

Estymatory postselekcyjne i ich własności

Wykład III

Wiśła, grudzień 2009

Estymatory postselekcyjne

\mathcal{M} -zbiór (lista) modeli.

$M \in \mathcal{M}$, $M = \{P_\theta, \theta \in \Theta\}$. Metoda selekcji: na podstawie danych $\mathbf{Y} = (Y_1, \dots, Y_n)$ opisanych przez rozkład P wybieramy $\hat{M}(\mathbf{Y})$: model adekwatnie reprezentujący dane.

Często wybór \hat{M} nie jest celem analizy, \hat{M} jest używany do konstrukcji estymatorów, statystyk testowych, predykcji.

$\hat{\theta}(M)$ - ustalony estymator θ w modelu M (np. NW lub MNK)

Estymator postselekcyjny PMS (post-model selection estimator)

$$\tilde{\theta}_{PMS} = \sum_{M \in \mathcal{M}} \hat{\theta}(M) I\{\hat{M} = M\}.$$

Tutaj: własności predykcyjne metod selekcji opartych na minimalizacji estymatora błędu predykcji i wynikowych estymatorów postselekcyjnych.

Poprawna specyfikacja modelu

Model M poprawnie wyspecyfikowany: Istnieje θ : $P = P_\theta$.

Ma różne znaczenie w zależności od sposobu zdefiniowania M i P . Dla próby $(Y_1, \mathbf{X}_1), \dots, (Y_n, \mathbf{X}_n)$, równość rozkładów łącznych (lub gęstości łącznych)

$$p(y_1, \mathbf{x}_1, \dots, \mathbf{x}_n, y_n) = p_\theta(y_1, \mathbf{x}_1, \dots, \mathbf{x}_n, y_n) \quad (*)$$

lub równość rozkładów warunkowych (lub gęstości warunkowych)

$$p(y_1, \dots, y_n | \mathbf{x}_1, \dots, \mathbf{x}_n) = p_\theta(y_1, \dots, y_n | \mathbf{x}_1, \dots, \mathbf{x}_n) \quad (**)$$

Czasami warunek słabszy niż $(**)$ np. Shao (1997)

$$E(Y_1, \dots, Y_n | \mathbf{x}_1, \dots, \mathbf{x}_n) = E_\theta(Y_1, \dots, Y_n | \mathbf{x}_1, \dots, \mathbf{x}_n) \quad (**)$$

Przykład 1 Lista modeli liniowych.

$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, gdzie \mathbf{X} : deterministyczna macierz $n \times p$, $\boldsymbol{\varepsilon} \sim F \in \mathcal{F}$, F nie zależy od $\boldsymbol{\beta}$. Dla $\boldsymbol{\tau} \in \{0, 1\}^p$ i $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)'$

$$M_{\boldsymbol{\tau}} = \{P_{\boldsymbol{\beta}, F} : \boldsymbol{\beta} \in R^p \text{ t.ż. } \beta_i = 0 \text{ gdy } \tau_i = 0, F \in \mathcal{F}\}$$

$$M(k) = \{P_{\boldsymbol{\beta}, F} : \boldsymbol{\beta} \in R^p \text{ t.ż. } \beta_i = 0 \text{ gdy } i > k, F \in \mathcal{F}\}$$

$$\mathcal{M}_1 = \{M_{\boldsymbol{\tau}}, \boldsymbol{\tau} \in \{0, 1\}^p\} \quad : 2^p \text{ modeli}$$

$$\mathcal{M}_2 = \{M(k), 0 \leq k \leq p\} \quad : p + 1 \text{ modeli}$$

$$\mathcal{M}_3 = \{M_{\boldsymbol{\tau}}, \boldsymbol{\tau} \in \{0, 1\}^p \& \tau_i = 1, i = 1, 2, \dots, l\} \quad : 2^{p-l} \text{ modeli.}$$

p może zmieniać się wraz z n : $p = p(n)$.

Przykład 2 Model jednoczynnikowej ANOVA. $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$

$$\mathbf{X}_n = \begin{pmatrix} \mathbf{1}_r & \mathbf{0} & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{1}_r & \mathbf{1}_r & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{1}_r & \mathbf{0} & \mathbf{1}_r & \dots & \mathbf{0} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{1}_r & \mathbf{0} & \mathbf{0} & \dots & \mathbf{1}_r \end{pmatrix}$$

p poziomów czynnika, na każdym r obserwacji.

$\boldsymbol{\beta} = (\mu_1, \mu_2 - \mu_1, \dots, \mu_p - \mu_1)'$.

$M_1: \boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_p) : \mu_1 = \mu_2 = \dots = \mu_p$.

$M_2: \boldsymbol{\mu} \in R^p$.

$\mathcal{M} = \{M_1, M_2\}$.

Przypadek $p = p(n) \rightarrow \infty$. Model dobrze wyspecyfikowany może również zmieniać się wraz z n !

Zgodność i konserwatywność reguły selekcji

Zakładamy, że rodzina modeli \mathcal{M} jest dobrze wyspecyfikowana tzn. istnieje $M \in \mathcal{M}$ i $P_\theta = P \in M$ opisujący dane \mathbf{Y} oraz, że jest domknięta ze względu na przecięcia ($M_1, M_2 \in \mathcal{M} \Rightarrow M_1 \cap M_2 \in \mathcal{M}$).

Wtedy istnieje minimalny model M_{min} o tej własności (minimalny model dobrze wyspecyfikowany).

Reguła wyboru modelu \hat{M} jest zgodna jeśli $P(\hat{M} = M_{min}) \rightarrow 1$ gdy $n \rightarrow \infty$.

Reguła wyboru modelu \hat{M} jest konserwatywna jeśli *nie* jest zgodna, ale

$$P(M_{min} \subset \hat{M}) \rightarrow 1.$$

Uwaga Zgodność (tak rozumiana) ma sens tylko dla list dobrze wyspecyfikowanych !

Problem zgodności AIC dla modelu liniowego

$M_1 \subset M_2$, M_1 oparty na p_0 predyktorach, M_2 na $p_0 + p_1$ predyktorach.
 $\varepsilon \sim N(0, \sigma^2 \mathbf{I})$.

$P \in M_1$: Oba modele dobrze wyspecyfikowane.

$$AIC = \frac{RSS_i}{n} + \frac{2\hat{\sigma}_n^2 \times (\text{liczba par. modelu } i)}{n}$$

Ale $RSS_i = \varepsilon'(\mathbf{I} - \mathbf{H}_i)\varepsilon$ (\mathbf{H}_i - macierz daszkowa dla modelu i)

$$\hat{M} = M_1 \iff 2\hat{\sigma}_n^2 \Delta > \varepsilon'(\mathbf{H}_2 - \mathbf{H}_1)\varepsilon$$

$\Delta = p_1$ - różnica liczb parametrów. Ale

$$\varepsilon'(\mathbf{H}_2 - \mathbf{H}_1)\varepsilon \sim \sigma^2 \chi_{\Delta}^2$$

i $\hat{\sigma}_n^2 \rightarrow \sigma^2(P)$. Jeśli $\Delta = p_1(n) \rightarrow \infty$ (*), to AIC zgodna.

Rozpatrzmy sytuację, gdy $\Delta = p_1$ - stała.

Wtedy

$$P(\sigma^2 \chi_{\Delta}^2 > C \sigma^2 \Delta) > 0,$$

zatem

$$\liminf_n P(\hat{M} = M_2) > 0$$

Kryterium AIC nie jest zgodne: stała $C = C_n$ (w miejsce 2) musi dążyć do ∞ !

Twierdzenie 1 Niech $|\mathcal{M}| = p$ -ustalona

$$\hat{M} = \operatorname{argmin}_{M \in \mathcal{M}} GIC(M) =: \operatorname{argmin}_{M \in \mathcal{M}} \left(\frac{RSS(M)}{n} + \frac{p(M)C_n \hat{\sigma}_n^2}{n} \right),$$

gdzie $p(M)$ liczba zmiennych w modelu M . $\varepsilon \sim N(0, \sigma^2 \mathbf{I}_n)$ i istnieje model $M \in \mathcal{M}$, t.ż. $P = P_{(\beta, \sigma^2)} = N(\beta, \sigma^2 \mathbf{I}_n) \in M$.

Jeśli $\mathbf{X}'\mathbf{X}$ dodatnio określona dla każdego n !! oraz $n^{-1}\mathbf{X}'\mathbf{X}$ zbiega do pewnej macierzy dodatnio określonej \mathbf{M} , $\hat{\sigma}_n^2$ zgodny estymator σ^2 i

(i) $C_n \rightarrow \infty$ i $C_n/n \rightarrow 0$, to \hat{M} -zgodna;

(ii) $\limsup_n |C_n| < \infty$ to \hat{M} -konserwatywna.

Zgodność a efektywność predykcji

Uwaga Często nie zgodność jest własnością, która interesuje nas najbardziej. Dla $\boldsymbol{\mu}_n = E(\mathbf{Y}|\mathbf{X})$

$$\begin{aligned}\tilde{M} &= \operatorname{argmin}_{M \in \mathcal{M}} \operatorname{Err}_{in}(M) = \operatorname{argmin}_{M \in \mathcal{M}} n^{-1} E_{\mathbf{Y}^0} (\|\mathbf{Y}^0 - \mathbf{X}(M)\hat{\beta}_M\|^2 | \mathbf{X}) = \\ &= \operatorname{argmin}_{M \in \mathcal{M}} \underbrace{(n^{-1} \|\boldsymbol{\mu}_n - \mathbf{H}(M)\boldsymbol{\mu}_n\|^2 + n^{-1} \boldsymbol{\varepsilon}' \mathbf{H}(M) \boldsymbol{\varepsilon})}_{L_n(M)}\end{aligned}$$

$$P(\operatorname{Err}_{in}(\tilde{M}) = \operatorname{Err}_{in}(\hat{M})) \rightarrow 1 \quad ?? \quad (*)$$

lub

$$\operatorname{Err}_{in}(\hat{M}) / \operatorname{Err}_{in}(\tilde{M}) \rightarrow 1 \quad (P) \quad ?? \quad (**)$$

Oba problemy dobrze postawione również dla list błędnie wyspecyfikowanych.

(*) jest inną własnością zgodności (**zgodność predycyjna**).

(**) - **efektywność predycyjna**.

Lista może nie zawierać poprawnych modeli, a (**) będzie spełniona (Shao (1997)), tak jest np. przy pewnych warunkach dla k. Akaike.

Twierdzenie 2 (Shao (1997)) Jeśli $\hat{\sigma}_n^2$ zgodny estymator wariancji,

$$C_1 n \leq \lambda_{1, \mathbf{X}'_n \mathbf{X}_n}, \lambda_{p, \mathbf{X}'_n \mathbf{X}_n} \leq C_2 n,$$

$$\sum_{M: P \notin M} (nE(\|\boldsymbol{\mu}_n - \mathbf{X}(M)\hat{\boldsymbol{\beta}}(M)\|^2))^{-l} \rightarrow 0 \text{ dla pewnego } l \in \mathbb{N},$$

to

$$AIC(M) = \frac{\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}}{n} + \frac{2p\hat{\sigma}^2}{n} - \frac{\boldsymbol{\varepsilon}'\mathbf{H}(M)\boldsymbol{\varepsilon}}{n}$$

dla każdego M takiego, że $P \in M$

oraz

$$AIC(M) = \frac{\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}}{n} + L_n(M) + o_P(L_n(M))$$

jeśli $P \notin M$, gdzie $L_n(M) = (\|\boldsymbol{\mu}_n - \mathbf{H}(M)\boldsymbol{\mu}_n\|^2 + \boldsymbol{\varepsilon}'\mathbf{H}(M)\boldsymbol{\varepsilon})/n$

przy czym $o_P(L_n(M))$ jest jednostajne po wszystkich modelach M takich, że $P \notin M$.

Jeśli $P \in M$ dla dokładnie jednego modelu M i $p_n(M) \rightarrow \infty$ to
($\frac{p\hat{\sigma}_n^2}{n} - \frac{\epsilon' \mathbf{H}(M)\epsilon}{n} = o_P(L_n(M))$)



$$AIC(M) = \frac{\epsilon' \epsilon}{n} + \frac{2p\hat{\sigma}_n^2}{n} - \frac{\epsilon' \mathbf{H}(M)\epsilon}{n} = \frac{\epsilon' \epsilon}{n} + L_n(M) + o_P(L_n(M))$$

jednostajnie po wszystkich modelach M



predykcyjna efektywność AIC

Podobnie $\limsup p_n(M) < \infty \Rightarrow$ zgodność predykcyjna \Rightarrow efektywność predykcyjna.

Ogólniej $Err_{in}(\hat{M})/Err_{in}(\tilde{M}) \rightarrow 1 (P)$ dla \hat{M} wybranego w oparciu o AIC, gdy

- P nie należy do więcej niż jednego modelu na liście (w szczególności żadnego);
- $\#\{M : P \in M\}$ jest ograniczona i $p_n(M_{min}) \rightarrow \infty$ lub

$$\min_{M:P \in M, M \neq M_{min}} (p_n(M) - p_n(M_{min})) \rightarrow \infty,$$

gdzie M_{min} jest dobrze wyspecyfikowanym modelem o minimalnej liczbie parametrów.

Przykład 2. Kontynuacja $p \rightarrow \infty$, r -ustalone. ($p/n = r^{-1}$ **nie** dąży do 0 !)

Z tw. Shao wynika, że AIC efektywne predykcyjnie, natomiast dla GIC przy $C_n \rightarrow \infty$ $P(\hat{M}_{GIC} = M_1) \rightarrow 1$ i GIC jest efektywne predykcyjnie tylko gdy M_1 jest dobrze wyspecyfikowany.

Dla sytuacji $r \rightarrow \infty$, p -ustalone, wymiary obu modeli są ustalone, AIC **nie** jest efektywne predykcyjnie, gdy średnia odpowiedź nie zależy od poziomu czynnika, a GIC jest zawsze, gdy $C_n \rightarrow \infty$ i $C_n/n \rightarrow 0$.

Shao (1997): ogólna konkluzja dla modeli liniowych: AIC bardziej predykcyjnie użyteczne, gdy M_{min} nie ma ustalonego wymiaru (lub M_{min} nie istnieje), w przeciwnym przypadku GIC z $C_n \rightarrow \infty$ bardziej użyteczne.

Przykład 2. Kontynuacja Efektywność n -krotnej krosvalidacji

$$L_n(M) = \Delta_n(M) + \frac{\varepsilon' \mathbf{H}(M) \varepsilon}{n},$$

gdzie dla $\mu_i = EY_i$

$$\Delta_n(M) = \frac{1}{k} \sum_{i=1}^k (\mu_i - \bar{\mu})^2.$$

Jeśli $\Delta_n(M) \rightarrow \Delta > 0$, to krosvalidacja n -krotna **nie** jest efektywna predykcyjnie, jeśli

$$\frac{\sigma^2}{r} < \Delta \leq \frac{\sigma^2}{r-1}$$

Odtąd $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$. Popatrzmy na ryzyko średniokwadratowe

$$E(\|\mathbf{Y}^0 - \mathbf{X}\tilde{\boldsymbol{\beta}}\|^2|\mathbf{X}) = n\sigma^2 + E(\|\mathbf{X}\boldsymbol{\beta} - \mathbf{X}\tilde{\boldsymbol{\beta}}\|^2|\mathbf{X})$$

$R_n = E(\|\mathbf{X}\boldsymbol{\beta} - \mathbf{X}\tilde{\boldsymbol{\beta}}\|^2|\mathbf{X})$ średniokwadratowa miara jakości predykcji.

Związki między zgodnością (w sensie wyboru minimalnego modelu dobrze wyspecyfikowanego) a zachowaniem się ryzyka średniokwadratowego dla estymatora PMS $\tilde{\boldsymbol{\beta}}$.

Lista modeli liniowych zawierających **skończoną** liczbę predyktorów, $\mathbf{j}_0 = \{1, \dots, k_0\}$ zbiór indeksów predyktorów odpowiadających niezerowym współczynnikom.

$$\mathbf{J}_1 = \{\mathbf{j} : \mathbf{j}_0 \setminus \mathbf{j} \neq \emptyset\};$$

$$\mathbf{J}_2 = \{\mathbf{j} : \mathbf{j}_0 \subset \mathbf{j}\}.$$

$\hat{\mathbf{j}}$ - reguła wyboru, $\tilde{\beta}$ -odpowiadający jej PMS.

Twierdzenie (Nishii (1984)) Jeśli $n^{-1}\mathbf{X}'\mathbf{X}$ zbiega do pewnej macierzy \mathbf{M}

Jeśli

i) $nP(\hat{\mathbf{j}} = \mathbf{j}) \rightarrow 0$ dla $\mathbf{j} \in \mathbf{J}_1$

(ii) $P(\hat{\mathbf{j}} = \mathbf{j}) \rightarrow 0$ dla $\mathbf{j} \in \mathbf{J}_2 \setminus \mathbf{j}_0$

to

$$R_n(\mathbf{j}_0^c) = E(\|\mathbf{X}\tilde{\boldsymbol{\beta}} - \mathbf{X}\boldsymbol{\beta}\|^2 I\{\hat{\mathbf{j}} \neq \mathbf{j}_0\} | \mathbf{X}) \rightarrow 0.$$

Dwa modele liniowe

$M_1 \subset M_2$, M_1 oparty na p_0 predyktorach, M_2 na $p_0 + p_1$ predyktorach

$$\beta = (\beta'_1, \beta'_2)'$$

$M_1 : \beta_2 = \mathbf{0}$.

$\hat{\mathbf{j}}$: reguła wyboru, $\tilde{\beta}_2$ odpowiadający jej PMS. Z tw. Nishii

$$P(\tilde{\beta}_2 = \mathbf{0}) \rightarrow 0$$

implikuje

$$E(\|\mathbf{X}\tilde{\beta} - \mathbf{X}\beta\|^2) \rightarrow \sigma^2 p_0 \quad \text{jeśli } \beta_2 = \mathbf{0}$$

i (*)

$$E(\|\mathbf{X}\tilde{\beta} - \mathbf{X}\beta\|^2) \rightarrow \sigma^2(p_0 + p_1) \quad \text{jeśli } \beta_2 \neq \mathbf{0}$$

Rozpatrzmy (nieobserwowalną) metodę selekcji:

$$\beta_2 = 0 \Rightarrow \hat{\mathbf{j}} = \{1, 2, \dots, p_0\} \text{ i } \beta^* = \hat{\beta}_{MNK,1}$$

$$\beta_2 = 0 \Rightarrow \hat{\mathbf{j}} = \{1, 2, \dots, p_0 + p_1\} \text{ i } \beta^* = \hat{\beta}_{MNK,2}$$

Ryzyko β^* ma własność (*).

Ryzyko $\tilde{\beta}$ zachowuje się tak samo jak ryzyko nieobserwowalnego estymatora β^* (dla ustalonego β). 'Własność prorocza'.

Tak jest tylko dla ustalonego β !

\mathcal{M} : lista zawierająca wszystkie podmodele modelu liniowego ustalonego wymiaru p . Błędy o gęstości f , takiej, że $\infty > I(f) > 0$.

Dla zgodnej reguły selekcji i $\hat{\beta} = \hat{\beta}_{PMS}$ na niej opartej

$$\limsup_{\beta \in R^p} E \|\mathbf{X}\hat{\beta} - \mathbf{X}\beta\|^2 = \infty.$$

(Leeb i Pötscher (2008), również Yang (2005))

Twierdzenie ma znaczenie, gdy parametry model modelu dobrze wyspecyfikowanego zależą od n : $\mathbf{Y}^{(n)} = \mathbf{X}^{(n)}\beta^{(n)} + \varepsilon^{(n)}$.

Twierdzenie $r(\beta) = (r_1, r_2, \dots, r_p)$, $r_i = I(\beta_i \neq 0)$.

$\hat{\beta}$ jest estymatorem β takim, że dla dowolnego $\beta \in R^p$

$$P_{\beta}(r(\hat{\beta}) \leq r(\beta)) \rightarrow 1 \quad n \rightarrow \infty$$

($\hat{\beta}$ prawidłowo identyfikuje nieistotne zmienne z pr. dążącym do 1, w szczególności wystarczy, aby $\hat{\beta}$ zgodny).

$\ell : R^p \rightarrow R^+$ dowolna nieujemna funkcja straty. Wówczas

$$\sup_{\beta} E(\ell(n^{1/2}(\hat{\beta} - \beta))) \rightarrow \sup_{s \in R^p} \ell(s).$$

W szczególności dla kwadratowej funkcji straty

$$\sup_{\beta} E(n(\hat{\beta} - \beta)'(\hat{\beta} - \beta)) \rightarrow \infty$$

Ponadto

$$\sup_{\beta} E((\mathbf{X}\hat{\beta} - \mathbf{X}\beta)'(\mathbf{X}\hat{\beta} - \mathbf{X}\beta)) \rightarrow \infty$$

dla estymatora MNK w pełnym modelu mamy

$$E(n(\hat{\beta}_{MNK} - \beta_{MNK})'(\hat{\beta}_{MNK} - \beta_{MNK})) = \text{tr}((n^{-1}\mathbf{X}'\mathbf{X})^{-1}) \rightarrow \text{tr}(\mathbf{M}^{-1}).$$

Własność estymatora w twierdzeniu odpowiednik złego zachowania się superefektywnego estymatora Hodgesa.

$$X_1, \dots, X_n \sim N(\theta, 1), \quad \bar{X}_n^a = \bar{X}\{|\bar{X}| \geq n^{-1/4}\} + a\{|\bar{X}| < n^{-1/4}\}.$$

Wariancja asymptotyczna \bar{X}_n^a dla $\theta = 0$ równa a^2 , natomiast $E_{\theta_n}(\bar{X}_n^a - \theta_n)^2 \rightarrow \infty$, gdy $\theta_n = n^{-1/4}$.

Dla dowolnego $\mathbf{s} \in R^p$, $\beta_n = -n^{-1/2}\mathbf{s}$

$$\sup_{\beta \in R^p} E_{\beta} \ell(n^{1/2}(\hat{\beta} - \beta)) \geq E_{\beta_n}(\ell(n^{1/2}(\hat{\beta} - \beta_n))) \geq$$

$$\ell(-n^{1/2}\beta_n)P_{\beta_n}(r(\hat{\beta}) = 0) = \ell(\mathbf{s})P_{\beta_n}(r(\hat{\beta}) = 0)$$

ale

$$P_0(r(\hat{\beta}) = 0) \rightarrow 1$$

i model liniowy jest modelem Asymptotycznie Lokalnie Normalnym (LAN)
 \Rightarrow ciąg P_{β_n} jest kontygualny względem P_0 . Zatem

$$P_{\beta_n}(r(\hat{\beta}) = 0) \rightarrow 1.$$

\mathbf{s} -dowolny, zatem $\sup_{\beta \in R^p} E_{\beta} \ell(n^{1/2}(\hat{\beta} - \beta)) \geq \sup_{\mathbf{s} \in R^p} \ell(\mathbf{s})$.

Twierdzenie prawdziwe, gdy supremum brane po otoczeniach zera $\theta \in K(0, \rho_n)$ takich, że $n^{1/2}\rho_n \rightarrow \infty$.

Eksperyment symulacyjny dla modelu liniowego, $p = 8$, $\Sigma_\varepsilon = \mathbf{I}$, ,
 $\mathbf{x}_1 \sim N(0, \Sigma)$, $\Sigma_{\mathbf{x}} = (0.5^{|i-j|})$.

Porównanie estymatora MNK z estymatorem SCAD2 (Fan i Li (2001):
wersja regularyzowanego estymatora MNK, mająca własność zgodności.

$\beta_n = \beta_0 + (\gamma/\sqrt{n})(0, 0, 1, 1, 0, 1, 1, 1)'$, $\beta_0 = (3, 1.5, 0, 0, 2, 0, 0, 0)'$,
 $n = 60, 120, 240, 480, 960$.


Relative Mean Squared Error:

$$E(\hat{\beta} - \beta)'(\hat{\beta} - \beta)) / E(\hat{\beta}_{MNK} - \beta_{MNK})'(\hat{\beta}_{MNK} - \beta_{MNK})$$

Model Relative Error: $Me(\hat{\beta}) / Me(\hat{\beta}_{MNK})$, gdzie

$$Me(\hat{\beta}) = (\hat{\beta} - \beta)' \Sigma (\hat{\beta} - \beta).$$

Median Relative Model Error of SCAD2



Relative Mean Squared Error of SCAD2

