

Εκτίμηση αθροιστικής συνάρτησης κατανομής

Μη Παραμετρική Στατιστική

Παναγιώτης Παπασταμούλης
Αναπληρωτής Καθηγητής
Τμήμα Στατιστικής ΟΠΑ

papastamoulis@aueb.gr

2026




Περιεχόμενα: Εκτίμηση αθροιστικής συνάρτησης κατανομής και συναρτησιακών


- 1 Εκτίμηση αθροιστικής συνάρτησης κατανομής
 - Εμπειρική συνάρτηση κατανομής
 - Ζώνη εμπιστοσύνης DKW
 - Σημειακά διαστήματα εμπιστοσύνης για την $F(x)$
- 2 Έλεγχος καλής προσαρμογής Kolmogorov-Smirnov
- 3 Εκτίμηση συναρτησιακών της συνάρτησης κατανομής
 - Στατιστικά συναρτησιακά και εκτιμητές αντικατάστασης
 - Συνάρτηση επιρροής και μη παραμετρική μέθοδος Δέλτα

Nerve data

- Cox and Lewis (1966)
- $n = 799$ χρόνοι αναμονής μεταξύ διαδοχικών συσπάσεων νευρικής ίνας



Ιστόγραμμα δεδομένων



Εμπειρική συνάρτηση κατανομής
+ 95% ζώνη εμπιστοσύνης

Εκτίμηση αθροιστικής συνάρτησης κατανομής

Έστω X_1, \dots, X_n τυχαίο δείγμα από κάποια (άγνωστη) συνάρτηση κατανομής F (διακριτή ή συνεχή).

Ορισμός (Εμπειρική συνάρτηση κατανομής)

Η εμπειρική συνάρτηση κατανομής ορίζεται ως

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n I\{X_i \leq x\}. \quad (1)$$

Στον παραπάνω ορισμό:

$$I\{X_i \leq x\} = \begin{cases} 1, & \text{αν } X_i \leq x \\ 0, & \text{διαφορετικά.} \end{cases}$$

Παράδειγμα ($n = 10$)

- Δεδομένα:

$(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$

- Διατεταγμένο δείγμα

$(-1.13, -0.90, -0.24, -0.14, -0.08, 0.13, 0.18, 0.71, 1.59, 1.98)$


- Υπολογισμός $\hat{F}_n(x)$

x	$\hat{F}_n(x)$
$(-\infty, -1.13)$	0
$[-1.13, -0.90)$	1/10
$[-0.90, -0.24)$	2/10
$[-0.24, -0.14)$	3/10
$[-0.14, -0.08)$	4/10
$[-0.08, 0.13)$	5/10
$[0.13, 0.18)$	6/10
$[0.18, 0.71)$	7/10
$[0.71, 1.59)$	8/10
$[1.59, 1.98)$	9/10
$[1.98, \infty)$	1

- Παράδειγμα: $\hat{F}_n(1.64) = 0.9$ (πραγματική τιμή: $F(1.64) \approx 0.95$)


Παράδειγμα ($n = 10$)

Δεδομένα: $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$




Παράδειγμα ($n = 10$)

Δεδομένα: $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$




Παράδειγμα ($n = 100$)




Παράδειγμα: $\hat{F}_n(1.64) = 0.97$ (πραγματική τιμή: $F(1.64) \approx 0.95$)

Παράδειγμα ($n = 100$)



Παράδειγμα: $\hat{F}_n(1.64) = 0.97$ (πραγματική τιμή: $F(1.64) \approx 0.95$)

Παράδειγμα ($n = 1000$)



Παράδειγμα: $\hat{F}_n(1.64) = 0.95$ (πραγματική τιμή: $F(1.64) \approx 0.95$)

Ιδιότητες Εμπειρικής Συνάρτησης Κατανομής

1 Μέση τιμή και διασπορά

$$E\hat{F}_n(x) = F(x) \quad \text{και} \quad \text{Var}\hat{F}_n(x) = \frac{F(x)(1 - F(x))}{n}$$

για κάθε $x \in \mathbb{R}$.

2 Θεμελιώδες θεώρημα Glivenko-Cantelli. Για κάθε συνάρτηση κατανομής F ισχύει ότι:

$$\sup_{x \in \mathbb{R}} \left| \hat{F}_n(x) - F(x) \right| \xrightarrow{a.s.} 0$$

3 Ανισότητα DKW (Dvoretzky-Kiefer-Wolfowitz). Για κάθε $\varepsilon > 0$:

$$P \left(\sup_{x \in \mathbb{R}} \left| \hat{F}_n(x) - F(x) \right| > \varepsilon \right) \leq 2e^{-2n\varepsilon^2}$$

(για όλα τα n).

Απόδειξη για το (1)

- Για δοθέν $x \in \mathbb{R}$, έστω η τυχαία μεταβλητή

$$Y = n\hat{F}_n(x) = \sum_{i=1}^n \mathbf{I}\{X_i \leq x\} = \text{«πόσα } X \text{ από τα } n \text{ είναι } \leq x\text{»}.$$

Απόδειξη για το (1)

- Για δοθέν $x \in \mathbb{R}$, έστω η τυχαία μεταβλητή

$$Y = n\widehat{F}_n(x) = \sum_{i=1}^n \mathbf{I}\{X_i \leq x\} = \text{«πόσα } X \text{ από τα } n \text{ είναι } \leq x\text{»}.$$

- Ξεκάθαρα: $Y \sim \mathcal{B}(n, F(x))$.

Απόδειξη για το (1)

- Για δοθέν $x \in \mathbb{R}$, έστω η τυχαία μεταβλητή

$$Y = n\hat{F}_n(x) = \sum_{i=1}^n \mathbf{I}\{X_i \leq x\} = \text{«πόσα } X \text{ από τα } n \text{ είναι } \leq x\text{»}.$$

- Ξεκάθαρα: $Y \sim \mathcal{B}(n, F(x))$.
- Συνεπώς για τη μέση τιμή

$$E(Y) = nF(x), \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$E(n\hat{F}_n(x)) = nF(x), \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$E(\hat{F}_n(x)) = F(x), \quad \forall x \in \mathbb{R}$$

Απόδειξη για το (1)

- Για δοθέν $x \in \mathbb{R}$, έστω η τυχαία μεταβλητή

$$Y = n\widehat{F}_n(x) = \sum_{i=1}^n \mathbf{I}\{X_i \leq x\} = \text{«πόσα } X \text{ από τα } n \text{ είναι } \leq x\text{»}.$$

- Ξεκάθαρα: $Y \sim \mathcal{B}(n, F(x))$.
- Συνεπώς για τη μέση τιμή

$$E(Y) = nF(x), \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$E(n\widehat{F}_n(x)) = nF(x), \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$E(\widehat{F}_n(x)) = F(x), \quad \forall x \in \mathbb{R}$$

- Διασπορά

$$\text{Var}(Y) = nF(x)(1 - F(x)), \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$n^2 \text{Var}(\widehat{F}_n(x)) = nF(x)(1 - F(x)), \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$\text{Var}(\widehat{F}_n(x)) = \frac{F(x)(1 - F(x))}{n}, \quad \forall x \in \mathbb{R}.$$

Συνέπεια του (3): Μία ζώνη εμπιστοσύνης για την F

Μέσω της ανισότητας DKW μπορούμε να κατασκευάσουμε μία **ζώνη εμπιστοσύνης** για τη συνάρτηση κατανομής (F).

- Έστω $\alpha \in (0, 1)$.
- Ορίζουμε

$$L_n(x) = \max \left\{ \hat{F}_n(x) - \sqrt{\frac{1}{2n} \log \frac{2}{\alpha}}, 0 \right\}$$
$$U_n(x) = \min \left\{ \hat{F}_n(x) + \sqrt{\frac{1}{2n} \log \frac{2}{\alpha}}, 1 \right\}$$

Λήμμα ($100(1 - \alpha)\%$ DKW ζώνη εμπιστοσύνης για την F)

Για κάθε F και για κάθε n

$$P(L_n(x) \leq F(x) \leq U_n(x) \text{ για κάθε } x) \geq 1 - \alpha.$$

Απόδειξη

Από την ανισότητα DKW για $\varepsilon_n^2 = \frac{1}{2n} \log \frac{2}{\alpha}$ προκύπτει ότι

$$P \left(\sup_{x \in \mathbb{R}} \left| \widehat{F}_n(x) - F(x) \right| > \varepsilon_n \right) \leq 2e^{-2n\varepsilon_n^2} \Leftrightarrow$$

$$P \left(\left| \widehat{F}_n(x) - F(x) \right| > \varepsilon_n \right) \leq 2e^{-2n \frac{1}{2n} \log \frac{2}{\alpha}}, \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$P \left(\left| \widehat{F}_n(x) - F(x) \right| > \varepsilon_n \right) \leq \alpha, \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$P \left(\left| \widehat{F}_n(x) - F(x) \right| \leq \varepsilon_n \right) \geq 1 - \alpha, \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$P \left(-\varepsilon_n \leq \widehat{F}_n(x) - F(x) \leq \varepsilon_n \right) \geq 1 - \alpha, \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$P \left(-\widehat{F}_n(x) - \varepsilon_n \leq -F(x) \leq -\widehat{F}_n(x) + \varepsilon_n \right) \geq 1 - \alpha, \quad \forall x \in \mathbb{R} \Leftrightarrow$$

$$P \left(\widehat{F}_n(x) - \varepsilon_n \leq F(x) \leq \widehat{F}_n(x) + \varepsilon_n \right) \geq 1 - \alpha, \quad \forall x \in \mathbb{R}$$

η απόδειξη ολοκληρώνεται θέτοντας $L(x) = \max\{\widehat{F}_n(x) - \varepsilon_n, 0\}$ και $U(x) = \min\{\widehat{F}_n(x) + \varepsilon_n, 1\}$.

Παράδειγμα: 90% ζώνη εμπιστοσύνης ($n = 10$)

- $n = 10$

- $\alpha = 0.1$


- $\varepsilon_n = \sqrt{\frac{1}{2n} \log \frac{2}{\alpha}} \approx 0.387$

- $L_n(x) = \max\{\widehat{F}_n(x) - 0.387, 0\}$


- $U_n(x) = \min\{\widehat{F}_n(x) + 0.387, 1\}$

x	$\widehat{F}_n(x)$	$L_n(x)$	$U_n(x)$
$(-\infty, -1.13)$	0	0	0.387
$[-1.13, -0.90)$	0.1	0	0.487
$[-0.90, -0.24)$	0.2	0	0.587
$[-0.24, -0.14)$	0.3	0	0.687
$[-0.14, -0.08)$	0.4	0.013	0.787
$[-0.08, 0.13)$	0.5	0.113	0.887
$[0.13, 0.18)$	0.6	0.213	0.987
$[0.18, 0.71)$	0.7	0.313	1
$[0.71, 1.59)$	0.8	0.413	1
$[1.59, 1.98)$	0.9	0.513	1
$[1.98, \infty)$	1	0.613	1

Παράδειγμα: 90% ζώνη εμπιστοσύνης ($n = 10$)



Παράδειγμα: 90% ζώνη εμπιστοσύνης ($n = 100$)



Διαστήματα εμπιστοσύνης για την $F(x)$ σε δοθέν x

- Θέλουμε να καθορίσουμε ℓ_n, u_n τέτοια ώστε

$$P(\ell_n \leq F(x) \leq u_n) \geq 1 - \alpha$$

- Όμως

$$Y = n\hat{F}_n(x) \sim \mathcal{B}(n, F(x))$$

- Οπότε το πρόβλημα μπορεί να αναδιατυπωθεί ως εξής:
 - ▶ Παρατηρούμε $Y \sim \mathcal{B}(n, p)$
 - ▶ $p = F(x) \in [0, 1]$ (άγνωστη παράμετρος)
 - ▶ και θέλουμε να βρούμε διάστημα εμπιστοσύνης για το p .
- Μερικές τεχνικές
 - 1 Clopper-Pearson: Ακριβές Δ.Ε. μέσω της διωνυμικής κατανομής
 - 2 Wald: ασυμπτωτικό Δ.Ε.
 - 3 Wilson: ασυμπτωτικό Δ.Ε.
 - 4 μετασχηματισμός arcsin: ασυμπτωτικό Δ.Ε. με σταθεροποίηση (ασυμπτωτικής) διασποράς

Ασυμπτωτικό ΔΕ (Wald)

- Έστω $\hat{p}_n = Y/n$. Από Κεντρικό Οριακό Θεώρημα

$$\sqrt{n} \frac{\hat{p}_n - p}{\sqrt{p(1-p)}} \xrightarrow{d} \mathcal{N}(0, 1)$$

Ασυμπτωτικό ΔΕ (Wald)

- Έστω $\hat{p}_n = Y/n$. Από Κεντρικό Οριακό Θεώρημα

$$\sqrt{n} \frac{\hat{p}_n - p}{\sqrt{p(1-p)}} \xrightarrow{d} \mathcal{N}(0, 1)$$

- (Ασθενής) Νόμος Μεγάλων Αριθμών

$$p_n \xrightarrow{P} p$$

Ασυμπτωτικό ΔΕ (Wald)

- Έστω $\hat{p}_n = Y/n$. Από Κεντρικό Οριακό Θεώρημα

$$\sqrt{n} \frac{\hat{p}_n - p}{\sqrt{p(1-p)}} \xrightarrow{d} \mathcal{N}(0, 1)$$

- (Ασθενής) Νόμος Μεγάλων Αριθμών

$$p_n \xrightarrow{P} p$$

- Από όπου προκύπτει **(γιατί;)**

$$\sqrt{n} \frac{\hat{p}_n - p}{\sqrt{\hat{p}_n(1-\hat{p}_n)}} \xrightarrow{d} \mathcal{N}(0, 1)$$

Ασυμπτωτικό ΔΕ (Wald)

- Έστω $\hat{p}_n = Y/n$. Από Κεντρικό Οριακό Θεώρημα

$$\sqrt{n} \frac{\hat{p}_n - p}{\sqrt{p(1-p)}} \xrightarrow{d} \mathcal{N}(0, 1)$$

- (Ασθενής) Νόμος Μεγάλων Αριθμών

$$p_n \xrightarrow{P} p$$

- Από όπου προκύπτει **(γιατί;)**

$$\sqrt{n} \frac{\hat{p}_n - p}{\sqrt{\hat{p}_n(1-\hat{p}_n)}} \xrightarrow{d} \mathcal{N}(0, 1)$$

- Λύνοντας ως προς p προκύπτει ότι το τυχαίο διάστημα

$$\left[\hat{p}_n - z_{\alpha/2} \sqrt{\frac{\hat{p}_n(1-\hat{p}_n)}{n}}, \hat{p}_n + z_{\alpha/2} \sqrt{\frac{\hat{p}_n(1-\hat{p}_n)}{n}} \right]$$

είναι το $100(1-\alpha)\%$ Α.Δ.Ε ίσων ουρών για το $p = F(x)$.

Παράδειγμα ($n = 10$)

- Δεδομένα:

$$(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$$


- Να υπολογιστεί το 90% ΑΔΕ ίσων ουρών του Wald για την $F(1.64)$.

x	$\hat{F}_n(x)$
$(-\infty, -1.13)$	0
$[-1.13, -0.90)$	1/10
$[-0.90, -0.24)$	2/10
$[-0.24, -0.14)$	3/10
$[-0.14, -0.08)$	4/10
$[-0.08, 0.13)$	5/10
$[0.13, 0.18)$	6/10
$[0.18, 0.71)$	7/10
$[0.71, 1.59)$	8/10
$[1.59, 1.98)$	9/10
$[1.98, \infty)$	1


- Υπολογισμός $\hat{F}_n(x)$

- Είναι $\hat{p}_n = \hat{F}_n(1.64) = 0.9$, $\alpha = 0.1$, $z_{0.05} \approx 1.64$ και $n = 10$
- 90% ΑΔΕ για $F(1.64)$: $[0.744, 1.056]$
- Παρατηρήστε ότι τα άκρα του ΑΔΕ μπορεί να υπερβαίνουν τα όρια του παραμετρικού χώρου.

Παράδειγμα ($n = 10$)



Παράδειγμα ($n = 100$): $[0.942, 0.998]$



Έλεγχος καλής προσαρμογής Kolmogorov-Smirnov

Ενδιαφέρει ο έλεγχος της

$$H_0 : F(x) = F_0(x), \forall x \in \mathbb{R}, \quad \text{VS} \quad H_1 : \exists x : F(x) \neq F_0(x).$$

- Ορίζουμε ως στατιστική συνάρτηση Kolmogorov-Smirnov την

$$D_n = \sup_{x \in \mathbb{R}} \left| \widehat{F}_n(x) - F(x) \right|.$$

- «Μεγάλες» τιμές της $D_n \Rightarrow$ απόρριψη H_0
- Ασυμπτωτικά,

$$P(\sqrt{n}D_n > k) \xrightarrow{H_0} 2 \sum_{j=1}^{\infty} (-1)^{j+1} e^{-2j^2 k^2}$$

- (Ασυμπτωτικό) p-value:

$$2 \sum_{j=1}^{\infty} (-1)^{j+1} e^{-2j^2 k^2},$$

όπου k η πραγματοποίηση της $\sqrt{n}D_n$ στο δείγμα.

Η βασική ιδέα για την απόδειξη

Λήμμα

Η κατανομή της τυχαίας μεταβλητής $\sup_{x \in \mathbb{R}} |\hat{F}_n(x) - F(x)|$ δεν εξαρτάται από την F (αν F συνεχής).

- Αν $X_i \sim F$, τότε $U_i := F(X_i) \sim \mathcal{U}(0, 1)$
- Πράγματι, για $0 \leq t \leq 1$:

$$\begin{aligned}F_U(t) &:= \mathbb{P}(U_i \leq t) \\&= \mathbb{P}(F(X_i) \leq t) \\&= \mathbb{P}(X_i \leq F^{-1}(t)) \\&= F(F^{-1}(t)) \\&= t.\end{aligned}$$

Η βασική ιδέα για την απόδειξη

Συνοπώς

$$\begin{aligned}\sup_{x \in \mathbb{R}} \left| \widehat{F}_n(x) - F(x) \right| &= \sup_{t \in [0,1]} \left| \widehat{F}_n(F^{-1}(t)) - F(F^{-1}(t)) \right| \\ &= \sup_{t \in [0,1]} \left| \frac{1}{n} \sum_{i=1}^n \mathbf{I}\{X_i \leq F^{-1}(t)\} - t \right| \\ &= \sup_{t \in [0,1]} \left| \frac{1}{n} \sum_{i=1}^n \mathbf{I}\{F(X_i) \leq t\} - t \right| \\ &= \sup_{t \in [0,1]} \left| \frac{1}{n} \sum_{i=1}^n \mathbf{I}\{U_i \leq t\} - t \right| \\ &= \sup_{t \in [0,1]} \left| \widehat{G}_n(t) - t \right|,\end{aligned}$$

όπου $\widehat{G}_n(\cdot)$ η εμπειρική συνάρτηση κατανομής των $U_i = F(X_i)$,
 $i = 1, \dots, n$.

Τι σημαίνει αυτό για το τεστ

Επειδή η κατανομή του D_n δεν εξαρτάται από το F :

- Οι κρίσιμες τιμές είναι καθολικές.
- Μπορούν να υπολογιστούν και να πινακοποιηθούν μία φορά για πάντα.
- Το τεστ ισχύει για **κάθε συνεχή κατανομή**.

Αυτό είναι το βασικό χαρακτηριστικό που καθιστά το τεστ Kolmogorov–Smirnov απαλλαγμένο από παραμέτρους (ελεύθερο κατανομής).

Σύνδεση με το Οριακό Αποτέλεσμα

Καθώς $n \rightarrow \infty$,

$$\sqrt{n} D_n \rightarrow \sup_{0 \leq u \leq 1} |B(u)|,$$

όπου $B(u)$ είναι μια «γέφυρα Brown» (Brownian bridge)¹.

Αυτό οδηγεί στην **κατανομή Kolmogorov**, η οποία παρέχει τις ασυμπτωτικές κρίσιμες τιμές του τεστ.

¹ειδική περίπτωση Gaussian process

Παράδειγμα ($n = 10$)

- $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$
- Να ελεγχθεί η υπόθεση ($\alpha = 5\%$)

$$H_0 : F(x) = F_0(x), \forall x \in \mathbb{R}, \quad \text{VS} \quad H_1 : \exists x : F(x) \neq F_0(x),$$

όπου $F_0(x)$ η συνάρτηση κατανομής της $\mathcal{N}(0, 1)$.


x	$\widehat{F}_n(x)$
$(-\infty, -1.13)$	0
$[-1.13, -0.90)$	1/10
$[-0.90, -0.24)$	2/10
$[-0.24, -0.14)$	3/10
$[-0.14, -0.08)$	4/10
$[-0.08, 0.13)$	5/10
$[0.13, 0.18)$	6/10
$[0.18, 0.71)$	7/10
$[0.71, 1.59)$	8/10
$[1.59, 1.98)$	9/10
$[1.98, \infty)$	1

- Υπολογισμός $\widehat{F}_n(x)$

- Συνάρτηση κατανομής της $\mathcal{N}(0, 1)$: $F_0(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{t^2}{2}\right\} dt.$


Παράδειγμα (συνέχεια)

Αρκεί το στατιστικό να υπολογιστεί ως \max επί των $x = X_i$ και των $x = X_i - \varepsilon$ για μικρό ε .



Παράδειγμα (συνέχεια)

Αρκεί το στατιστικό να υπολογιστεί ως \max επί των $x = X_i$ και των $x = X_i - \varepsilon$ για μικρό ε .



Παράδειγμα (συνέχεια)

- Έστω

- ▶ $\widehat{F}_n(x_0^-) = \lim_{x \rightarrow x_0^-} \widehat{F}_n(x)$

- ▶ $D^-(x) = |\widehat{F}_n(x^-) - F_0(x)|$

- ▶ $D^+(x) = |\widehat{F}_n(x) - F_0(x)|$

- Για κάθε x στο παρατηρηθέν δείγμα υπολογίζουμε $D^-(x)$ και $D^+(x)$
- Η στατιστική συνάρτηση Kolmogorov-Smirnov ισούται με


$$D_n = \max_x \{D^-(x), D^+(x)\}.$$

Παράδειγμα (συνέχεια)

	x	$\widehat{F}_n(x^-)$	$\widehat{F}_n(x)$	$F_0(x)$	D^+	D^-
1	-1.130	0.000	0.100	0.129	0.029	0.129
2	-0.900	0.100	0.200	0.184	0.016	0.084
3	-0.240	0.200	0.300	0.405	0.105	0.205
4	-0.140	0.300	0.400	0.444	0.044	0.144
5	-0.080	0.400	0.500	0.468	0.032	0.068
6	0.130	0.500	0.600	0.552	0.048	0.052
7	0.180	0.600	0.700	0.571	0.129	0.029
8	0.710	0.700	0.800	0.761	0.039	0.061
9	1.590	0.800	0.900	0.944	0.044	0.144
10	1.980	0.900	1.000	0.976	0.024	0.076

- Συνεπώς $D_n = 0.205$.
- Η στήλη $F_0(x)$ υπολογίστηκε μέσω της $\text{pnorm}()$ στην R.

Παράδειγμα (συνέχεια)



- Είναι $k = \sqrt{n}D_n = \sqrt{10} \times 0.205 \approx 0.648$
- (Ασυμπτωτικό) p-value: $2 \sum_{j=1}^{\infty} (-1)^{j+1} e^{-2j^2 k^2} \approx 0.794 > 0.05$
- Αποτυγχάνουμε να απορρίψουμε την H_0 σε επίπεδο σημαντικότητας 5%.

Ορισμός

Έστω X μια τυχαία μεταβλητή από έναν πληθυσμό με αθροιστική συνάρτηση κατανομής $F(\cdot)$. Ονομάζεται **στατιστικό συναρτησιακό** μια απεικόνιση T , η οποία απεικονίζει την αθροιστική συνάρτηση F σε έναν πραγματικό αριθμό ή διάνυσμα.

Εκτίμηση συναρτησιακών της συνάρτησης κατανομής

- Ενδιαφερόμαστε για την εκτίμηση παραμέτρων που γράφονται ως συναρτήσεις της συνάρτησης κατανομής F , δηλαδή: $T(F)$ όπου T συνάρτηση της F .
 - ▶ **Μέσος:** $\mu = E(X_1)$ γράφεται ως

$$\mu = \int x dF = \begin{cases} \int x f(x) dx, & \text{αν } X_1 \text{ συνεχής} \\ \sum x f(x), & \text{αν } X_1 \text{ διακριτή} \end{cases}$$

όπου στην συνεχή περίπτωση: $f(x) = \frac{dF(x)}{dx}$ ενώ στην διακριτή περίπτωση $f(x) = P(X_1 = x) = F(x) - F(x^-)$.

- ▶ **(κάτω) α -ποσοσטיαίο σημείο:** $q_\alpha = F^{-1}(\alpha) = \inf\{x : F(x) \geq \alpha\}$.
- Εκτός από τη σημειακή εκτίμηση παραμέτρων, ενδιαφέρει και η συμπερασματολογία
 - ▶ Εκτίμηση διασποράς/τυπικών σφαλμάτων του εκτιμητή
 - ▶ Κατασκευή διαστημάτων εμπιστοσύνης για την παράμετρο.

Εκτιμητής αντικατάστασης (plug-in estimator)

Ορισμός (plug-in estimator)

Ο εκτιμητής αντικατάστασης (plug-in estimator) $\hat{\theta}_n$ της $\theta = T(F)$ ορίζεται ως

$$\hat{\theta}_n := T(\hat{F}_n).$$

Εκτιμητής αντικατάστασης (plug-in estimator)

Ορισμός (plug-in estimator)

Ο εκτιμητής αντικατάστασης (plug-in estimator) $\hat{\theta}_n$ της $\theta = T(F)$ ορίζεται ως

$$\hat{\theta}_n := T(\hat{F}_n).$$

- Ο εκτιμητής αντικατάστασης προκύπτει απλά αντικαθιστώντας την F με την \hat{F}_n στη συνάρτηση T .

Εκτιμητής αντικατάστασης (plug-in estimator)

Ορισμός (plug-in estimator)

Ο εκτιμητής αντικατάστασης (plug-in estimator) $\hat{\theta}_n$ της $\theta = T(F)$ ορίζεται ως

$$\hat{\theta}_n := T(\hat{F}_n).$$

- Ο εκτιμητής αντικατάστασης προκύπτει απλά αντικαθιστώντας την F με την \hat{F}_n στη συνάρτηση T .
- Σε πολλές περιπτώσεις παίρνουμε ως εκτιμητή το δειγματικό «εμπειρικό» ανάλογο της ποσότητας που μας ενδιαφέρει.

Εκτιμητής αντικατάστασης (plug-in estimator)

Ορισμός (plug-in estimator)

Ο εκτιμητής αντικατάστασης (plug-in estimator) $\hat{\theta}_n$ της $\theta = T(F)$ ορίζεται ως

$$\hat{\theta}_n := T(\hat{F}_n).$$

- Ο εκτιμητής αντικατάστασης προκύπτει απλά αντικαθιστώντας την F με την \hat{F}_n στη συνάρτηση T .
- Σε πολλές περιπτώσεις παίρνουμε ως εκτιμητή το δειγματικό «εμπειρικό» ανάλογο της ποσότητας που μας ενδιαφέρει.
- Προσοχή:
 - ▶ Η πραγματική (F) είναι συνάρτηση κατανομής η οποία, γενικά, μπορεί να είναι συνεχής/διακριτή.
 - ▶ Η εμπειρική (\hat{F}_n) είναι διακριτή: θέτει μάζα $1/n$ σε κάθε μία από τις n τιμές του δείγματος.

Γραμμικά συναρτησιακά

Ορισμός (Γραμμικά συναρτησιακά)

Ένα συναρτησιακό της μορφής $T(F) = \int \alpha(x)dF(x)$ καλείται γραμμικό συναρτησιακό.

Γραμμικά συναρτησιακά

Ορισμός (Γραμμικά συναρτησιακά)

Ένα συναρτησιακό της μορφής $T(F) = \int \alpha(x)dF(x)$ καλείται γραμμικό συναρτησιακό.

- Υπενθύμιση:

$$\int \alpha(x)dF(x) = \begin{cases} \int \alpha(x)f(x)dx, & \text{(συνεχής περίπτωση)} \\ \sum_j x_j f(x_j), & \text{(διακριτή περίπτωση)} \end{cases}$$

Γραμμικά συναρτησιακά

Ορισμός (Γραμμικά συναρτησιακά)

Ένα συναρτησιακό της μορφής $T(F) = \int \alpha(x)dF(x)$ καλείται γραμμικό συναρτησιακό.

- Υπενθύμιση:

$$\int \alpha(x)dF(x) = \begin{cases} \int \alpha(x)f(x)dx, & \text{(συνεχής περίπτωση)} \\ \sum_j x_j f(x_j), & \text{(διακριτή περίπτωση)} \end{cases}$$

- Επειδή \hat{F}_n διακριτή, ο **εκτιμητής αντικατάστασης για ένα γραμμικό συναρτησιακό** $T(F) = \int \alpha(x)dF(x)$ είναι

$$T(\hat{F}_n) = \int \alpha(x)d\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \alpha(X_i).$$

Παράδειγμα Ι: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.

Παράδειγμα Ι: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.
- Είναι γραμμικό συναρτησιακό της F με $\alpha(x) = x$.

Παράδειγμα I: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.
- Είναι γραμμικό συναρτησιακό της F με $\alpha(x) = x$.
- Εκτιμητής αντικατάστασης:

$$\hat{\mu} = \int x d\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \alpha(X_i) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.$$

Παράδειγμα I: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.
- Είναι γραμμικό συναρτησιακό της F με $\alpha(x) = x$.
- Εκτιμητής αντικατάστασης:

$$\hat{\mu} = \int x d\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \alpha(X_i) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.$$

- Είναι $\text{Var}(\hat{\mu}) = \frac{\sigma^2}{n}$

Παράδειγμα I: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.
- Είναι γραμμικό συναρτησιακό της F με $\alpha(x) = x$.
- Εκτιμητής αντικατάστασης:

$$\hat{\mu} = \int x d\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \alpha(X_i) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.$$

- Είναι $\text{Var}(\hat{\mu}) = \frac{\sigma^2}{n}$
- Τυπικό σφάλμα: $\text{se} = \sqrt{\text{Var}(\hat{\mu})} = \frac{\sigma}{\sqrt{n}}$.

Παράδειγμα I: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.
- Είναι γραμμικό συναρτησιακό της F με $\alpha(x) = x$.
- Εκτιμητής αντικατάστασης:

$$\hat{\mu} = \int x d\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \alpha(X_i) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.$$

- Είναι $\text{Var}(\hat{\mu}) = \frac{\sigma^2}{n}$
- Τυπικό σφάλμα: $se = \sqrt{\text{Var}(\hat{\mu})} = \frac{\sigma}{\sqrt{n}}$.
- Έστω $\hat{\sigma}$ εκτιμητής του σ .

Παράδειγμα I: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.
- Είναι γραμμικό συναρτησιακό της F με $\alpha(x) = x$.
- Εκτιμητής αντικατάστασης:

$$\hat{\mu} = \int x d\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \alpha(X_i) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.$$

- Είναι $\text{Var}(\hat{\mu}) = \frac{\sigma^2}{n}$
- Τυπικό σφάλμα: $\text{se} = \sqrt{\text{Var}(\hat{\mu})} = \frac{\sigma}{\sqrt{n}}$.
- Έστω $\hat{\sigma}$ εκτιμητής του σ .
- Plug-in εκτιμητής του τυπικού σφάλματος: $\hat{\text{se}} = \frac{\hat{\sigma}}{\sqrt{n}}$.

Παράδειγμα I: μέση τιμή

- Έστω $\mu = T(F) = \int x dF$.
- Είναι γραμμικό συναρτησιακό της F με $\alpha(x) = x$.
- Εκτιμητής αντικατάστασης:

$$\hat{\mu} = \int x d\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \alpha(X_i) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.$$

- Είναι $\text{Var}(\hat{\mu}) = \frac{\sigma^2}{n}$
- Τυπικό σφάλμα: $se = \sqrt{\text{Var}(\hat{\mu})} = \frac{\sigma}{\sqrt{n}}$.
- Έστω $\hat{\sigma}$ εκτιμητής του σ .
- Plug-in εκτιμητής του τυπικού σφάλματος: $\hat{se} = \frac{\hat{\sigma}}{\sqrt{n}}$.
- $100(1 - \alpha)\%$ διάστημα εμπιστοσύνης (ασυμπτωτικό) για το $\mu = T(F)$

$$\left[\bar{X}_n - z_{\alpha/2} \frac{\hat{\sigma}}{\sqrt{n}}, \bar{X}_n + z_{\alpha/2} \frac{\hat{\sigma}}{\sqrt{n}} \right].$$

Παράδειγμα II: διασπορά

- Έστω $\sigma^2 = T(F) = \int (x - \mu)^2 dF$.

Παράδειγμα II: διασπορά

- Έστω $\sigma^2 = T(F) = \int (x - \mu)^2 dF$.
- Επειδή $\mu = \int x dF(x)$, ισχύει ότι $\sigma^2 = \int x^2 dF(x) - (\int x dF(x))^2$.

Παράδειγμα II: διασπορά

- Έστω $\sigma^2 = T(F) = \int (x - \mu)^2 dF$.
- Επειδή $\mu = \int x dF(x)$, ισχύει ότι $\sigma^2 = \int x^2 dF(x) - (\int x dF(x))^2$.
- Εκτιμητής αντικατάστασης:

$$\begin{aligned}\hat{\sigma}^2 &= \int x^2 d\hat{F}_n(x) - \left(\int x d\hat{F}_n(x) \right)^2 \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i \right)^2 \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu})^2.\end{aligned}$$

Παράδειγμα II: διασπορά

- Έστω $\sigma^2 = T(F) = \int (x - \mu)^2 dF$.
- Επειδή $\mu = \int x dF(x)$, ισχύει ότι $\sigma^2 = \int x^2 dF(x) - (\int x dF(x))^2$.
- Εκτιμητής αντικατάστασης:

$$\begin{aligned}\hat{\sigma}^2 &= \int x^2 d\hat{F}_n(x) - \left(\int x d\hat{F}_n(x) \right)^2 \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i \right)^2 \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu})^2.\end{aligned}$$

- Παρατηρήστε ότι $\hat{\sigma}^2 \neq S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$.

Παράδειγμα III: λοξότητα

- Έστω μ και σ^2 η μέση τιμή και διασπορά της τυχαίας μεταβλητής X .

Παράδειγμα III: λοξότητα

- Έστω μ και σ^2 η μέση τιμή και διασπορά της τυχαίας μεταβλητής X .
- Η λοξότητα ορίζεται ως

$$\kappa = \frac{E(X - \mu)^3}{\sigma^3} = \frac{\int (x - \mu)^3 dF(x)}{\left\{ \int (x - \mu)^2 dF(x) \right\}^{3/2}}$$

και μετράει την ασυμμετρία της κατανομής της X .

Παράδειγμα III: Λοξότητα

- Έστω μ και σ^2 η μέση τιμή και διασπορά της τυχαίας μεταβλητής X .
- Η λοξότητα ορίζεται ως

$$\kappa = \frac{E(X - \mu)^3}{\sigma^3} = \frac{\int (x - \mu)^3 dF(x)}{\left\{ \int (x - \mu)^2 dF(x) \right\}^{3/2}}$$

και μετράει την ασυμμετρία της κατανομής της X .

- Έχουμε ότι $\hat{\mu} = \bar{X}_n$ και $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu})^2$.

Παράδειγμα III: Λοξότητα

- Έστω μ και σ^2 η μέση τιμή και διασπορά της τυχαίας μεταβλητής X .
- Η λοξότητα ορίζεται ως

$$\kappa = \frac{E(X - \mu)^3}{\sigma^3} = \frac{\int (x - \mu)^3 dF(x)}{\left\{ \int (x - \mu)^2 dF(x) \right\}^{3/2}}$$

και μετράει την ασυμμετρία της κατανομής της X .

- Έχουμε ότι $\hat{\mu} = \bar{X}_n$ και $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu})^2$.
- Εκτιμητής αντικατάστασης του κ

$$\hat{\kappa} = \frac{\int (x - \mu)^3 d\hat{F}_n(x)}{\left\{ \int (x - \mu)^2 d\hat{F}_n(x) \right\}^{3/2}} = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu})^3}{\hat{\sigma}^3}.$$

Εφαρμογή

Έστω τυχαίο δείγμα μεγέθους $n = 10$:

$(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$.

Να υπολογιστούν οι εκτιμητές αντικατάστασης για τη μέση τιμή, διασπορά και λοξότητα της κατανομής των δεδομένων και ένα 95% Α.Δ.Ε για τη μέση τιμή.

Εφαρμογή

Έστω τυχαίο δείγμα μεγέθους $n = 10$:

$(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$.

Να υπολογιστούν οι εκτιμητές αντικατάστασης για τη μέση τιμή, διασπορά και λοξότητα της κατανομής των δεδομένων και ένα 95% Α.Δ.Ε για τη μέση τιμή.

- $\hat{\mu} = 0.21$

Εφαρμογή

Έστω τυχαίο δείγμα μεγέθους $n = 10$:

$$(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14).$$

Να υπολογιστούν οι εκτιμητές αντικατάστασης για τη μέση τιμή, διασπορά και λοξότητα της κατανομής των δεδομένων και ένα 95% Α.Δ.Ε για τη μέση τιμή.

- $\hat{\mu} = 0.21$
- $\hat{\sigma}^2 \approx 0.87$ (παρατηρήστε ότι αυτό είναι διαφορετικό του S_n^2)

Εφαρμογή

Έστω τυχαίο δείγμα μεγέθους $n = 10$:

$$(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14).$$

Να υπολογιστούν οι εκτιμητές αντικατάστασης για τη μέση τιμή, διασπορά και λοξότητα της κατανομής των δεδομένων και ένα 95% Α.Δ.Ε για τη μέση τιμή.

- $\hat{\mu} = 0.21$
- $\hat{\sigma}^2 \approx 0.87$ (παρατηρήστε ότι αυτό είναι διαφορετικό του S_n^2)
- $\hat{\kappa} \approx 0.54$

Παρατήρηση: η παραπάνω εκτίμηση της λοξότητας υπολογίζεται στην R μέσω της εντολής `skewness(x, type = 1)` του πακέτου 'e1071'.

Εφαρμογή

Έστω τυχαίο δείγμα μεγέθους $n = 10$:

$$(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14).$$

Να υπολογιστούν οι εκτιμητές αντικατάστασης για τη μέση τιμή, διασπορά και λοξότητα της κατανομής των δεδομένων και ένα 95% Α.Δ.Ε για τη μέση τιμή.

- $\hat{\mu} = 0.21$
- $\hat{\sigma}^2 \approx 0.87$ (παρατηρήστε ότι αυτό είναι διαφορετικό του S_n^2)
- $\hat{\kappa} \approx 0.54$

Παρατήρηση: η παραπάνω εκτίμηση της λοξότητας υπολογίζεται στην R μέσω της εντολής `skewness(x, type = 1)` του πακέτου `'e1071'`.

- 95% Α.Δ.Ε για το μ : $[-0.37, 0.79]$

Παρατήρηση: η εκτίμηση του τυπικού σφάλματος του δειγματικού μέσου υπολογίστηκε ως:

$$\widehat{se} = \frac{\hat{\sigma}}{\sqrt{n}} \approx \frac{\sqrt{0.87}}{\sqrt{10}} \approx 0.31.$$

Παράδειγμα IV: συντελεστής συσχέτισης

- Έστω $Z = (X, Y)$ διδιάστατη τυχαία μεταβλητή με συνάρτηση κατανομής $F(x, y)$.

Παράδειγμα IV: συντελεστής συσχέτισης

- Έστω $Z = (X, Y)$ διδιάστατη τυχαία μεταβλητή με συνάρτηση κατανομής $F(x, y)$.
- Συντελεστής συσχέτισης $\rho = T(F) = \frac{E(X - \mu_X)(Y - \mu_Y)}{\sigma_X \sigma_Y} = \frac{E(XY) - \mu_X \mu_Y}{\sigma_X \sigma_Y}$

Παράδειγμα IV: συντελεστής συσχέτισης

- Έστω $Z = (X, Y)$ διδιάστατη τυχαία μεταβλητή με συνάρτηση κατανομής $F(x, y)$.
- Συντελεστής συσχέτισης $\rho = T(F) = \frac{E(X - \mu_X)(Y - \mu_Y)}{\sigma_X \sigma_Y} = \frac{E(XY) - \mu_X \mu_Y}{\sigma_X \sigma_Y}$
- Προφανώς $T(F) = g(T_1(F), T_2(F), T_3(F), T_4(F), T_5(F))$, όπου
 $T_1(F) = \int x dF(z)$ $T_2(F) = \int y dF(z)$ $T_3(F) = \int xy dF(z)$
 $T_4(F) = \int x^2 dF(z)$ $T_5(F) = \int y^2 dF(z)$

και

$$g(t_1, t_2, t_3, t_4, t_5) = \frac{t_3 - t_1 t_2}{\sqrt{(t_4 - t_1^2)(t_5 - t_2^2)}}.$$

Παράδειγμα IV: συντελεστής συσχέτισης

- Έστω $Z = (X, Y)$ διδιάστατη τυχαία μεταβλητή με συνάρτηση κατανομής $F(x, y)$.
- Συντελεστής συσχέτισης $\rho = T(F) = \frac{E(X - \mu_X)(Y - \mu_Y)}{\sigma_X \sigma_Y} = \frac{E(XY) - \mu_X \mu_Y}{\sigma_X \sigma_Y}$
- Προφανώς $T(F) = g(T_1(F), T_2(F), T_3(F), T_4(F), T_5(F))$, όπου
 $T_1(F) = \int x dF(z)$ $T_2(F) = \int y dF(z)$ $T_3(F) = \int xy dF(z)$
 $T_4(F) = \int x^2 dF(z)$ $T_5(F) = \int y^2 dF(z)$

και

$$g(t_1, t_2, t_3, t_4, t_5) = \frac{t_3 - t_1 t_2}{\sqrt{(t_4 - t_1^2)(t_5 - t_2^2)}}.$$

- Αντικαθιστώντας την F με \hat{F}_n στις $T_1(F), T_2(F), T_3(F), T_4(F), T_5(F)$ προκύπτει ότι ο εκτιμητής αντικατάστασης είναι

$$\begin{aligned}\hat{\rho} &= g(T_1(\hat{F}_n), T_2(\hat{F}_n), T_3(\hat{F}_n), T_4(\hat{F}_n), T_5(\hat{F}_n)) \\ &= \frac{\sum_{i=1}^n (X_i - \bar{X}_n)(Y_i - \bar{Y}_n)}{\sqrt{\sum_{i=1}^n (X_i - \bar{X}_n)^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y}_n)^2}}\end{aligned}$$

δηλαδή ο δειγματικός συντελεστής συσχέτισης.

Παράδειγμα V: ποσοστιαία σημεία

- Υπενθύμιση ορισμού: **(κάτω) p -ποσοστιαίο σημείο**
 - ▶ Για F γνησίως αύξουσα $q_p = F^{-1}(p)$
 - ▶ δηλαδή το q_p είναι το μοναδικό μέλος του συνόλου $\{x : F(x) = p\}$
 - ▶ Γενικός ορισμός μέσω γενικευμένης αντίστροφης συνάρτησης:
 $q_p = F^{-1}(p) = \inf\{x : F(x) \geq p\}, p \in (0, 1).$

Παράδειγμα V: ποσοστιαία σημεία

- Υπενθύμιση ορισμού: **(κάτω) p -ποσοστιαίο σημείο**
 - ▶ Για F γνησίως αύξουσα $q_p = F^{-1}(p)$
 - ▶ δηλαδή το q_p είναι το μοναδικό μέλος του συνόλου $\{x : F(x) = p\}$
 - ▶ Γενικός ορισμός μέσω γενικευμένης αντίστροφης συνάρτησης:
 $q_p = F^{-1}(p) = \inf\{x : F(x) \geq p\}, p \in (0, 1).$
- Εκτιμητής αντικατάστασης

$$\begin{aligned}\hat{q}_p &= \hat{F}_n^{-1}(p) \\ &= \inf\{x : \hat{F}_n(x) \geq p\} \\ &= X_{[j]}\end{aligned}$$

όπου

- ▶ $(X_{[1]}, \dots, X_{[n]})$ είναι το διατεταγμένο δείγμα
- ▶ j ο δείκτης για τον οποίον $\frac{j-1}{n} < p \leq \frac{j}{n}$

Παράδειγμα V: ποσοστιαία σημεία

- Υπενθύμιση ορισμού: **(κάτω) p -ποσοστιαίο σημείο**
 - ▶ Για F γνησίως αύξουσα $q_p = F^{-1}(p)$
 - ▶ δηλαδή το q_p είναι το μοναδικό μέλος του συνόλου $\{x : F(x) = p\}$
 - ▶ Γενικός ορισμός μέσω γενικευμένης αντίστροφης συνάρτησης:
 $q_p = F^{-1}(p) = \inf\{x : F(x) \geq p\}$, $p \in (0, 1)$.
- Εκτιμητής αντικατάστασης

$$\begin{aligned}\hat{q}_p &= \hat{F}_n^{-1}(p) \\ &= \inf\{x : \hat{F}_n(x) \geq p\} \\ &= X_{[j]}\end{aligned}$$

όπου

- ▶ $(X_{[1]}, \dots, X_{[n]})$ είναι το διατεταγμένο δείγμα
- ▶ j ο δείκτης για τον οποίον $\frac{j-1}{n} < p \leq \frac{j}{n}$
- Το \hat{q}_p είναι το *δειγματικό (κάτω) p -ποσοστιαίο σημείο*.

Παράδειγμα V: ποσοστιαία σημεία

- Παράδειγμα: ο εκτιμητής του $q_{0.5}$ (διάμεσος)

$$\begin{aligned}\hat{q}_{0.5} &= \hat{F}_n^{-1}(0.5) \\ &= \inf\{x : \hat{F}_n(x) \geq 0.5\} \\ &= \begin{cases} X_{[n/2]}, & \text{αν } n \text{ άρτιος} \\ X_{[(n+1)/2]}, & \text{αν } n \text{ περιττός} \end{cases}\end{aligned}$$

Παράδειγμα V: ποσοστιαία σημεία

- Παράδειγμα: ο εκτιμητής του $q_{0.5}$ (διάμεσος)

$$\begin{aligned}\hat{q}_{0.5} &= \hat{F}_n^{-1}(0.5) \\ &= \inf\{x : \hat{F}_n(x) \geq 0.5\} \\ &= \begin{cases} X_{[n/2]}, & \text{αν } n \text{ άρτιος} \\ X_{[(n+1)/2]}, & \text{αν } n \text{ περιττός} \end{cases}\end{aligned}$$

- Παράδειγμα: εκτιμητής του $q_{0.9}$

$$\begin{aligned}\hat{q}_{0.9} &= \hat{F}_n^{-1}(0.9) \\ &= \inf\{x : \hat{F}_n(x) \geq 0.9\} \\ &= X_{[j]}\end{aligned}$$

όπου j ο δείκτης για τον οποίον: $\frac{j-1}{n} < 0.9 \leq \frac{j}{n}$. Πχ:

- ▶ Αν $n = 10$: $\hat{q}_{0.9} = X_{[9]}$ διότι: $\frac{9-1}{10} = 0.8 < 0.9 \leq \frac{9}{10} = 0.9$.
- ▶ Αν $n = 11$: $\hat{q}_{0.9} = X_{[10]}$ διότι: $\frac{10-1}{11} \approx 0.82 < 0.9 \leq \frac{10}{11} \approx 0.91$.

Παράδειγμα V: ποσοστιαία σημεία

- Παράδειγμα: ο εκτιμητής του $q_{0.5}$ (διάμεσος)

$$\begin{aligned}\hat{q}_{0.5} &= \hat{F}_n^{-1}(0.5) \\ &= \inf\{x : \hat{F}_n(x) \geq 0.5\} \\ &= \begin{cases} X_{[n/2]}, & \text{αν } n \text{ άρτιος} \\ X_{[(n+1)/2]}, & \text{αν } n \text{ περιττός} \end{cases}\end{aligned}$$

- Παράδειγμα: εκτιμητής του $q_{0.9}$

$$\begin{aligned}\hat{q}_{0.9} &= \hat{F}_n^{-1}(0.9) \\ &= \inf\{x : \hat{F}_n(x) \geq 0.9\} \\ &= X_{[j]}\end{aligned}$$

όπου j ο δείκτης για τον οποίον: $\frac{j-1}{n} < 0.9 \leq \frac{j}{n}$. Πχ:


- ▶ Αν $n = 10$: $\hat{q}_{0.9} = X_{[9]}$ διότι: $\frac{9-1}{10} = 0.8 < 0.9 \leq \frac{9}{10} = 0.9$.
- ▶ Αν $n = 11$: $\hat{q}_{0.9} = X_{[10]}$ διότι: $\frac{10-1}{11} \approx 0.82 < 0.9 \leq \frac{10}{11} \approx 0.91$.

- Παρατήρηση: στην R **quantile(..., type = 1)**.

Παράδειγμα V: ποσοστιαία σημεία

Δεδομένα: $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$


x	$\widehat{F}_n(x)$
$(-\infty, -1.13)$	0
$[-1.13, -0.90)$	1/10
$[-0.90, -0.24)$	2/10
$[-0.24, -0.14)$	3/10
$[-0.14, -0.08)$	4/10
$[-0.08, 0.13)$	5/10
$[0.13, 0.18)$	6/10
$[0.18, 0.71)$	7/10
$[0.71, 1.59)$	8/10
$[1.59, 1.98)$	9/10
$[1.98, \infty)$	1



Παράδειγμα V: ποσοστιαία σημεία

Δεδομένα: $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$

x	$\widehat{F}_n(x)$
$(-\infty, -1.13)$	0
$[-1.13, -0.90)$	1/10
$[-0.90, -0.24)$	2/10
$[-0.24, -0.14)$	3/10
$[-0.14, -0.08)$	4/10
$[-0.08, 0.13)$	5/10
$[0.13, 0.18)$	6/10
$[0.18, 0.71)$	7/10
$[0.71, 1.59)$	8/10
$[1.59, 1.98)$	9/10
$[1.98, \infty)$	1




• $\widehat{q}_{0.5} = -0.08$

Παράδειγμα V: ποσοστιαία σημεία

Δεδομένα: $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$

x	$\widehat{F}_n(x)$
$(-\infty, -1.13)$	0
$[-1.13, -0.90)$	1/10
$[-0.90, -0.24)$	2/10
$[-0.24, -0.14)$	3/10
$[-0.14, -0.08)$	4/10
$[-0.08, 0.13)$	5/10
$[0.13, 0.18)$	6/10
$[0.18, 0.71)$	7/10
$[0.71, 1.59)$	8/10
$[1.59, 1.98)$	9/10
$[1.98, \infty)$	1




- $\widehat{q}_{0.5} = -0.08$
- $\widehat{q}_{0.9} = 1.59$

Παράδειγμα V: ποσοστιαία σημεία

Δεδομένα: $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$

x	$\widehat{F}_n(x)$
$(-\infty, -1.13)$	0
$[-1.13, -0.90)$	1/10
$[-0.90, -0.24)$	2/10
$[-0.24, -0.14)$	3/10
$[-0.14, -0.08)$	4/10
$[-0.08, 0.13)$	5/10
$[0.13, 0.18)$	6/10
$[0.18, 0.71)$	7/10
$[0.71, 1.59)$	8/10
$[1.59, 1.98)$	9/10
$[1.98, \infty)$	1



- $\widehat{q}_{0.5} = -0.08$
- $\widehat{q}_{0.9} = 1.59$
- $\widehat{q}_{0.86} = 1.59$

Εφαρμογή: Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

- Ακριβή: μέσω της διωνυμικής κατανομής
- Ασυμπτωτικά: μέθοδος Δέλτα

Διωνυμικά Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

- Σκοπός: κατασκευή $100(1 - \alpha)\%$ Δ.Ε για το q_p

Διωνυμικά Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

- Σκοπός: κατασκευή $100(1 - \alpha)\%$ Δ.Ε για το q_p
- Αρκεί να επιλέξουμε $r < s$ τέτοια ώστε:

$$P (X_{[r]} < q_p \leq X_{[s]}) \geq 1 - \alpha$$

Διωνυμικά Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

- Σκοπός: κατασκευή $100(1 - \alpha)\%$ Δ.Ε για το q_p
- Αρκεί να επιλέξουμε $r < s$ τέτοια ώστε:

$$P(X_{[r]} < q_p \leq X_{[s]}) \geq 1 - \alpha$$

- Παρατηρούμε ότι

$$P(X_{[r]} < q_p \leq X_{[s]}) = 1 - \{P(X_{[r]} \geq q_p) + P(X_{[s]} < q_p)\}$$

Διωνυμικά Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

- Σκοπός: κατασκευή $100(1 - \alpha)\%$ Δ.Ε για το q_p
- Αρκεί να επιλέξουμε $r < s$ τέτοια ώστε:

$$P(X_{[r]} < q_p \leq X_{[s]}) \geq 1 - \alpha$$

- Παρατηρούμε ότι

$$P(X_{[r]} < q_p \leq X_{[s]}) = 1 - \{P(X_{[r]} \geq q_p) + P(X_{[s]} < q_p)\}$$

- Αρκεί το άθροισμα στις αγκύλες να είναι $\leq \alpha$:

$$P(X_{[r]} \geq q_p) \leq \frac{\alpha}{2}$$

$$P(X_{[s]} < q_p) \leq \frac{\alpha}{2}$$

Διωνυμικά Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

- $\{X_{[s]} < q_p\}$: τουλάχιστον s παρατηρήσεις είναι μικρότερες του q_p
- $\{X_{[r]} \geq q_p\}$: το πολύ $r - 1$ παρατηρήσεις είναι μικρότερες του q_p
- Ορίζω $Y = \sum_{i=1}^n I\{X_i < q_p\}$
- Για συνεχή F : $P(X_1 < q_p) = P(X_1 \leq q_p) = p$
- Επειδή X_i ανεξάρτητες και ισόνομες: $Y \sim \mathcal{B}(n, p)$
- Οπότε

$$P(X_{[s]} \leq q_p) = P(Y \geq s) = \sum_{i=s}^n \binom{n}{i} p^i (1-p)^{n-i}$$

- Ομοίως:

$$\begin{aligned} P(X_{[r]} \geq q_p) &= 1 - P(X_{[r]} < q_p) \\ &= 1 - P(Y \geq r) = \sum_{i=0}^{r-1} \binom{n}{i} p^i (1-p)^{n-i} \end{aligned}$$

Διωνυμικά Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

Συνοψίζοντας, δείξαμε την

Πρόταση

Το τυχαίο διάστημα

$$(X_{[r]}, X_{[s]})$$

όπου

- $r = \max\{k = 0, 1, \dots, n : F_{n,p}(k - 1) \leq \alpha/2\}$
- $s = \min\{k = 1, \dots, n + 1 : F_{n,p}(k - 1) \geq 1 - \alpha/2\}$
- $F_{n,p}(\cdot)$ είναι η αθροιστική συνάρτηση κατανομής της $\mathcal{B}(n, p)$

είναι ένα $100(1 - \alpha)\%$ διάστημα εμπιστοσύνης για το q_p , $p \in (0, 1)$.

Σχόλια

Διωνυμικά Διαστήματα εμπιστοσύνης για ποσοστιαία σημεία

Συνοψίζοντας, δείξαμε την

Πρόταση

Το τυχαίο διάστημα

$$(X_{[r]}, X_{[s]})$$

όπου

- $r = \max\{k = 0, 1, \dots, n : F_{n,p}(k-1) \leq \alpha/2\}$
- $s = \min\{k = 1, \dots, n+1 : F_{n,p}(k-1) \geq 1 - \alpha/2\}$
- $F_{n,p}(\cdot)$ είναι η αθροιστική συνάρτηση κατανομής της $\mathcal{B}(n, p)$

είναι ένα $100(1 - \alpha)\%$ διάστημα εμπιστοσύνης για το q_p , $p \in (0, 1)$.

Σχόλια

- Στην πρόταση πρέπει να ορίσουμε $X_{[0]} = -\infty$ και $X_{[n+1]} = \infty$.
- Το προηγούμενο Δ.Ε είναι συντηρητικό.

Εφαρμογή

Έστω $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$. Να υπολογιστεί το 95% Διωνυμικό διάστημα εμπιστοσύνης για τη διάμεσο.

Εφαρμογή

Έστω $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$. Να υπολογιστεί το 95% Διωνυμικό διάστημα εμπιστοσύνης για τη διάμεσο.

- Διάμεσος: $q_{0.5}$ (και σημειακά: $\hat{q}_{0.5} = -0.08$)

Εφαρμογή

Έστω $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$. Να υπολογιστεί το 95% Διωνυμικό διάστημα εμπιστοσύνης για τη διάμεσο.

- Διάμεσος: $q_{0.5}$ (και σημειακά: $\hat{q}_{0.5} = -0.08$)
- $F_{n,p} = F_{10,0.5}$: συνάρτηση κατανομής της $\mathcal{B}(10, 0.5)$

Εφαρμογή

Έστω $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$. Να υπολογιστεί το 95% Διωνυμικό διάστημα εμπιστοσύνης για τη διάμεσο.

- Διάμεσος: $q_{0.5}$ (και σημειακά: $\hat{q}_{0.5} = -0.08$)
- $F_{n,p} = F_{10,0.5}$: συνάρτηση κατανομής της $\mathcal{B}(10, 0.5)$
- Υπολογισμός r και s

k	$F_{10,0.5}(k-1)$	$x_{[k]}$	
0	0.000	$-\infty$	
1	0.001	-1.13	
2	0.011	-0.90	$\alpha = 0.05$
3	0.055	-0.24	$r = \max\{k = 0, 1, \dots, 10 : F_{10,0.5}(k-1) \leq 0.025\}$
4	0.172	-0.14	$= 2 \Rightarrow$
5	0.377	-0.08	$x_{[r]} = x_{[2]} = -0.90$
6	0.623	0.13	
7	0.828	0.18	$s = \min\{k = 1, \dots, 11 : F_{10,0.5}(k-1) \geq 0.975\}$
8	0.945	0.71	$= 9 \Rightarrow$
9	0.989	1.59	$x_{[s]} = x_{[9]} = 1.59$
10	0.999	1.98	
11	1.000	∞	

Εφαρμογή

Έστω $(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71, -0.24, 1.98, -0.14)$. Να υπολογιστεί το 95% Διωνυμικό διάστημα εμπιστοσύνης για τη διάμεσο.

- Διάμεσος: $q_{0.5}$ (και σημειακά: $\hat{q}_{0.5} = -0.08$)
- $F_{n,p} = F_{10,0.5}$: συνάρτηση κατανομής της $\mathcal{B}(10, 0.5)$
- Υπολογισμός r και s

k	$F_{10,0.5}(k-1)$	$x_{[k]}$	
0	0.000	$-\infty$	
1	0.001	-1.13	
2	0.011	-0.90	$\alpha = 0.05$
3	0.055	-0.24	$r = \max\{k = 0, 1, \dots, 10 : F_{10,0.5}(k-1) \leq 0.025\}$
4	0.172	-0.14	$= 2 \Rightarrow$
5	0.377	-0.08	$x_{[r]} = x_{[2]} = -0.90$
6	0.623	0.13	
7	0.828	0.18	$s = \min\{k = 1, \dots, 11 : F_{10,0.5}(k-1) \geq 0.975\}$
8	0.945	0.71	$= 9 \Rightarrow$
9	0.989	1.59	$x_{[s]} = x_{[9]} = 1.59$
10	0.999	1.98	
11	1.000	∞	

- 95% Δ.Ε για τη διάμεσο: $(x_{[2]}, x_{[9]}) = (-0.90, 1.59]$

Εφαρμογή (εντολές R)

```
> x <- c(-0.90, 0.18, 1.59, -1.13, -0.08, 0.13, 0.71,  
+        -0.24, 1.98, -0.14)  
> n <- length(x)  
> p <- 0.5  
> cbind(0:(n+1), pbinom(q=(-1):n, size = n, prob = p)  
+        c(-Inf, sort(x), Inf))
```

Κάποιοι προβληματισμοί

- Γνωρίζουμε ότι \widehat{F}_n είναι «κοντά» στην F (για κάθε F).

Κάποιοι προβληματισμοί

- Γνωρίζουμε ότι \hat{F}_n είναι «κοντά» στην F (για κάθε F).
- Είναι αυτό επαρκές για να έχουμε $T(\hat{F}_n)$ κοντά στην $T(F)$;

Κάποιοι προβληματισμοί

- Γνωρίζουμε ότι \hat{F}_n είναι «κοντά» στην F (για κάθε F).
- Είναι αυτό επαρκές για να έχουμε $T(\hat{F}_n)$ κοντά στην $T(F)$;
- Όχι απαραίτητα

Κάποιοι προβληματισμοί

- Γνωρίζουμε ότι \widehat{F}_n είναι «κοντά» στην F (για κάθε F).
- Είναι αυτό επαρκές για να έχουμε $T(\widehat{F}_n)$ κοντά στην $T(F)$;
- Όχι απαραίτητα
- Αντιπαράδειγμα:
 - ▶ έστω F παραγωγίσιμη με συνάρτηση πυκνότητας $f(x)$.
 - ▶ έστω $T(F) = F'(x)|_{x=x_0} = f(x_0)$
 - ▶ Η \widehat{F}_n δεν είναι παραγωγίσιμη στα $x_0 = x_1, \dots, x_n$, ενώ για $x_0 \neq x_1, \dots, x_n$ έχουμε $\widehat{F}'_n(x_0) = 0$.

Κάποιοι προβληματισμοί

- Γνωρίζουμε ότι \widehat{F}_n είναι «κοντά» στην F (για κάθε F).
- Είναι αυτό επαρκές για να έχουμε $T(\widehat{F}_n)$ κοντά στην $T(F)$;
- Όχι απαραίτητα
- Αντιπαράδειγμα:
 - ▶ έστω F παραγωγίσιμη με συνάρτηση πυκνότητας $f(x)$.
 - ▶ έστω $T(F) = F'(x)|_{x=x_0} = f(x_0)$
 - ▶ Η \widehat{F}_n δεν είναι παραγωγίσιμη στα $x_0 = x_1, \dots, x_n$, ενώ για $x_0 \neq x_1, \dots, x_n$ έχουμε $\widehat{F}'_n(x_0) = 0$.
- Η συνέπεια και η ασυμπτωτική κανονικότητα εκτιμητών συναρτησιακών της F απαιτούν επί πλέον ιδιότητες για την $T(F)$ όπως η συνέχεια και η διαφορισιμότητα συναρτησιακών.

Ορισμός

Έστω T ένα συναρτησιακό, F είναι συνάρτηση κατανομής στο \mathbb{R} και δ_x είναι η εκφυλισμένη κατανομή στο x . Τότε η **συνάρτηση επιρροής** (Influence Function) ορίζεται ως,

$$\text{IF}_F(x) = \lim_{\varepsilon \rightarrow 0} \frac{T((1 - \varepsilon)F + \varepsilon\delta_x) - T(F)}{\varepsilon},$$

αν το όριο υπάρχει για κάθε $x \in \mathbb{R}$.

Ορισμός

Έστω T ένα συναρτησιακό, F είναι συνάρτηση κατανομής στο \mathbb{R} και δ_x είναι η εκφυλισμένη κατανομή στο x . Τότε η **συνάρτηση επιρροής** (Influence Function) ορίζεται ως,

$$\text{IF}_F(x) = \lim_{\varepsilon \rightarrow 0} \frac{T((1 - \varepsilon)F + \varepsilon\delta_x) - T(F)}{\varepsilon},$$

αν το όριο υπάρχει για κάθε $x \in \mathbb{R}$.

Αν αλλοιώσω ελαφρώς τα δεδομένα σε ένα μόνο σημείο, πόσο αλλάζει ο εκτιμητής μου ;

Υπενθυμίζεται ότι $\delta_x(y)$ είναι ένα σημείο μάζας στο $x \in \mathbb{R}$, αν

$$\delta_x(y) = \begin{cases} 1 & , \quad y \geq x, \\ 0 & , \quad y < x. \end{cases}$$

Ουσιαστικά, η συνάρτηση επιρροής είναι η παράγωγος του συναρτησιακού $T(F)$ στην κατεύθυνση του δ_x . Δηλαδή, αν θεωρήσουμε $F_\varepsilon = (1 - \varepsilon)F + \varepsilon\delta_x$, τότε

$$\text{IF}_F(x) = \left. \frac{d}{d\varepsilon} T(F_\varepsilon) \right|_{\varepsilon=0}, \quad (2)$$

υπό την προϋπόθεση ότι υπάρχει η παράγωγος.

Influence Function: Μέσος vs Διάμεσος

Μέσος

Για $T(F) = \mathbb{E}[X]$,

$$\text{IF}(x)_F = x - \mathbb{E}[X]$$

- Μη φραγμένο influence function
- Ένα outlier μπορεί να επηρεάσει αυθαίρετα τον εκτιμητή

Διάμεσος

Για διάμεσο m ,

$$\text{IF}(x)_F = \frac{1}{2f(m)} \text{sign}(x - m)$$

- Φραγμένο influence function
- Ανθεκτική σε ακραίες τιμές

Ορισμός

Έστω X_1, X_2, \dots, X_n , είναι ένα τυχαίο δείγμα από έναν πληθυσμό με α.σ.κ. $F(\cdot)$. Η **εμπειρική συνάρτηση επιρροής** συμβολίζεται με $\widehat{IF}(x)$ και ορίζεται ως εξής: $\widehat{IF}(x) = IF_{F_n}(x)$, δηλαδή,

$$\widehat{IF}(x) = \lim_{\varepsilon \rightarrow 0} \frac{T((1 - \varepsilon)F_n + \varepsilon\delta_x) - T(F_n)}{\varepsilon}.$$

Παράδειγμα

Μέσος

Για $T(F) = \mathbb{E}[X]$,

$$\widehat{\text{IF}}(x) = x - \bar{x}.$$

- Μη φραγμένη ως συνάρτηση του x

Διάμεσος

Έστω \hat{m} η εμπειρική διάμεσος και $\hat{f}(\hat{m})$ εκτίμηση της πυκνότητας στο \hat{m} .

$$\widehat{\text{IF}}(x) = \frac{1}{2\hat{f}(\hat{m})} \text{sign}(x - \hat{m}).$$

- Φραγμένη ως συνάρτηση του x

Αξιολόγηση της Empirical IF στις Παρατηρήσεις

Η εμπειρική συνάρτηση επιρροής είναι συνάρτηση του x .

Στην πράξη μας ενδιαφέρει η επίδραση κάθε παρατήρησης:

$$\widehat{\text{IF}}(x_1), \widehat{\text{IF}}(x_2), \dots, \widehat{\text{IF}}(x_n)$$

Μέσος

$$\widehat{\text{IF}}(x_i) = x_i - \bar{x}, \quad i = 1, \dots, n$$

Διάμεσος

$$\widehat{\text{IF}}(x_i) = \frac{1}{2\hat{f}(\hat{m})} \text{sign}(x_i - \hat{m}), \quad i = 1, \dots, n$$

Σημείωση: Αυτά τα $\widehat{\text{IF}}(x_i)$ χρησιμοποιούνται για τον υπολογισμό της ασυμπτωτικής διασποράς (μεταξύ άλλων).

Θεώρημα

Έστω $T(F) = \int a(x)dF(x)$ είναι ένα γραμμικό συναρτησιακό, τότε

❶ $\text{IF}_F(x) = a(x) - T(F)$ και $\widehat{\text{IF}}(x) = a(x) - T(F_n)$.

❷ Για οποιαδήποτε συνάρτηση κατανομής G ,

$$T(G) = T(F) + \int \text{IF}_F(x)dG(x). \quad (3)$$

❸ $\int \text{IF}_F(x)dF(x) = 0$.

❹ Έστω $\tau^2 = \int \text{IF}_F^2(x)dF(x)$. Τότε, $\tau^2 = \int (a(x) - T(F))^2 dF(x)$ και, αν $\tau^2 < \infty$,

$$\sqrt{n}(T(F) - T(F_n)) \rightarrow \mathcal{N}(0, \tau^2). \quad (4)$$

❺ Έστω $\hat{\tau}^2 = \frac{1}{n} \sum_{i=1}^n \widehat{\text{IF}}^2(X_i) = \frac{1}{n} \sum_{i=1}^n (a(X_i) - T(F_n))^2$. Τότε, $\hat{\tau}^2 \xrightarrow{P} \tau^2$ και

$\widehat{\text{se}}/\text{se} \xrightarrow{P} 1$, όπου $\widehat{\text{se}} = \hat{\tau}/\sqrt{n}$ και $\text{se} = \sqrt{\text{Var}(T(F_n))}$.

❻

$$\frac{\sqrt{n}(T(F) - T(F_n))}{\hat{\tau}} \rightarrow \mathcal{N}(0, 1). \quad (5)$$

Παρατηρήσεις

- Η συνάρτηση επιρροής συμπεριφέρεται όπως η συνάρτηση σκορ στην παραμετρική στατιστική συμπερασματολογία:

$$\int \text{IF}_F(x) dF(x) = 0 \text{ και } \text{Var}(T(F_n)) = \int \text{IF}_F^2(x) dF(x) / n.$$

- Από τη σχέση (5) του Θεωρήματος προκύπτει ότι η στατιστική συνάρτηση $\frac{T(F) - T(F_n)}{\widehat{\text{se}}}$ ακολουθεί (προσεγγιστικά) την κατανομή $\mathcal{N}(0, 1)$. Το αποτέλεσμα αυτό είναι γνωστό στη βιβλιογραφία ως **μη παραμετρική μέθοδος Δέλτα**.
- Από την κανονική προσέγγιση προκύπτει το ασυμπτωτικό διάστημα εμπιστοσύνης για το γραμμικό συναρτησιακό $T(F)$.

Διάστημα Εμπιστοσύνης με τη Μη Παραμετρική Μέθοδο Δέλτα

Θεώρημα

Έστω X_1, X_2, \dots, X_n είναι ένα τυχαίο δείγμα από έναν πληθυσμό με αθροιστική συνάρτηση κατανομής $F(\cdot)$ και $T(F)$ ένα γραμμικό συναρτησιακό. Υποθέτουμε ότι:

$$\tau^2 = \int (a(x) - T(F))^2 dF(x) < \infty.$$

Τότε ένα $100(1 - \alpha)\%$ ασυμπτωτικό διάστημα εμπιστοσύνης για το γραμμικό συναρτησιακό $T(F)$ είναι το:

$$\left(T(F_n) - z_{\alpha/2} \frac{\hat{\tau}}{\sqrt{n}}, T(F_n) + z_{\alpha/2} \frac{\hat{\tau}}{\sqrt{n}} \right) \quad (6)$$

ή ισοδύναμα το

$$(T(F_n) - z_{\alpha/2} \hat{s}e, T(F_n) + z_{\alpha/2} \hat{s}e)$$

$$\text{όπου } \hat{s}e = \frac{\hat{\tau}}{\sqrt{n}}, \text{ με } \hat{\tau}^2 = \frac{1}{n} \sum_{i=1}^n (a(X_i) - T(F_n))^2.$$

Ασυμπτωτικό ΔΕ για τη Μέση Τιμή με τη Μη Παραμετρική Μέθοδο Δέλτα

Παράδειγμα

Έστω X_1, X_2, \dots, X_n είναι ένα τυχαίο δείγμα από έναν πληθυσμό με αθροιστική συνάρτηση κατανομής $F(\cdot)$. Έστω ότι

$$\tau^2 = \int (a(x) - T(F))^2 dF(x) = \int (x - \theta)^2 dF(x) < \infty.$$

Να δείξετε ότι το τυχαίο διάστημα

$$(\bar{X} - z_{a/2} \widehat{se}, \bar{X} + z_{a/2} \widehat{se}),$$

όπου $\widehat{se} = \frac{\widehat{\tau}}{\sqrt{n}}$ είναι ένα $100(1 - a)\%$, κατά σημείο, ασυμπτωτικό διάστημα εμπιστοσύνης για την πληθυσμιακή μέση τιμή θ .

Ασυμπτωτικό ΔΕ για την $F(\beta)$ με τη Μη Παραμετρική Μέθοδο Δέλτα

Παράδειγμα

Έστω X_1, X_2, \dots, X_n είναι ένα τυχαίο δείγμα από έναν πληθυσμό με αθροιστική συνάρτηση κατανομής $F(\cdot)$. Έστω ότι

$$\hat{\tau}^2 = \frac{1}{n} \sum_{i=1}^n \{\delta_{X_i}(\beta) - \hat{F}_n(\beta)\}^2$$

όπου $\hat{F}_n(\cdot)$ η εμπειρική συνάρτηση κατανομής. Να δείξετε ότι το τυχαίο διάστημα

$$(\hat{F}_n(\beta) - z_{\alpha/2}\hat{s}\hat{e}, \hat{F}_n(\beta) + z_{\alpha/2}\hat{s}\hat{e}),$$

όπου $\hat{s}\hat{e} = \hat{\tau}/\sqrt{n}$ είναι ένα $100(1 - \alpha)\%$ ασυμπτωτικό διάστημα εμπιστοσύνης για την $F(\beta)$.

Να δείξετε ότι το παραπάνω συμπίπτει με το Ασυμπτωτικό ΔΕ Wald (σελίδα 17)