

Kryterium minimalnej p-wartości ilorazu wiarygodności

Porównanie p-wartości ilorazu wiarygodności oraz obiektywnych czynników Bayesa w modelach liniowych

Piotr Pokarowski i Jan Mielniczuk

Inst. Inf. UW

IPI PAN, MINI PW

Przykład = buduj model lin dla danych "samochody"

$$\text{Zużycie Paliwa} = \beta_0 + \beta_1 \text{Masa} + \beta_2 \text{PojemuSiln.} + \beta_3 \text{Moc} + \dots$$

- Policzmy p-wartość testu F (\Leftrightarrow ilorazm wiarygodności) dla każdego modelu (podzbiorem predyktorów).
- Sprawdźmy jaki jest związek $P(>F)$ i BIC, AIC
- Okazało się, że $\text{cor}(P(>F), \text{BIC}) \approx 0.99$
- Dlaczego tak jest?

F, G dystrybuanty, $p(t|F) := 1 - F(t)$, $T \sim G$

$p(T|F)$ - p -wartość T przy hipotezie F

$X_{n, \text{full}}$ - plan modelu pełnego $n \times p_{\text{full}}$

o - model minimalny (np. złożony tylko ze stałej)

$o \subseteq j \subseteq \text{full}$

$$j: \quad y_n = X_{nj} \beta_j + \varepsilon_n, \quad \varepsilon_n \sim N(0, \sigma^2 I_n)$$

X_{nj} - plan o kolumnach ze zbioru j

$$S_{nj} := y_n^T (I - H_{nj}) y_n = \|y_n - X_{nj} \hat{\beta}_j\|^2$$

$$\text{Dewiacja} := 2 \log \frac{f_{\hat{\theta}_j}}{f_{\hat{\theta}_o}}$$

σ^2 znana

$$D_{nj} := 2 \log \frac{f_{\hat{\beta}_j}(y_n)}{f_{\hat{\beta}_0}(y_n)} = \frac{S_{n0} - S_{nj}}{\sigma^2}$$

 σ^2 nieznaną

$$D_{nj} := 2 \log \frac{f_{\hat{\beta}_j \hat{\sigma}^2}(y_n)}{f_{\hat{\beta}_0 \hat{\sigma}^2}(y_n)} = -n \log \frac{S_{nj}}{S_{n0}} \sim D_{p_0, p_j, n}$$

$$\Leftrightarrow R_{nj}^2 := 1 - \frac{S_{nj}}{S_{n0}} \sim B_{\frac{p_j - p_0}{2}, \frac{n - p_j}{2}}$$

$$\Leftrightarrow F_{nj} = \frac{(S_{n0} - S_{nj}) / (p_j - p_0)}{S_{nj} / (n - p_j)} \sim F_{p_j - p_0, n - p_j}$$

MPVC (minimal p-value criterion)

$$M_n = \operatorname{argmin}_j p(D_{nj} | D_{p_0, p_j, n}), \quad p(D_{n0} | D_{p_0, p_0, n}) := \frac{1}{n}$$

$$= \operatorname{argmin}_j p(D_{nj} | \chi_{p_j - p_0}^2), \quad p(D_{n0} | \chi_0^2) := \frac{1}{n}$$

Aproksymacja ogonów rozkładów χ^2 i B

$$(1) \quad \forall p \geq 1 \quad p(x | \chi_p^2) = e^{-x/2} \left(\frac{x}{2}\right)^{\frac{p}{2}-1} \Gamma^{-1}\left(\frac{p}{2}\right) \left[1 + O\left(\frac{1}{x}\right)\right], \quad x \rightarrow \infty$$

$$(2) \quad x > \frac{a-1}{a+b} \quad p(x | B_{a,b}) = (1-x)^b (bx)^{a-1} \Gamma^{-1}(a) \left[1 + O\left(\frac{1}{b}\right)\right], \quad b \rightarrow \infty$$

Jeśli $D_{nj} = d_j n + o_p(n)$, to

σ^2 znana
$$n p(D_{nj} | \chi_{p_j-p_0}^2) = e^{-D_{nj}/2} n^{\frac{p_j-p_0}{2}} c_1(p_j-p_0, d_j) \left[1 + O_p\left(\frac{1}{n}\right)\right]$$

σ^2 nieznaną
$$n p(D_{nj} | \mathcal{D}_{p_0, p_j, n}) = e^{-D_{nj}/2} n^{\frac{p_j-p_0}{2}} c_2(p_0, p_j, d_j) \left[1 + O_p\left(\frac{1}{n}\right)\right]$$

$$\left\{ \begin{array}{l} d = -n \log(1-x) \\ e^{-d/n} = 1-x \end{array} \right\} \left\{ S = D_{nj} - (p_j - p_0) \log n \right\}$$

$$-2 \log n p(D_{nj} | \chi_{p_j-p_0}^2) = S + \text{const} + O_p\left(\frac{1}{n}\right)$$

Regularny plan \Rightarrow regularne dewiacje \Rightarrow zgodność MPVC

$$(1) \exists 0 \leq t \leq \text{full} \quad y_n = X_{nt} \beta_t + \varepsilon_n, \quad \varepsilon_n \sim N(0, \sigma^2 I_n)$$

(2) t jest minimalnym w sensie "c" modelem spełniającym (1)

$$(3) \forall j \neq t \quad \frac{1}{n} X_{n,t;j}^T (I - H_{n,j}) X_{n,t;j} \rightarrow \Sigma_j > 0$$

(Casella et. al. Ann. Stat. 2009)

Uwaga (3) słabszy od "klasycznego"

$$(4) \frac{1}{n} X_{n,\text{full}}^T X_{n,\text{full}} \rightarrow \Sigma_{\text{full}} > 0 \quad (\text{Nishii, Ann. Stat. 1984})$$

Wnioski

- (1) $\frac{1}{n} S_{nj} \xrightarrow{\text{a.s.}} b_j^2 + \sigma^2$, $b_j^2 = \beta_{t_{1j}}^T \Sigma_j \beta_{t_{1j}}$
- (2) σ^2 znana $\frac{1}{n} D_{nj} \xrightarrow{\text{a.s.}} \frac{b_0^2 - b_j^2}{\sigma^2} =: d_j$
- (3) σ^2 nieznaną $\frac{1}{n} D_{nj} \xrightarrow{\text{a.s.}} \log \frac{b_0^2 + \sigma^2}{b_j^2 + \sigma^2} =: d_j$

Dewiacje (D_{nj}) są regularne

- (1) $\forall j \quad D_{nj} = d_j n + o_P(n)$
- (2) $\forall j \geq t \quad D_{nj} - D_{nt} \xrightarrow{d} \chi_{p_j - p_t}^2$

Tw Jeśli dewiacje są regularne, to $\mathbb{P}(M_n = t) \rightarrow 1$.

Obiektywne czynniki Bayesa (BF - Bayes Factor)

- wykorzystują obiektywne (objective, noninformative, reference) rozkłady a priori

$$B_{1/0} = \frac{\int f(y|\theta_1) \pi_1(\theta_1) d\theta_1}{\int f(y|\theta_0) \pi_0(\theta_0) d\theta_0}$$

jeśli $j \geq 0$, to często wymaga się "zgodności" π i π_1 :

$$\begin{aligned} B_{j/0} &= \frac{\int f(y|\theta_1, \theta_2) \pi(\theta_1, \theta_2) d\theta_1 d\theta_2}{\int f(y|\theta_1, \theta_2^0) \pi_1(\theta_1) d\theta_1} \\ &= \frac{\int f(y|\theta_1, \theta_2) \pi_1(\theta_1) \pi_{2/1}(\theta_2|\theta_1) d\theta_1 d\theta_2}{\int f(y|\theta_1, \theta_2^0) \pi_1(\theta_1) d\theta_1} \end{aligned}$$

Obiektywne czynniki Bayesa dla modeli lin - σ^2 nieznaną

$$BF = e^S c_k [1 + o_p(1)]$$

$$2S = D_{nj} - (p_j - p_0) \log n = -n \log \frac{RSS}{TSS} - (p_j - p_0) \log n$$

$S \Leftrightarrow$ kryterium Schwarz

c_k zależy od rodzaju BF

Fisher Factor $FF := \frac{1}{n p(D_{nj} | D_{p_0, p_j, n})} = e^S c_2 [1 + o_p(\frac{1}{n})]$

Porównanie $c_k \equiv c_k(p, \frac{RSS}{TSS})$

$$r = \frac{RSS}{TSS}$$

- (1) Kass & Wasserman, JASA 1995
 Pauler, Biometrika 1998

Unit information prior $c_1 = 1$

Jeffreys prior $c_2 = 2^{p/2} \Gamma(\frac{p+1}{2}) / \Gamma(\frac{1}{2})$

- (2) Zellner & Sioo, Bayesian Statistics 1980

= fractional BF O'Hagan, JRSS B, 1995

$$c_3 = 2^{p/2} \Gamma(\frac{p+1}{2}) r^{\frac{p+3}{2}} / \Gamma(\frac{1}{2})$$

- (3) Berger & Pericchi, JASA 1996

Intrinsic BF $c_4 = \pi^{-1} r^{\frac{1}{2}} (p+2)^{\frac{p}{2}} B(\frac{1}{2}, \frac{p+1}{2}) \text{hyp1f1}(\frac{p+1}{2}; \frac{p+2}{2}; \frac{p+2}{2} (1-\frac{1}{r}))$

Casella et al, Ann. Stat. 2009

(4) Statistic based BF
 V. Johnson, JRSS B 2005

$$c_5 = r^{\frac{p+1}{2}} \left[\frac{p}{e(1-r)} \right]^{\frac{p}{2}}$$

(5) FF

$$c_6 = r^{\frac{p+1}{2}} \left[\frac{2}{1-r} \right]^{\frac{p-2}{2}} \Gamma\left(\frac{p}{2}\right)$$

Numeryczne porównanie funkcji $c_1 - c_6$:

- Zamieniamy c_k na wektor v_k .

- Porównujemy wektory v_i, v_j odległością Canberra

$$CBR(v_i, v_j) = \sum_{l=1}^m \frac{|v_{li} - v_{lj}|}{|v_{li} + v_{lj}|} \stackrel{!}{=} CBR(v_i^{-1}, v_j^{-1})$$

lub $mCBR(v_i, v_j) = \text{med}_l \dots$

FF jest medoidem dla (CBR_{ij}) i $(mCBR_{ij})$