

Συμπερασματολογία για συναρτησιακά της F

Μη Παραμετρική Στατιστική

Παναγιώτης Παπασταμούλης
Επίκουρος Καθηγητής
Τμήμα Στατιστικής ΟΠΑ

papastamoulis@aueb.gr

Παρασκευή, 03/04/2020



Υπενθύμιση: Εκτίμηση αθροιστικής συνάρτησης κατανομής

- Εστω X_1, \dots, X_n τυχαίο δείγμα από κάποια (άγνωστη) συνάρτηση κατανομής F .
- Η F εκτιμάται από την εμπειρική συνάρτηση κατανομής \hat{F}_n

Ορισμός (Εμπειρική συνάρτηση κατανομής)

Η εμπειρική συνάρτηση κατανομής ορίζεται ως

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

Στον παραπάνω ορισμό:

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

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 συμπεραματολογία
 - ▶ 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 I: 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: $se = \sqrt{\text{Var}(\hat{\mu})} = \frac{\sigma}{\sqrt{n}}$.
- Έστω $\hat{\sigma}$ εκτιμητής του σ .
- Plug-in εκτιμητής του τυπικού σφάλματος: $\hat{se} = \frac{\hat{\sigma}}{\sqrt{n}}$.

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:

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

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 **quant(..., 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

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

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 $Y = \sum_{i=1}^n I\{X_i < q_p\}$

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 : $P(X_1 < q_p) = P(X_1 \leq q_p) = p$

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: $Y \sim \mathcal{B}(n, p)$

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

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

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 $X_{[n+1]} = \infty$.

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	
6	0.623	0.13	$x_{[r]} = x_{[2]} = -0.90$
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	
6	0.623	0.13	$x_{[r]} = x_{[2]} = -0.90$
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 \hat{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.