

ΜΗ ΠΑΡΑΜΕΤΡΙΚΗ ΣΤΑΤΙΣΤΙΚΗ - ΚΑΤΗΓΟΡΙΚΑ ΔΕΔΟΜΕΝΑ

(Non parametric statistics - Categorical data analysis)

(Distributions Free methods)

(Κεφ. 7 Εισαγωγή στη στατιστική - Διδ. Σημειώσεις Μπασιδής, Ζωγράφου)

Μάθημα 1ο

01/03/2017

(Εκτός εξεταστέας ύλης)

Κλίμακες μέτρησης

- ΠΟΙΟΤΙΚΕΣ**
- Όνοματική ή ονομαστική: μόνο κατηγορίες, π.χ. αριθμοί αυτοκινήτων
 - Διατάξιμη: Συγκριτική σχέση, π.χ. βαθμοί αξιωματικών
- ΠΟΣΟΤΙΚΕΣ**
- Διαστηματική: Τιμή στη διαφορά 2 μετρήσεων (το μηδέν δεν είναι σταθερό), π.χ. θερμοκρασία
 - Αναλογική ή λόγου: Το σταθερό μηδέν, π.χ. βάρη, ύψη

Πολυωνομική κατανομή (Multinomial)

Μια δοκιμή με E_1, \dots, E_k δυνατά αποτελέσματα και $p_i = P(E_i), \dots, p_k = P(E_k), \sum_{i=1}^k p_i = 1$.
η ανεξάρτητες δοκιμές και X_1, \dots, X_k εμφανίσεις, αντίστοιχα, $\sum_{i=1}^k X_i = n$.
 $(X_1, X_2, \dots, X_{k-1}) \sim M(n, p_1, p_2, \dots, p_{k-1})$

$$P_{X_1, \dots, X_{k-1}} = \frac{n!}{X_1! \dots X_{k-1}!} p_1^{X_1} \dots p_k^{X_k}, \quad \sum_{i=1}^k p_i = 1, \quad \sum_{i=1}^k X_i = n.$$

ΙΔΙΟΤΗΤΕΣ:

1) $X_i \sim B(n, p_i)$ $\text{Var}(X_i) = n \cdot p_i (1 - p_i)$

2) $(X_i, X_j) \sim M(n, p_i, p_j)$ $\text{Cov}(X_i, X_j) = n \cdot p_i p_j$

$$\sqrt{n} \left(\frac{X_1}{n} - p_1, \dots, \frac{X_k}{n} - p_k \right) \xrightarrow{n \rightarrow \infty} N_k(0, \Sigma)$$

Εκτίμηση με τη μέθοδο μέγιστης πιθανοφάνειας (ΕΜΠ)

Εστω X_1, \dots, X_n τ.δ. από πληθυσμό με σ.π. $P(x, \theta)$ ή σ.π.π. $f(x, \theta)$

Η συνάρτηση $L(\theta|X) = \prod_{i=1}^n P(x_i, \theta)$ ή $L(\theta|X) = \prod_{i=1}^n f(x_i, \theta)$ ονομάζεται συνάρτηση

πιθανοφάνειας (likelihood function).

Ο εκτιμητής $\hat{\theta} = \theta(X_1, \dots, X_n)$ του θ , λέγεται εκτιμητής μέγιστης πιθανοφάνειας (ΕΜΠ) του θ αν $L(\hat{\theta}|X) = \max_{\theta \in \Theta} L(\theta|X)$, όπου Θ ο παραμετρικός χώρος του θ .

ΠΑΡΑΤΗΡΗΣΕΙΣ:

α) Ισοδύναμα αν $\ln L(\hat{\theta}|X)$

β) κανένα, ένα ή πολλα πηπερασμένα.

ΠΑΡΑΔΕΙΓΜΑ 1: Εστω X_1, \dots, X_n τ.δ. από $Exp(\theta|1/\theta)$. ΕΜΠ;

ΛΥΣΗ

$$L(\theta|X) = \prod_{i=1}^n \frac{1}{\theta} e^{-\frac{x_i}{\theta}} = \frac{1}{\theta^n} e^{-\frac{\sum x_i}{\theta}} \text{ και}$$

$$\ln L(\theta|X) = -n \ln \theta - \frac{\sum x_i}{\theta},$$

$$\frac{\partial \ln L(\theta|X)}{\partial \theta} = -\frac{n}{\theta} + \frac{\sum x_i}{\theta^2} (=0 \rightsquigarrow)$$

$$\hat{\theta} = \frac{\sum_{i=1}^n x_i}{n} = \bar{X} \text{ με } \left. \frac{\partial^2 \ln L(\theta|X)}{\partial \theta^2} \right|_{\theta=\hat{\theta}} = \frac{n}{\theta^2} - \frac{2 \sum x_i}{\hat{\theta}^3} = \frac{n^3}{(\sum x_i)^2} - \frac{2n^3}{(\sum x_i)^2} = -\frac{n^3}{(\sum x_i)^2} < 0$$

άρα maximum

ΠΑΡΑΔΕΙΓΜΑ 2: Εστω τ.δ. X_1, \dots, X_n από $Poisson(\theta)$. ΕΜΠ;

ΛΥΣΗ:

$$L(\theta|X) = \prod_{i=1}^n \frac{e^{-\theta} \theta^{x_i}}{x_i!} = \frac{e^{-n\theta} \theta^{\sum x_i}}{\prod_{i=1}^n x_i!}$$

$$\ln L(\theta|X) = -n\theta + (\sum x_i) \ln \theta - \sum_{i=1}^n \ln x_i!$$

$$\frac{\partial \ln L(\theta|x)}{\partial \theta} = -n + \frac{\sum x_i}{\theta} \quad (=0 \rightarrow)$$


$$\hat{\theta} = \frac{\sum x_i}{n} = \bar{x}$$

$$\frac{\partial^2 \ln L(\theta|x)}{\partial \theta^2} \Big|_{\theta=\hat{\theta}} = -\frac{n^2}{\sum x_i} < 0, \text{ \u03c1\u03ac \u03c1\u03ac maximum.}$$

Εμπειρική Αθροιστική Συνάρτηση Κατανομής (ε.α.σ.κ.)

ΟΡΙΣΜΟΣ: Έστω x_1, \dots, x_n τ.δ. από πληθυσμό με α.σ.κ. $F(x)$. Η ε.α.σ.κ. $F_n(x)$ ισούται με το μέρος (ποσοστό) των x_i 's που είναι μικρότερη ή ίση του x , $-\infty < x < +\infty$. Δηλαδή

$$F_n(x) = \frac{\text{αριθμός των } x_i \text{'s } \leq x}{n} = \frac{\sum_{i=1}^n I_{(-\infty, x]}(x_i)}{n}, \quad x \in \mathbb{R} \text{ όπου } I_c(x_i) = \begin{cases} 1, & x_i \leq c \\ 0, & \text{αλλιώς} \end{cases}$$



Χρόνοι 5 μαθητών Άλυσαν
6.2, 5.6, 7.1, 6.4, 5.2

ΘΕΩΡΗΜΑ 1: Έστω x_1, \dots, x_n τ.δ. από πληθυσμό με α.σ.κ. $F(x)$. Για σταθερό x , η τ.μ. $n * F_n(x) \sim B(n, F(x))$, όπου $F_n(x)$ η ε.α.σ.κ.

ΑΠΟΔΕΙΞΗ: Οι δυνατές π.μές της ε.α.σ.κ. ανήκουν στο σύνολο $\{0, \frac{1}{n}, \dots, \frac{n-1}{n}, 1\}$.

Για σταθερό x , η π.μή της ε.α.σ.κ. είναι ίση με $\frac{k}{n}$, $k=0, 1, \dots, n$, αν k το

πλήθος βεγματοπιτών π.μών είναι $\leq x$. Άρα, ο υπολογισμός της $P(F_n(x) = \frac{k}{n})$ είναι η πιθανότητα να έχουμε k επιτυχίες σε n δοκιμές με $p = P(E) = P(X_i \leq x) = F(x)$.

$$\text{Άρα, } P(F_n(x) = \frac{k}{n}) = \binom{n}{k} [F(x)]^k [1-F(x)]^{n-k} \quad \eta'$$

$$P(n \cdot F_n(x) = k) = \binom{n}{k} [F(x)]^k [1-F(x)]^{n-k} \quad \eta'$$

$$n \cdot F_n(x) \sim B(n, F(x)).$$

$$E[n \cdot F_n(x)] = n \cdot F(x) \rightarrow E[F_n(x)] = F(x) \leftarrow \text{αμερόληπτος εκτιμητής.}$$

$$\text{Var}[n \cdot F_n(x)] = n[F(x)][1-F(x)] \rightarrow \text{Var}[F_n(x)] = \frac{F(x) \cdot [1-F(x)]}{n} \xrightarrow{n \rightarrow \infty} 0$$

$$F_n(x) \xrightarrow[n \rightarrow \infty]{\text{ασυμ.}} N\left(F(x), \frac{F(x)[1-F(x)]}{n}\right)$$