

Estymator wariancji i bootstrap

- Najwcześniejsze użycie bootstrap (wtórnego próbkowania) Efron(1979)
- Z próby n obserwacji wybieramy B sztucznych próbek (bootstrap samples) o liczebności n losując z oryginalnej próby *ze zwracaniem*
- Dla każdej z tak wylosowanych prób liczymy estymator $\hat{\theta}_j^*$
- Liczymy średnią z tak policzonych estymatorów $\hat{\theta}^*$

- Obliczamy estymator wariancji ze standardowego wzoru:

$$\hat{\Sigma} = \left(\frac{1}{B-1} \sum_{j=1}^B (\hat{\theta}_j^* - \hat{\theta}^*) (\hat{\theta}_j^* - \hat{\theta}^*)' \right)$$

- Ten sposób użycia bootstrapu obecnie wyszedł raczej z użycia - zazwyczaj nie da się uzyskać w ten sposób estymatorów efektywniejszych niż standardowe estymatory zgodne

Korekta obciążenia i bootstrap

- Szacujemy estymator bootstrap parametrów

$$\hat{\theta}^* = \frac{1}{B} \sum_{j=1}^B \hat{\theta}_j^*$$

- Szacujemy obciążenie estymatora

$$b^* \left(\hat{\theta} \right) = \hat{\theta}^* - \hat{\theta}$$

- Tworzymy oszacowanie skorygowane o obciążenie

$$\tilde{\theta} = \hat{\theta} - b^* \left(\hat{\theta} \right) = 2\hat{\theta} - \hat{\theta}^*$$

- Stosując tę procedurę zakładamy, że obciążenie estymatora *nie zależy* od wektora nieznanymi parametrów
- Jeśli obciążenie zależy od wektora nieznanymi parametrów, wtedy stosując bootstrap możemy często uzyskać redukcję obciążenia ale za cenę spadku efektywności esymacji.
- Niekiedy spadek tej efektywności jest tak duży, że rośnie błąd średniokwadratowy $MSE = E \left(\hat{\theta} - \theta \right)$.

Przedziały ufności i bootstrap

- Jednym z bardzo popularnych zastosowań bootstrap jest tworzenie przedziałów ufności
- Teoretycznie najlepszą metodą jest metoda procentowego t , przedział ufności

$$\left[\hat{\theta} - \hat{s}_{\theta} t_{1-\alpha/2}^*, \hat{\theta} + \hat{s}_{\theta} t_{\alpha/2}^* \right]$$

gdzie \hat{s}_{θ} jest błędem standardowym $\hat{\theta}$ a t_{δ}^* jest kwantylem δ bootstrapowanej statystyki

$$t_j^* = \frac{\hat{\theta}_j^* - \hat{\theta}^*}{se(\hat{\theta}_j^*)}$$

- Inną metodą jest prosty bootstrapowy przedział ufności

$$\left[\hat{\theta} - se^* t_{1-\alpha/2}, \hat{\theta} + se^* t_{\alpha/2} \right]$$

w którym wykorzystujemy standardowy rozkład t -studenta ale oszacowania błędów standardowych są z bootstrap

- Można w tym przypadku zastosować także korektę obciążania

Testowanie hipotez i bootstrap

- Obecnie najpopularniejszym zastosowaniem bootstrap jest testowanie hipotez
- Bootstrapowa wartość p dla statystyki τ jest równa

$$p^* (\hat{\tau}) = \frac{1}{B} \sum_{j=1}^B I (r_j^* > \hat{\tau})$$

gdzie $I (\cdot)$ jest funkcją indykatorową (charakterystyczną)

- Można to także zapisać jako

$$p^* (\hat{\tau}) = 1 - \hat{F}^* (\hat{\tau})$$

gdzie $\hat{F}^*(\cdot)$ jest dystrybuantą empiryczną uzyskaną z bootstrapu

Warunki poprawności testów bootstrap

- Dla szczególnego przypadku można pokazać, że policzone na podstawie bootstrap α jest dokładnie równe prawdziemu α (test jest dokładny) w małych próbach
- Warunki:
 - rozkład statystyki nie zależy od parametrów (*pivotal statistics*)
 - B jest takie, że $\alpha(B + 1)$ jest liczbą naturalną
- Przykładami testów o tych własnościach jest test Durbina-Watsona, test ARCH, test Jarque-Bera
- W większości przypadków mamy jednak do czynienia z testami, których

rozkłady statystyk są jedynie asymptotycznie niezależne od wielkości parametrów

- Bootstrapowane wartości krytyczne w tym przypadku dążą do prawdziwych wartości krytycznych dla $n \rightarrow \infty$ ale nie dla $B \rightarrow \infty$
- jeśli dystrybucja testu $F(\cdot)$ nie zależy silnie od nieznanymi wielkości parametrów wtedy bootstrap powinien dobrze działać
- jeśli $F(\cdot)$ silnie zależy od nieznanymi parametrów bądź parametry są estymowane nieefektywnie lub z dużym obciążeniem, wtedy bootstrap może działać źle
- jeśli mamy do wyboru kilka statystyk (np LM , LR , W), to powinniśmy użyć tej, która najslabiej zależy od nieznanymi parametrów
- różne metody wtórnego próbkowania (bootstrap) mogą mieć bardzo różne własności w małych próbach
- testy bazowane na bootstrapie nie są słabsze od testów bazowanych na wynikach asymptotycznych przy założeniu, że B jest wystarczająco duże

Bootstrapowanie modelu regresji

- Założenie

$$y_t = \mathbf{x}_t \boldsymbol{\beta} + \varepsilon_t$$

$$E(\varepsilon_t | \mathbf{x}_t) = 0$$

$$\varepsilon_t = IID(0, \sigma^2)$$

- Bootstrap na resztach

$$y_t^* = \mathbf{x}_t \boldsymbol{\beta} + \varepsilon_t^*$$

$$\varepsilon_t^* \sim EDF(\hat{\varepsilon}_t)$$

gdzie $\ddot{\varepsilon}_t = \left(\frac{n}{n-k}\right)^{\frac{1}{2}} e_t$ (korekta na liczbę stopni swobody) a EDF jest empiryczną dystrybuantą $\ddot{\varepsilon}_t$.

- Bootstrap parametryczny. Identyczny jak w poprzednim przypadku ale

$$\varepsilon_t^* \sim NID(0, s^2)$$

- Wild bootstrap

$$y_t^* = \mathbf{x}_t \boldsymbol{\beta} + f(\hat{\varepsilon}_t) v_t^*$$

v_t jest zmienną losową o wartości oczekiwanej 0 i wariancji 1 (np zmienna binarna $-1, 1$)

$$f(\hat{\varepsilon}_t) = \frac{\hat{\varepsilon}_t}{(1 - h_t)^{\frac{1}{2}}}$$

gdzie h_t jest t -wartością diagonalną macierz $H = X (X' X)^{-1} X'$.

Metoda ta jest odporna na heteroskedastyczność

- Bootstrap na parach:
 - wybieramy losowo pary $[y_t \quad x_t]$

Bootstrap w modelach ze skorelowanymi błędami losowymi

- Sitowy bootstrap (sieve bootstrap): zakładamy że błędy losowe zachowują się zgodnie z procesem $AR(p)$
 1. Oszacuj model $y_t = \mathbf{x}_t \boldsymbol{\beta} + \varepsilon_t$
 2. Oszacuj model $AR(p)$

$$\hat{\varepsilon}_t = \sum_{i=1}^p \rho_i \hat{\varepsilon}_{t-i} + u_t \quad (1)$$

3. Wygeneruj błędy bootstrapowane

$$\varepsilon_t^* = \sum_{i=1}^p \rho_i \varepsilon_{t-i}^* + u_t^*$$

gdzie u_t^* pochodzą z przeskalowanej dystrybuanty empirycznej reszt **1**

- Bootstrap blokowy. Dzielimy wielkości, które mamy wtórnie próbkować na s bloków b następujących po sobie obserwacji. Mogą to być zarówno reszty jak i pary $\begin{bmatrix} y_t & \mathbf{x}_t \end{bmatrix}$. Następnie losujemy bloki.

Jackknife

- Jackknife jest inną metodą wtórnego próbkowania
- Wtórne próbkowanie polega na stworzeniu n próbek poprzez usunięcie z pierwotnej próby j -tej obserwacji
- Estymatory $\hat{\theta}_j^*$ tworzymy dla tak powstałych próbek
- Używając tej metody możemy uzyskać skonstruować podobnie jak w przypadku bootstrap korektę obciążenia i estymator wariancji