

Μάθημα 2ο

08/03/17

Ένας πληθυσμός - ένα δείγμα

χ^2 τεστ καλής προσαρμοχής

Έστω X_1, \dots, X_n τ.δ. από πληθυσμό με ασκ. $F(x)$.

Ενδιαφέρει ο έλεγχος: $H_0: F(x) = F_0(x)$ έναντι $H_a: F(x) \neq F_0(x)$.

Διαιρούμε τον δειγματικό χώρο σε k κατηγορίες, $i=1, \dots, k$,

και έστω n_i οι παρατηρούμενες συχνότητες των δεδομένων με $\sum_{i=1}^k n_i = n$

Υπολογίζουμε την πιθανότητα η τ.μ. X να πάρει τιμές στις k κατηγορίες και έστω $p_i = P(X \in i^{\text{οστη}} \text{ κατηγορία} | F_0(x))$

Έστω $e_i = np_i$ ή αναμενόμενη συχνότητα $[(n_1, \dots, n_k) \sim M(n, p_1, \dots, p_k)]$ ή $n_i \sim B(n, p_i)$

Karl-Pearson

$$\chi^2 = \sum_{i=1}^k \frac{(n_i - e_i)^2}{e_i} \underset{\text{ασυμπ.}}{\sim} \chi_{k-1}^2$$

γιατί: $\sum_{i=1}^k n_i = n = \sum_{i=1}^k n p_i$

η προσέδοση είναι καλύτερη αν $e_i \geq 1$
αλλιώς πρέπει να συμπληθούν οι κατηγορίες

παραμετροί s για ευήμιση, τότε $k-s-1$.

ΘΕΩΡΗΜΑ (Ζωγράφος-σελ.15): Αν $(n_1, \dots, n_k) \sim M(n, p_1, \dots, p_k)$ τότε η σ.σ.

$\chi^2 = \sum_{i=1}^k \frac{(n_i - n p_{i0})^2}{n p_{i0}} \underset{\text{ασυμ.}}{\sim} \left(\underset{n \rightarrow \infty}{d} \right) \chi_{k-1}^2$ όταν η $H_0: p_i = p_{i0}$, p_{i0} γνωστό, είναι αληθής

όπου, $0 < p_{i0} < 1$, $i=1, \dots, k$, $\sum_{i=1}^k p_{i0} = 1$


ΠΑΡΑΔΕΙΓΜΑ 1. (7.1).

$\chi^2 = \sum_{i=1}^k \frac{(n_i - e_i)^2}{e_i} \left(= \sum_{i=1}^k \frac{n_i^2}{e_i} - n \right) \sim \chi_{k-1}^2 \boxed{(k-s-1)}$

$n = 90$ $H_0: p_i = \frac{1}{6}, i=1, \dots, 6$ έναντι $H_a: p_i \neq \frac{1}{6}$, $e_i = n \cdot p_i = 90 \cdot \frac{1}{6} = 15$

πλευρά	1	2	3	4	5	6
συχνότητα (n_i)	13	17	16	18	12	14
αναμενομένη συχνότητα (e_i)	15	15	15	15	15	15

$\chi^2 = \sum_{i=1}^6 \frac{(n_i - e_i)^2}{e_i} = \frac{(13-15)^2}{15} + \dots + \frac{(14-15)^2}{15} = 1.87$



$\chi_{0.05, 6-1}^2 = \chi_{0.05, 5}^2 = 11.07$
↑
 α

$1.87 < 11.07$ δεν απορ. H_0 .

ΠΑΡΑΔΕΙΓΜΑ 2 (7.2), ΠΑΡΑΔΕΙΓΜΑ 3 (1.5, 1.6 - Μπασιόδης)

ΠΑΡΑΔΕΙΓΜΑ 4 (ανάλογο του 2)

$n = 340$

Τα δεδομένα έχουν ως εξής:

μεταβλήθηκε 3 φορές, 45 μέρες

Αριθμός ημερήσιων μεταβολών (X)	0	1	2	3	4	5	6	≥ 7
συχνότητα (n _i)	62	123	84	45	17	5	3	1

X = αριθμός μεταβολών πρ μετοχής κατά τη διάρκεια μιας μέρας.

$$H_0: F(x) = F_0(x) = P(X) = P(X=x) = \frac{e^{-\lambda} \lambda^x}{x!}, \quad x=0, 1, \dots$$

$$H_a: F(x) \neq P(\lambda)$$

$$\hat{\lambda} = \bar{x} = \frac{\sum x_i \cdot f_i}{n} = 1.6$$

Άρα, $F(x) = F_0(x) = P(\lambda = 1.6)$

X	$P(X=x_i) = p_i$	n _i	$e_i = n \cdot p_i$	i
0	0.2012	62	68.696	1
1	0.3230	123	109.820	2
2	0.2584	84	87.856	3
3	0.1378	45	46.852	4
4	0.0551	17	18.734	5
5	0.0176	5	5.984	6
6	0.0047	3	1.5982	7
≥ 7	0.0011	1	1 > 0.374	8

340

↳ παίρνουμε στις δεξιότητες υποθέσεις και τις ευνωχούμε

$$\chi^2 = \sum_{i=1}^7 \frac{(n_i - e_i)^2}{e_i} = \frac{(62 - 68.696)^2}{68.696} + \dots + \frac{(4 - 1.972)^2}{1.972} = 4.874$$

Επειδή $4.874 < 11.07 = \chi_{0.05, 5}^2$ ($k - s - 1 = 7 - 1 - 1$)
δεν απορρίπτω H_0 .

Τεστ Kolmogorov-Smirnov

Έστω X_1, \dots, X_n τ.δ. από πληθυσμό με α.σ.κ. $F(x)$.

Ενδιαφέρει: $H_0: F(x) = F_0(x)$ έναντι $H_a: F(x) \neq F_0(x)$

Ο έλεγχος γίνεται με το στατιστικό: $D_n = \sup_x |F_n(x) - F_0(x)|$, όπου, $F_n(x) = \frac{\text{αρ. παραμρ. } X_i \leq x}{n}$
είναι η ε.α.σ.κ. $= \frac{1}{n} \sum_i I(X_i \leq x)$

Ισοδύναμα, $D_n = \max_x |F_n(x) - F_0(x)|$ με κρίσιμη περιοχή $D_n \geq D_{n,\alpha}$

ΠΑΡΑΔΕΙΓΜΑ 1 (7.3)

0.79, 0.15, 0.43, 0.01, 0.93, 0.15, 0.27, 0.19, 0.32, 0.96 // $U(0,1)$, $n=10$.

$H_0: F(x) = F_0(x) = U(0,1)$ έναντι $H_a: F(x) \neq U(0,1)$

$f(x) = 1, 0 < x < 1$ και $F(x) = \begin{cases} 0 & x < 0 \\ x & 0 < x < 1 \\ 1 & x \geq 1 \end{cases}$ αφού $F(x) = \int_0^x 1 dx$

X_i	0.01	0.15 (2)	0.19	0.27	0.32	0.43	0.79	0.93	0.96
$F_0(x_i)$	0.01	0.15	0.19	0.27	0.32	0.43	0.79	0.93	0.96
$F_n(x_i)$	1/10	3/10	4/10	0.5	0.6	0.7	0.8	0.9	1
$ F_n(x_i) - F_0(x_i) $	0.09				<u>0.28</u>				

$D_n = \max_{x_i} |F_n(x_i) - F_0(x_i)| = 0.28 < D_{n,\alpha} = D_{10,0.05} = 0.409$, δεν απορρίπτω H_0 .

ΠΑΡΑΔΕΙΓΜΑ 2

33.3, 31.4, 31.0, 33.4, 33.5, 37.0, 36.2, 34.9, 33.7, 34.4

$n=10$, $N(\mu=32, \sigma^2=3.24)$, $\sigma=1.8$.

$X \sim N(\mu, \sigma^2) \Rightarrow Z = \frac{X - \mu}{\sigma} \sim N(0,1)$

$H_0: F(x) = F_0(x) = N(\mu=32, \sigma^2=3.24)$ έναντι $H_a: F(x) \neq N(\mu=32, \sigma^2=3.24)$.

π.χ. $F_0(31.0) = P(X \leq 31.0) = P(Z = \frac{X - \mu}{\sigma} \leq \frac{31 - 32}{1.8}) = P(Z \leq -0.55) = 0.2912$ κ.λ.π.

X_i	31.0	31.4	33.3	33.4	33.5	33.7	34.4	34.9	36.2	37.0
$F_0(x_i)$	0.2912	0.3707	0.7642	0.7823	0.7967	0.8264	0.9082	0.9463	0.9901	0.9973
$F_n(x_i)$	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
$ F_n(x_i) - F_0(x_i) $	0.1912	0.1767	0.4642	0.3823	0.2967	0.2264	0.2082	0.1463	0.0901	0.0027

Επειδή $D_n = 0.4642 > D_{n,\alpha} (= D_{10,0.05}) = 0.409$, άρα απορρίπτω την H_0

δηλαδή τα δεδομένα δεν προέρχονται από $N(\mu=32, \sigma^2=3.24)$.