n}^2 + 6n\tau^2|\boldsymbol{\beta}|_{0,M} + 8 \cdot 18\sigma^2|\boldsymbol{\beta}|_{0,M} \log(12) \right. \\ \left. + 8 \cdot 18\sigma^2 \log\left(\frac{1}{\delta}\right)\right) \leq \delta \end{aligned}$$

となる. よって

$$\tau^2 = \frac{8 \cdot 18\sigma^2 \log(eM)}{n}$$

なので

$$\Pr\left(\begin{aligned} \text{MSE}(\varphi_{\hat{\beta}^{\text{BIC}}}) &\leq 2 \inf_{\beta \in \mathbb{R}^M} \text{MSE}(\varphi_{\beta}) + C \frac{\sigma^2 |\beta|_{0,M} \log(eM)}{n} + C \frac{\sigma^2 \log(1/\delta)}{n} \\ &\geq 1 - \delta \end{aligned}\right)$$

を得る. □

4.2 ノンパラメトリック回帰

記号

$$\begin{aligned} \mathcal{H} &= \{\varphi_1, \varphi_2, \dots, \varphi_M\} : \text{選択された辞書,} \\ f &: [0, 1] \rightarrow \mathbb{R}, \\ \varphi_j &: [0, 1] \rightarrow \mathbb{R} \quad (j = 1, 2, \dots, M). \end{aligned}$$

4.2.1 フーリエ分解

辞書を $L_2([0, 1])$ の正規直交系とする. すなわち,

$$\int_0^1 \varphi_j^x(x) dx = 1; \quad \int_0^1 \varphi_j(x) \varphi_k(x) dx = 0 \quad (1 \leq j \neq k \leq M).$$

ただし, $M = \infty$ の場合も扱う. その場合には, $1 \leq j \neq k < \infty$ と考える.

\mathcal{H} は正規直交系で, 係数 $\beta_j \in \mathbb{R}$ ($j = 1, 2, \dots$) を

$$\beta_j = \int_0^1 f(x) \varphi_j(x) dx$$

で定義する. これを f のフーリエ係数という.

回帰関数 f は

$$f = \sum_{j=1}^{\infty} \beta_j \varphi_j$$

なる分解を持つとする. ただし, 等号は

$$\lim_{M \rightarrow \infty} \int_0^1 \left| f(x) - \sum_{j=1}^M \beta_j \varphi_j(x) \right|^2 dx = 0$$

の意味である.

例 4.9. (三角関数基底) これは $L_2([0, 1])$ の正規直交基底となる.

$$\begin{aligned}\varphi_1(x) &= 1, \\ \varphi_{2k} &= \sqrt{2} \cos(2\pi kx), \\ \varphi_{2k+1} &= \sqrt{2} \sin(2\pi kx) \quad (k = 1, 2, \dots).\end{aligned}$$

□

例 4.10. (ウェーブレット) 関数 $\psi: \mathbb{R} \rightarrow \mathbb{R}$ を十分滑らかでコンパクトな台を持つものとする. この ψ をマザーウェーブレットという. 関数系を

$$\psi_{jk}(x) = 2^{j/2} \psi(2^j x - k) \quad (j, k \in \mathbb{Z})$$

で定義する. 適切な ψ に対して, 辞書 $\{\psi_{jk}; j, k \in \mathbb{Z}\}$ は $L_2([0, 1])$ の正規直交系となり, 時には基底となる. 基底となる場合には, $\forall g \in L_2([0, 1])$ に対して

$$g = \sum_{j=-\infty}^{j=\infty} \sum_{k=-\infty}^{k=\infty} \beta_{jk} \psi_{jk}; \quad \beta_{jk} = \int_0^1 g(x) \psi_{jk}(x) dx$$

とすればよい. 係数 β_{jk} を g のウェーブレット係数という.

最も簡単な例は Haar ウェーブレットである.

$$\psi(x) = \begin{cases} 1 & (0 < x < 1/2), \\ -1 & (1/2 \leq x \leq 1), \\ 0 & (\text{その他}). \end{cases}$$

□

4.2.2 Sobolev 族と楕円体

滑らかな関数族を考える. 滑らかさは微分できる回数で表現される. $f^{(k)}$ を f の k 回導関数とする.

定義 4.11. $p \in \{1, 2, \dots\}$ と $L > 0$ を固定する. 関数族である Sobolev クラス $W(p, L)$ を次で定義する.

$$\begin{aligned}W(p, L) &:= \{f: [0, 1] \rightarrow \mathbb{R}; f \in L_2([0, 1]), f^{(p-1)} \text{ は絶対連続で,} \\ &\int_0^1 \{f^{(p)}(x)\}^2 dx \leq L^2, \\ &f^{(j)}(0) = f^{(j)}(1) = 0 (j = 0, 1, \dots, p-1)\}.\end{aligned}$$

任意の $f \in W(p, L)$ は

$$f = \beta_1 \varphi_1 + \sum_{k=1}^{\infty} \{\beta_{2k} \varphi_{2k} + \beta_{2k+1} \varphi_{2k+1}\}$$

と展開される. ただし, 等号の意味は

$$\lim_{M \rightarrow \infty} \int_0^1 \left| f(x) - \sum_{j=1}^M \beta_j \varphi_j(x) \right|^2 dx = 0$$

である. $\beta = \{\beta_j\}_{j \geq 1}$ は

$$\ell_1(\mathbb{N}) = \left\{ \beta = (\beta_1, \beta_2, \dots) : \sum_{j=1}^{\infty} |\beta_j| < \infty \right\}$$

に属する.

$\forall p > 0$ に対して, $a_j (j = 1, 2, \dots)$ を

$$a_j = \begin{cases} j^p & (j \text{ は偶数}), \\ (j-1)^p & (j \text{ は奇数}), \end{cases} \quad (4.28)$$

で定める.

命題 4.12. $p \geq 1$ と L を固定する. $\{\varphi_j\}_{j \geq 1}$ を $L_2([0, 1])$ の三角関数基底とする. $\{a_j\}_{j \geq 1}$ を (4.28) で定義する. 関数 $f \in W(p, L)$ は

$$f = \sum_{j=1}^{\infty} \beta_j \varphi_j$$

と表現される. ただし, フーリエ係数 $\{\beta_j\}_{j \geq 1}$ は次で定義される $\ell_2(\mathbb{N})$ の Sobolev 楕円体に属する.

$$\Theta(p, L) := \left\{ \beta \in \ell_2(\mathbb{N}); \sum_{j=1}^{\infty} a_j \beta_j^2 \leq Q \right\},$$

$$Q = \frac{L^2}{\pi^{2p}}.$$

Proof. $j = 1, 2, \dots, p$ の j 回導関数 $f^{(j)}$ のフーリエ係数を $\{s_k(j)\}_{k \geq 1}$ で定義する.

$$\begin{aligned} s_1(j) &= \int_0^1 f^{(j)}(t) dt = f^{(j-1)}(1) - f^{(j-1)}(0) = 0, \\ s_{2k}(j) &= \sqrt{2} \int_0^1 f^{(j)}(t) \cos(2\pi kt) dt, \\ s_{2k+1}(j) &= \sqrt{2} \int_0^1 f^{(j)}(t) \sin(2\pi kt) dt. \end{aligned}$$

f のフーリエ係数は $\beta_k = s_k(0)$ で与えられる. 部分積分の公式より

$$\begin{aligned} s_{2k}(p) &= \sqrt{2}f^{(p-1)}(t)\cos(2\pi kt)\Big|_0^1 + (2\pi k)\sqrt{2}\int_0^1 f^{(p-1)}(t)\sin(2\pi kt) dt \\ &= \sqrt{2}\{f^{(p-1)}(1) - f^{(p-1)}(0)\} + (2\pi k)\sqrt{2}\int_0^1 f^{(p-1)}(t)\sin(2\pi kt) dt \\ &= (2\pi k)s_{2k+1}(p-1) \end{aligned}$$

となる. さらに

$$\begin{aligned} s_{2k+1}(p) &= \sqrt{2}f^{(p-1)}(t)(2\pi kt)\Big|_0^1 - (2\pi k)\sqrt{2}\int_0^1 f^{(p-1)}(t)\cos(2\pi kt) dt \\ &= -(2\pi k)s_{2k}(p-1) \end{aligned}$$

である. 特に, 帰納法より, $\forall k \geq 1$ に対して

$$\{s_{2k}(p)\}^2 + \{s_{2k+1}(p)\}^2 = (2\pi k)^{2p}\{\beta_{2k}^2 + \beta_{2k+1}^2\}$$

となる. 次に, (4.28) の a_j の定義より

$$\begin{aligned} \sum_{k=1}^{\infty} (2\pi k)^{2p}\{\beta_{2k}^2 + \beta_{2k+1}^2\} &= \pi^{2p}\left\{\sum_{k=1}^{\infty} a_{2k}^2\beta_{2k}^2 + \sum_{k=1}^{\infty} a_{2k+1}^2\beta_{2k+1}^2\right\} \\ &= \pi^{2p}\sum_{j=1}^{\infty} a_j^2\beta_j^2 \end{aligned}$$

である. よって, パーセルの等式より

$$\int_0^1 \{f^{(p)}(t)\}^2 dt = \sum_{k=1}^{\infty} \{\{s_{2k}(p)\}^2 + \{s_{2k+1}(p)\}^2\} = \pi^{2p}\sum_{j=1}^{\infty} a_j^2\beta_j^2$$

がわかる. $f \in W(p, L)$ なので

$$\int_0^1 \{f^{(p)}(t)\}^2 dt \leq L^2$$

となる. よって, $\beta \in \Theta(p, L^2/\pi^{2p})$ である. \square

注意 4.13. 命題 4.12 の逆も成立することが知られている. この本では, この事実を使わないので, 証明しない.

命題 4.14. Sobolev 楕円体は次の性質を持つ.

(1) $\forall Q > 0$ に対して

$$0 < p' < p \implies \Theta(p, Q) \subset \Theta(p', Q)$$

である.

(2) $\forall Q > 0$ に対して

$$p > \frac{1}{2} \implies f \text{ は連続}$$

である.

Proof. 証明は省略. □

補題 4.15. $n \in \mathbb{N} (n \geq 2)$ とする. $\{X_1, X_2, \dots, X_n\}$ を正則デザインとする. すなわち

$$X_j = \frac{j-1}{n} \quad (j = 1, 2, \dots, n)$$

とする. このとき, $\forall M \leq n-1$ に対して, $n \times M$ のデザイン行列

$$\Psi = (\varphi_j(X_i))_{1 \leq i \leq n; 1 \leq j \leq M}$$

は ORT 条件をみたす.

Proof. $j, j' \in \{1, 2, \dots, M-1\}$ を固定する.

$$\begin{aligned} \varphi_j &= (\varphi_j(X_1), \varphi_j(X_2), \dots, \varphi_j(X_n))^\top, \\ \varphi_{j'} &= (\varphi_{j'}(X_1), \varphi_{j'}(X_2), \dots, \varphi_{j'}(X_n))^\top \end{aligned}$$

の内積

$$\varphi_j^\top \varphi_{j'} = \sum_{i=1}^n \varphi_j(X_i) \varphi_{j'}(X_i)$$

を考える. $k_j = \lfloor j/2 \rfloor$ とおく. すなわち, $j/2$ の整数部分である. ベクトル $\mathbf{a}, \mathbf{b}, \mathbf{a}', \mathbf{b}' \in \mathbb{R}^n$ を以下のように定義する.

$$\begin{aligned} \exp\left(\frac{\sqrt{-1}2\pi k_j s}{n}\right) &= a_{s+1} + \sqrt{-1}b_{s+1}, \\ \exp\left(\frac{\sqrt{-1}2\pi k_{j'} s}{n}\right) &= a'_{s+1} + \sqrt{-1}b'_{s+1} \quad (s = 0, 1, \dots, n-1). \end{aligned}$$

このとき

$$\frac{1}{2} \varphi_j^\top \varphi_{j'} \in \{\mathbf{a}^\top \mathbf{a}', \mathbf{b}^\top \mathbf{b}', \mathbf{a}^\top \mathbf{b}'\}.$$

一方, $k_j \neq k_{j'}$ のとき, $\sigma \in \{-1, +1\}$ に対して

$$\sum_{s=0}^{n-1} \exp\left(\frac{\sqrt{-1}2\pi k_j s}{n}\right) \exp\left(\frac{\sqrt{-1}2\pi k_{j'} s}{n}\right) = \sum_{s=0}^{n-1} \exp\left(\frac{\sqrt{-1}2\pi (k_j + \sigma k_{j'}) s}{n}\right)$$

となる. 他方

$$\begin{aligned} & \sum_{s=0}^{n-1} \exp\left(\frac{\sqrt{-1}2\pi k_j s}{n}\right) \exp\left(\frac{\sqrt{-1}2\pi k_{j'} s}{n}\right) \\ &= (\mathbf{a} + \sqrt{-1}\mathbf{b})^\top (\mathbf{a}' + \sqrt{-1}\mathbf{b}') \\ &= \mathbf{a}^\top \mathbf{a}' - \sigma \mathbf{b}^\top \mathbf{b}' + \sqrt{-1}\{\mathbf{b}^\top \mathbf{a}' + \sigma \mathbf{a}^\top \mathbf{b}'\} \end{aligned}$$

である. よって, $k_j \neq k_{j'}$ のとき

$$\mathbf{a}^\top \mathbf{a}' = \pm \mathbf{b}^\top \mathbf{b}'; \quad \mathbf{b}^\top \mathbf{a}' = \pm \mathbf{a}^\top \mathbf{b}'$$

となる. 次に, $k_j = k_{j'}$ のときを考える. このとき

$$\sum_{s=0}^{n-1} \exp\left(\frac{\sqrt{-1}2\pi k_j s}{n}\right) \exp\left(\frac{\sqrt{-1}2\pi k_j s}{n}\right) = \begin{cases} 0 & (\sigma = 1), \\ n & (\sigma = -1) \end{cases}$$

となることがわかる. □

4.2.3 積分 2 乗誤差

$\beta \in \Theta(p, Q)$ のとき,

$$a_j^2 \beta_j \rightarrow 0 \quad (j \rightarrow \infty)$$

なので,

$$|\beta_j| = o(j^{-p}).$$

したがって, β_j は多項式のスピードで 0 に減衰するので, 固定した M に対して, f の打ち切りフーリエ列

$$\sum_{j=1}^M \beta_j \varphi_j =: \varphi_\beta^M$$

で f を近似するのは妥当であろう. 打ち切り $M \rightarrow \infty$ のとき, 誤差が 0 に収束するからである. 誤差の収束のレートに興味がある. Sobolev 族に f が属していると仮定すると, 誤差は打ち切り M と滑らかさの程度 p で制御されることがわかる.

補題 4.16. 任意の正の整数 M と $f \in \Theta(p, Q)$ ($p > 1/2$) に対して, 以下が成立する.

$$\|\varphi_\beta^M - f\|_{L_2([0,1])} = \sum_{j>M} |\beta_j|^2 \leq QM^{-2p}. \quad (4.29)$$

特に, $M = n - 1$ のとき

$$|\varphi_{\beta}^M - \mathbf{f}|_2 \leq 2n \left(\sum_{j>M} |\beta_j|^2 \right)^{1/2} \lesssim Qn^{2-2p} \quad (4.30)$$

となる. ただし

$$\begin{aligned} \varphi_{\beta}^M &= (\varphi_{\beta}^M(X_1), \varphi_{\beta}^M(X_2), \dots, \varphi_{\beta}^M(X_n))^{\top}, \\ \mathbf{f} &= (f(X_1), f(X_2), \dots, f(X_n))^{\top} \end{aligned}$$

である.

Proof. 任意の $\beta \in \Theta(p, Q)$ に対して, $p > 1/2$ のとき

$$\begin{aligned} \sum_{j=2}^{\infty} |\beta_j| &= \sum_{j=2}^{\infty} a_j |\beta_j| \frac{1}{a_j} \leq \sqrt{\sum_{j=2}^{\infty} a_j^2 \beta_j^2} \sqrt{\sum_{j=2}^{\infty} \frac{1}{a_j^2}} \quad (\text{Cauchy-Schwarz の不等式}) \\ &\leq \sqrt{Q \sum_{j=1}^{\infty} \frac{1}{j^{2p}}} < \infty \end{aligned}$$

である. $\{\varphi_j\}_{j \geq 1}$ は $L_2([0, 1])$ の正規直交系なので

$$\min_{\theta \in \mathbb{R}^M} \|\varphi_{\theta} - \mathbf{f}\|_{L_2} = \|\varphi_{\beta} - \mathbf{f}\|_{L_2}$$

である. さらに, $\beta \in \Theta(p, Q)$ のとき

$$\sum_{j>M} |\beta_j|^2 = \sum_{j>M} a_j^2 |\beta_j|^2 \frac{1}{a_j^2} \leq \frac{1}{a_{M+1}^2} Q \leq \frac{Q}{M^{2p}}$$

である. 2 番目の主張を証明するために

$$|\varphi_{\beta} - \mathbf{f}|_2 = \left| \sum_{j \geq n^2} \beta_j \varphi_j \right|_2 \leq 2\sqrt{2n} \sum_{j \geq n} |\beta_j|$$

に注意する. 最後の不等式は, いかなるデザイン X_1, X_2, \dots, X_n に対しても

$$|\varphi_j|_2 \leq \sqrt{2n} \quad (j \geq 1)$$

であることを用いた. $\beta \in \Theta(p, Q)$ のとき

$$\begin{aligned} \sum_{j \geq n} |\beta_j| \sum_{j \geq n} a_j |\beta_j| \frac{1}{a_j} &\leq \sqrt{\sum_{j \geq n} a_j^2 \beta_j^2} \sqrt{\sum_{j \geq n} \frac{1}{a_j^2}} \lesssim \sqrt{Q} n^{1/2-p}. \\ &\left(\because \sum_{j \geq n} \frac{1}{j^{2p}} \approx \int_n^{\infty} x^{-2p} dx = [x^{-2p+1}]_n^{\infty} = n^{-2p+1} \right) \end{aligned}$$

である. 一方, $f \in \Theta(p, Q)$ に対して

$$\beta_j^* = \int_0^1 f(x)\varphi_j(x) dx \quad (j = 1, 2, \dots)$$

であった. いま

$$\varphi_{\beta^*}^M := \varphi_{\beta^*}^M = \sum_{j=2}^M \beta_j^* \varphi_j$$

とする. $\varphi_{\beta^*}^M$ を推定するために, 最小 2 乗推定量 $\widehat{\beta}^{\text{LS}}$ を用いる.

$$\widehat{\beta}^{\text{LS}} \in \arg \min_{\beta \in \mathbb{R}^M} \sum_{j=1}^n \{Y_j - \varphi_{\beta}(X_j)\}^2.$$

定理 4.3 より, MSE に対するオラクル不等式は, $\forall \delta > 0$ に対して,

$$\Pr\left(|\varphi_{\widehat{\beta}^{\text{LS}}}^M - \mathbf{f}|_{2,n}^2 \leq \inf_{\beta \in \mathbb{R}^M} |\varphi_{\beta} - \mathbf{f}|_{2,n}^2 + C\sigma^2 \log\left(\frac{1}{\delta}\right)\right) \geq 1 - \delta$$

であった. ただし, $C > 0$ は定数である. これより

$$\begin{aligned} |\varphi_{\widehat{\beta}^{\text{LS}}}^M - \varphi_{\beta^*}^M|_{2,n}^2 &= |\varphi_{\widehat{\beta}^{\text{LS}}}^M - \mathbf{f}|_{2,n}^2 + |\varphi_{\beta^*}^M - \mathbf{f}|_{2,n}^2 - 2(\varphi_{\widehat{\beta}^{\text{LS}}}^M - \mathbf{f})^\top (\varphi_{\beta^*}^M - \mathbf{f}) \\ &\leq 2|\varphi_{\beta^*}^M - \mathbf{f}|_{2,n}^2 - 2(\varphi_{\widehat{\beta}^{\text{LS}}}^M - \mathbf{f})^\top (\varphi_{\beta^*}^M - \mathbf{f}) + C\sigma^2 \log\left(\frac{1}{\delta}\right) \\ &= 2(\varphi_{\beta^*}^M - \varphi_{\widehat{\beta}^{\text{LS}}}^M)^\top (\varphi_{\beta^*}^M - \mathbf{f}) + C\sigma^2 \log\left(\frac{1}{\delta}\right) \\ &= 2(\varphi_{\beta^*}^M - \varphi_{\widehat{\beta}^{\text{LS}}}^M)^\top \left(\sum_{j>M} \beta_j^* \varphi_j\right) + C\sigma^2 \log\left(\frac{1}{\delta}\right) \\ &= 2(\varphi_{\beta^*}^M - \varphi_{\widehat{\beta}^{\text{LS}}}^M)^\top \left(\sum_{j>M} \beta_j^* \varphi_j\right) + C\sigma^2 \log\left(\frac{1}{\delta}\right) \end{aligned}$$

となる. 最後の等号は補題 4.15 よりわかる. すなわち, $j = j'$ のとき

$$\varphi_j^\top \varphi_{j'} = 0.$$

(4.29) と Young の不等式より

$$2ab \leq \alpha a^2 + \frac{b^2}{\alpha} \quad (a, b \in \mathbb{R}, \alpha > 0)$$

より

$$\begin{aligned} 2(\varphi_{\beta^*}^M - \varphi_{\widehat{\beta}^{\text{LS}}}^M)^\top \left(\sum_{j>M} \beta_j^* \varphi_j\right) &\leq \alpha |\varphi_{\beta^*}^M - \varphi_{\widehat{\beta}^{\text{LS}}}^M|_2^2 + \frac{C}{\alpha} \sum_{j \geq 1} (\beta_j^*)^2 \varphi_j^2 \\ &= \alpha |\varphi_{\beta^*}^M - \varphi_{\widehat{\beta}^{\text{LS}}}^M|_2^2 + \frac{C}{\alpha} Qn^{2-2p}. \end{aligned}$$

が成り立つ。最後の等号は

$$\sum_{j \geq n} \beta_j^* \approx \int_n^\infty x^{-2p} dx \approx n^{-2p+1}, |\varphi_j^2| \leq 2n, \beta^* \in \Theta(p, Q)$$

よりわかる。以上を合わせると

$$\begin{aligned} |\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\beta^*}|_2^2 &\leq 2(\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\beta^*})^\top \left(\sum_{j \geq n} \beta_j^* \varphi_j \right) + C\sigma^2 \log \left(\frac{1}{\delta} \right) \\ &\leq \alpha |\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\beta^*}|_2^2 + \frac{C}{\alpha} Q n^{n-2p} + C\sigma^2 \log \left(\frac{1}{\delta} \right) \end{aligned}$$

なので, $0 < \alpha < 1$ に対して

$$(1 - \alpha) |\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\beta^*}|_2^2 \leq \frac{C}{\alpha} Q n^{n-2p} + C\sigma^2 M \log \left(\frac{1}{\delta} \right)$$

である。よって

$$|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\beta^*}|_{2,n}^2 \leq \frac{C}{\alpha(1-\alpha)} Q n^{n-2p} + \frac{\sigma^2 M}{1-\alpha} \log \left(\frac{1}{\delta} \right) \quad (4.31)$$

がわかる。ORT 条件をみたすので

$$\begin{aligned} |\varphi_{\hat{\beta}^{\text{LS}}}^M - \varphi_{\beta^*}^M|_{2,n}^2 &= \int_0^1 \left\{ \sum_{j=2}^M \hat{\beta}_j^{\text{LS}} \varphi_j(x) - \sum_{j=2}^M \beta_j^* \varphi_j(x) \right\}^2 dx \\ &= \sum_{j=1}^M (\hat{\beta}_j^{\text{LS}} - \beta_j^*)^2 \end{aligned}$$

である。一方, ORT 条件をみたすので

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n \varphi_j(X_i) \varphi_j(X_i) &= 1, \\ \frac{1}{n} \sum_{i=1}^n \varphi_j(X_i) \varphi_{j'}(X_i) &= 0 \quad (j \neq j') \end{aligned}$$

である。したがて

$$\begin{aligned} |\varphi_{\hat{\beta}^{\text{LS}}}^M - \varphi_{\beta^*}^M|_{2,n}^2 &= \left| \sum_{j=1}^M (\hat{\beta}_j^{\text{LS}} - \beta_j^*) \varphi_j \right|_{2,n}^2 = \sum_{i=1}^n \left(\sum_{j=1}^M (\hat{\beta}_j^{\text{LS}} - \beta_j^*) \varphi_j(X_i) \right)^2 \\ &= \sum_{j=1}^M \sum_{j'=1}^M (\hat{\beta}_j^{\text{LS}} - \beta_j^*) (\hat{\beta}_{j'}^{\text{LS}} - \beta_{j'}^*) \sum_{i=1}^n \varphi_j(X_i) \varphi_{j'}(X_i) \\ &= \sum_{j=1}^M \sum_{j'=1}^M (\hat{\beta}_j^{\text{LS}} - \beta_j^*) (\hat{\beta}_{j'}^{\text{LS}} - \beta_{j'}^*) \delta_{j,j'} = n \sum_{j=1}^M (\hat{\beta}_j^{\text{LS}} - \beta_j^*)^2 \end{aligned}$$

となる. よって

$$\|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\beta^*}\|_{2,n}^2 = n \|\varphi_{\hat{\beta}^{\text{LS}}} - \varphi_{\beta^*}^M\|_{L_2}^2$$

がわかる. \square

命題 4.17. $p \geq (1 + \sqrt{5})/4$, $Q > 0$ とする. 回帰モデル (4.1) を仮定し, $\epsilon \sim \text{subG}_n(\sigma^2)$ ($0 < \sigma \leq 1$) とする. さらに, $M = \lceil n^{1/(2p+1)} \rceil$ とし, n は十分大きく $M \leq n - 1$ とする. 最小 2 乗推定量

$$\begin{aligned} \hat{\beta}^{\text{LS}} &\in \arg \min_{\beta \in \mathbb{R}^M} \frac{1}{n} \sum_{j=1}^n \{Y_j - \varphi_{\hat{\beta}}^M(X_j)\}^2, \\ \varphi_{\hat{\beta}}^M(x) &= \sum_{k=1}^M \beta_k \varphi_k(x), \\ \varphi_k(x) &= \begin{cases} \sqrt{2} \cos(\pi k x) & (j \text{ は偶数}), \\ \sqrt{2} \sin(\pi(k-1)x) & (j \text{ は奇数}). \end{cases} \end{aligned}$$

で定義する. このとき, 最小 2 乗推定量 $\hat{\beta}^{\text{LS}}$ は, $\forall \delta > 0$ に対して

$$\Pr\left(\|\varphi_{\hat{\beta}}^M - f\|_{L_2([0,1])} \lesssim n^{-2p/(2p+1)} (1 + \sigma^2 \log(1/\delta))\right) \geq 1 - \delta$$

をみたす.

Proof. たとえば, $\alpha = 1/2$ とし, (4.31) と補題 4.15 を用いると, $M \leq n - 1$ のとき,

$$\|\varphi_{\hat{\beta}^{\text{LS}}}^M - \varphi_{\beta^*}^M\|_{L_2([0,1])} \lesssim n^{1-2p} + \sigma^2 \frac{M \log(1/\delta)}{n}.$$

補題 4.16 と $\sigma^2 \leq 1$ を用いると

$$\begin{aligned} \|\varphi_{\hat{\beta}^{\text{LS}}}^M - f\|_{L_2([0,1])} &\leq 2\|\varphi_{\hat{\beta}^{\text{LS}}}^M - \varphi_{\beta^*}^M\|_{L_2([0,1])} + 2\|\varphi_{\beta^*}^M - f\|_{L_2([0,1])} \\ &\lesssim M^{-2p} + n^{1-2p} + \sigma^2 \frac{M \log(1/\delta)}{n} \end{aligned}$$

となる. ここで, $M = \lceil n^{1/(2p+1)} \rceil \leq n - 1$ になるように n を十分大きく取れば

$$\|\varphi_{\hat{\beta}^{\text{LS}}}^M - f\|_{L_2([0,1])} \lesssim n^{-2p/(2p+1)} + n^{1-2p} \sigma^2 \log\left(\frac{1}{\delta}\right)$$

となる. 最後に, $p \geq (1 + \sqrt{5})/4$ であることに注意すれば

$$\begin{aligned} n^{1-2p} < n^{-2p/(2p+1)} &\iff 1 - 2p < -\frac{2p}{2p+1} \iff (1 - 2p)(2p + 1) < -p \\ &\iff 4p^2 - 2p - 1 > 0 \iff p > \frac{1 + \sqrt{5}}{4}, p < \frac{1 - \sqrt{5}}{4} \end{aligned}$$

となる. だから

$$\|\varphi_{\hat{\beta}^{\text{LS}}}^M - f\|_{L_2([0,1])} \lesssim n^{-2p/(2p+1)} \left(1 + \sigma^2 \log\left(\frac{1}{\delta}\right)\right)$$

を得る.

□

4.3 章末注釈と参考文献

この章は [3] を参考にした.

4.4 演習問題

演習問題 4.1.

演習問題 4.1 の解答

□

