

Χαρακτηριστικό, Τυχαίο Δείγμα και παρατηρήσεις

X : χαρακτηριστικό (δέντρα)

Έχω δείγμα μεγέθους $n(=100)$

$X_1, X_2, X_3, \dots, X_{100}$

τυχαίες μεταβλητές
(κάθε φορά που κάνω δει-
γματοληψία έχω αλλη-
γήνη τιμή)

Έχω πάρει ένα συγκεκριμένο
δείγμα

$x_1 = 0$ $x_2 = 5$ $x_3 = 1$ $x_4 = 0$ $x_5 = 0$ ----- $x_{100} = 1$

(έχω διακριτό χαρακτηριστικό)

συχνότητα	0	1	2	3	4	5
	46	32	8	11	2	1



από τις x_1, \dots, x_{100} οι 46 ισούται με 0

Εκτιμητές των παραμέτρων- εκτίμηση από το συγκεκριμένο δείγμα

Το θ είναι η μέση τιμή: (πληθυσμός)

$$E(X) = \sum_{x=0}^{\infty} x P(X=x) \rightarrow \text{από το θεωρητικό μοντέλο}$$

↓ expected value $E(X) = \theta$

$$\bar{X} = \sum_{i=1}^n X_i \frac{1}{n} \rightarrow \text{από τις παρατηρήσεις του δείγματος}$$

↓ δειγματικός μέσος

$$\theta = \bar{X} \quad (\text{εκτιμητής: συνάρτηση των παρατηρήσεων})$$


Εκτίμω την άγνωστη παράμετρο από την αντίστοιχη δειγματική της τιμή.

κάθε φορά \bar{x} είναι διαφορετικό
(έχει άλλη τιμή για κάθε δείγμα)

και έτσι παίρνω μια εκτίμηση για το θ . Μπορώ να ^{βάλω} την συγκεκριμένη τιμή στο μοντέλο και να το προσδιορίσω πάλι ως

**Δείγμα από τη συγκέντρωση ενός συγκεκριμένου
ρύπου (σε mgr/cm³) σε δείγματα αέρος από 57 πόλεις**

68 63 42 27 30 36 28 32 79 27 22 23 24 25 24
65 43 25 74 51 36 42 28 31 28 25 45 12 57 51
12 32 49 38 42 27 31 50 38 21 16 24 69 47 23
22 43 27 49 48 23 12 19 46 30 49 49




$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} = \frac{68 + 63 + 42 + \dots + 30 + 49 + 49}{57} = \frac{2099}{57} = 36.82 \text{ mgr/cm}^3$$

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n - 1} = \frac{(68 - 36.82)^2 + (63 - 36.82)^2 + \dots + (49 - 36.82)^2}{56}$$

$$= \frac{971.90 + 685.15 + \dots + 148.24}{56} = \frac{14366.25}{56} = 256.54 = (16.02)^2$$

$$S = 16.02 \text{ mgr/cm}^3$$

Όρια κλάσης L_i-U_i	Κεντρική τιμή x_i	Συχνότητα f_i	Αθροιστική Συχνότητα F_i
[10-20)	15	5	5
[20-30)	25	19	24
[30-40)	35	10	34
[40-50)	45	13	47
[50-60)	55	4	51
[60-70)	65	4	55
[70-80]	75	2	57
		57	



Cases weighted by Frequency

$$\bar{X} = \frac{\sum_{i=1}^K x_i f_i}{\sum_{i=1}^K f_i} = \frac{15 \times 5 + 25 \times 19 + \dots + 65 \times 4 + 75 \times 2}{5 + 19 + \dots + 4 + 2} = \frac{2115}{57} = 37.11 \text{ mgr/cm}^3$$

$$S^2 = \frac{\sum_{i=1}^K (X_i - \bar{X})^2 f_i}{n - 1} = \frac{(15 - 37.11)^2 \times 5 + (25 - 37.11)^2 \times 19 + \dots + (75 - 37.11)^2 \times 2}{56}$$
$$= \frac{2443.21 + 2784.21 + \dots + 2872.02}{56} = \frac{13347.37}{56} = 238.34 = (15.43)^2$$

$$S = 15.43 \text{ mgr/cm}^3$$

Statistics

Pollution

N	Valid	57
	Missing	0
Mean		37.11
Mode		25
Std. Deviation		15.438
Variance		238.346
Percentiles	25	24.79 ^a
	50	34.66
	75	47.65

a. Percentiles are calculated from grouped data.

Pollution

Όρια κλάσης $L_i - U_i$		Frequency	Percent	Αθροιστική Συχνότητα F_i	Cumulative Percent
[10-20)	15	5	8.8	5	8.8
[20-30)	25	19	33.3	24	42.1
[30-40)	35	10	17.5	34	59.6
[40-50)	45	13	22.8	47	82.5
[50-60)	55	4	7.0	51	89.5
[60-70)	65	4	7.0	55	96.5
[70-80]	75	2	3.5	57	100.0
	Total	57	100.0		

$$\delta = Q_2 = L_3 + \frac{\frac{n}{2} - F_2}{f_3} c = 30 + \frac{28.5 - 24}{10} 10$$

$$= 30 + 4.5 = 34.5 \text{ mgr/cm}^3$$

Διάμεσος (Median) δ

• ενός πεπερασμένου συνόλου τιμών μιας μεταβλητής ή παρατηρήσεων είναι εκείνη η τιμή που χωρίζει το σύνολο σε δύο ίσα μέρη
 Δηλ. $50\% \text{ παρατηρήσεων} \geq \delta$
 $\quad \quad \quad \quad \quad \quad \quad \quad \leq \delta$

• Διατάσσουμε τις παρατηρήσεις κατά αύξουσα σειρά μεγέθους. Έστω το πλήθος των παρατηρήσεων n είναι περιττό τότε η διάμεσος είναι η μεσαία τιμή. Έστω το n είναι άρτιο $\delta = \text{κρυφθροισμα των δύο μεσαίων παρατηρήσεων}$

• Σε ομαδοποιημένες παρατηρήσεις η διάμεσος δίνεται από τον τύπο

$$\delta = L_i + \frac{\frac{n}{2} - F_{i-1}}{f_i} \cdot c$$

L_i : το κάτω αλγεθινό όριο της υλάεως που βριέεται
 n : πλήθος παρατηρήσεων
 f_i : η διάμεσος

$F_{i-1} = \sum_{j=1}^{i-1} f_j$ το αθροισμα των συχνοτήτων μέχρι των προηγούμενων υλάων

c : εύρος της υλάεως

με i τέτοιο ώστε $F_{i-1} < n/2 \leq F_i$

$$\frac{n}{2} = 28.5 \quad F_2 = 24 < 28.5 \leq 34 = F_3$$

Όρια κλάσης $L_i - U_i$	Κεντρική τιμή x_i	Συχνότητα f_i	Αθροιστική Συχνότητα F_i
[10-20)	15	5	5
[20-30)	25	19	24
[30-40)	35	10	34
[40-50)	45	13	47
[50-60)	55	4	51
[60-70)	65	4	55
[70-80]	75	2	57
		57	

• Για ομαδοποιημένες παρατηρήσεις

$$p_k = L_i + \left(\frac{\frac{kn}{100} - F_{i-1}}{f_i} \right) c$$

με i τέτοιο ώστε $F_{i-1} < k \cdot n/100 \leq F_i$

• 1^ο τεταρτημόριο

$$Q_1 = L_i + \left(\frac{\frac{n}{4} - F_{i-1}}{f_i} \right) c$$

• 2^ο τεταρτημόριο (Μέσος)

$$\bar{x} = L_i + \left(\frac{\frac{n}{2} - F_{i-1}}{f_i} \right) c$$

• 3^ο τεταρτημόριο

$$Q_3 = L_i + \left(\frac{\frac{3n}{4} - F_{i-1}}{f_i} \right) c$$

$$\frac{n}{4} = 14.25$$

$$F_1 = 5 < 14.25 \leq 24 = F_2$$

$$\frac{3n}{4} = 42.75$$

$$F_3 = 34 < 42.75 \leq 47 = F_4$$

$$Q_1 = L_2 + \frac{\frac{n}{4} - F_1}{f_2} c = 20 + \frac{14.25 - 5}{19} 10 = 20 + 4.49 = 24.49 \text{ mgr/cm}^3$$

$$Q_3 = L_4 + \frac{\frac{3n}{4} - F_3}{f_4} c = 40 + \frac{42.75 - 34}{13} 10 = 40 + 6.73 = 46.73 \text{ mgr/cm}^3$$

• Σε ομαδοποιημένες παρατηρήσεις η κορυφή δίνεται από τον τύπο

$$M_0 = L_i + \frac{\Delta_1}{\Delta_1 + \Delta_2} \cdot c$$

$$\Delta_1 = f_i - f_{i-1}$$

$$\Delta_2 = f_i - f_{i+1}$$

$$M = L_2 + \frac{\Delta_1}{\Delta_1 + \Delta_2} c = 20 + \frac{14}{14 + 9} 10 = 20 + 6.09 = 26.09 \text{ mgr/cm}^3$$

με i τέτοιο ώστε $f_i > f_j$ για κάθε $j \neq i$

$$\max f_i = f_2 = 19$$

$$\Delta_1 = f_2 - f_1 = 19 - 5 = 14 \quad \Delta_2 = f_2 - f_3 = 19 - 10 = 9$$

Εναλλακτικός τύπος υπολογισμού της διασποράς

κεντρική τιμή ομαδοποιημένες παρατηρήσεις

$$S^2 = \frac{1}{n-1} \sum_{i=1}^K (x_i - \bar{x})^2 f_i \quad \text{διασπορά} \quad K: \text{πλήθος κλάσεων}$$

x_i : αντιπρόσωπος για τις f_i το πλήθος παρατηρήσεων για i κλάση

$$= \frac{1}{n-1} \sum_{i=1}^K (x_i^2 - 2\bar{x}x_i + \bar{x}^2) f_i$$

$$= \frac{1}{n-1} \left\{ \sum_{i=1}^K x_i^2 f_i - 2\bar{x} \sum_{i=1}^K x_i f_i + \bar{x}^2 \sum_{i=1}^K f_i \right\} \quad \bar{x} = \frac{1}{n} \sum_{i=1}^K x_i f_i$$

$$= \frac{1}{n-1} \left\{ \sum_{i=1}^K x_i^2 f_i - 2n\bar{x}^2 + n\bar{x}^2 \right\} \quad n\bar{x} = \sum_{i=1}^K x_i f_i$$

$$= \frac{1}{n-1} \left\{ \sum_{i=1}^K x_i^2 f_i - n\bar{x}^2 \right\} = \frac{1}{n-1} \left\{ \sum_{i=1}^K x_i^2 f_i - n \left(\frac{\sum x_i f_i}{n} \right)^2 \right\}$$

$$= \frac{1}{n-1} \left\{ \sum_{i=1}^K x_i^2 f_i - \frac{(\sum x_i f_i)^2}{n} \right\}$$

Γραμμικός Μετασχηματισμός των παρατηρήσεων

Έστω $y_i = \alpha x_i + \beta$

$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$

$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

αλλαγή θέσης
υπόμακας

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n} = \frac{\sum_{i=1}^n (\alpha x_i + \beta)}{n} = \frac{\sum_{i=1}^n \alpha x_i}{n} + \frac{\sum_{i=1}^n \beta}{n} = \alpha \frac{\sum_{i=1}^n x_i}{n} + \frac{n\beta}{n}$$
$$= \alpha \bar{x} + \beta$$

$$S_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \sum_{i=1}^n (\alpha x_i + \beta - (\alpha \bar{x} + \beta))^2$$

$$= \frac{1}{n-1} \sum_{i=1}^n (\alpha x_i - \alpha \bar{x})^2 = \frac{1}{n-1} \sum_{i=1}^n [\alpha (x_i - \bar{x})]^2$$

$$= \alpha^2 \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \Rightarrow S_y^2 = \alpha^2 \cdot S_x^2 \Rightarrow S_y = |\alpha| S_x$$

Τα ποσοστιαία σημεία και η κορυφή μετασχηματίζονται,
«όπως αριζώνως» και οι παρατηρήσεις προσοχή για $\alpha < 0$