

Μέθοδος Διασποράς

ΕΥΡΟΣ $R = \max x_i - \min x_i$

$$\bar{x} = \frac{1}{n} \sum x_i$$

2, 2, 4, 4, (15) $\rightarrow S$ ΔΙΑΚΥΜΑΝΣΗ S^2 ΑΠΕΥΘΕΙΑΣ από x_1, \dots, x_n

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

$$\sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \sum_{i=1}^n x_i^2 - 2\bar{x} \underbrace{\left(\sum_{i=1}^n x_i \right)}_{n\bar{x}} + n\bar{x}^2 =$$

$$EX = \mu, \quad \text{Var } X = 6^2$$

$$\text{Var } X = E(X - \mu)^2 = EX^2 - (EX)^2$$

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

Η διακύμανση δείχνει πως κατανομονται τα δεδομένα γύρω από τη μέση τιμή.

Συνδυάζοντας, $S^2 = \frac{1}{n-1} \sum (x_i - \bar{x})^2$ και ο λόγος είναι μαζί τότε

$$n ES^2 = 6^2$$

↑
αναμενόμενη τιμή
του S^2

$$\text{ΑΠΕΥΘΕΙΑΣ: } S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$\text{ΔΙΑΤΕΤΑΓΜΕΝΟΣ: } S^2 = \frac{1}{n-1} \sum_{j=1}^k (x_j - \bar{x})^2 f_j$$

$$\text{ΟΜΑΔΟΠΟΙΗΜΕΝΟΣ: } S^2 = \frac{1}{n-1} \sum_{j=1}^k (m_j - \bar{x})^2 f_j$$

→ το πλήθος των διακεκριμένων μετρήσεων

→ το πλήθος των ομάδων

x_1, \dots, x_{15}


$\bar{x} = 60$

$S^2_x = 7$

y_1, \dots, y_{10}

$\bar{y} = 60$

$S^2_y = 3$



Παρατήρηση: Αν έχω 2 ή περισσότερα δείγματα, αυτό που έχει την μικρότερη διακύμανση είναι πιο ομοιογενές.

Συντελεστής μεταβλητότητας C.V. (coefficient of variation)

$$C.V = \frac{S}{|\bar{x}|} \rightarrow \text{θετική ρίζα της διακύμανσης} - \text{τυπική απόκλιση } \text{Var} X = \sigma^2 \text{ διακύμανση}$$

$$\text{ή } \frac{S}{|\bar{x}|} \times 100\%$$

Ο συντελεστής μεταβλητότητας χρησιμοποιείται για να συγκριθούν δύο δείγματα που έχουν διαφορετικές μέγες τιμές ως προς την μεταβλητότητα τους.


Ορισμός: Ένα δείγμα λέγεται ομοιογενές αν ο συντελεστής μεταβλητότητας είναι μικρότερος ή ίσος από το 10%.

Μέτρα κλίματος και παρατηρήσεις για τη μορφή των δεδομένων


$\mu = \bar{x}, M, k$

- Αν \bar{x}, M, k είναι "κοντά" και επιπλέον έχουμε μονοκόρυφη κορυφή (k μοναδικό) τότε λέμε ότι έχουμε συμμετρική κατανομή (π.χ. κανονική)
- Αν $\bar{x} > M > k$ λέμε ότι έχουμε θετική ασυμμετρία ενώ αν έχουμε $\bar{x} < M < k$ λέμε ότι έχουμε αρνητική ασυμμετρία.

θετική



αρνητική



$$b_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{n S^3}$$

→ συντελεστής λοξότητας

- ≈ 0 συμμετρική
- < 0 θετική ασυμμετρία, η λοξότητα σεβεία
- > 0 λοξότητα αριστερά

$$b_2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{n s^4} \rightsquigarrow \# \text{ κύρτωσης} \begin{cases} \text{ΛΕΠΤΟΚΥΡΤΕΣ} \\ > 3 \\ \text{ΜΕΣΟΚΥΡΤΕΣ} \\ \approx 3 \\ \text{ΠΛΑΤΥΚΥΡΤΕΣ} \end{cases}$$

ΔΕΙΓΜΑΤΙΚΕΣ ΚΑΤΑΝΟΜΕΣ

Έστω x_1, x_2, \dots, x_n είναι τυχαίο δείγμα (τ.δ.) $\rightarrow x_1, \dots, x_n$ είναι ισόνομες τ.μ. (ανεξάρτητες μεταξύ τους) από έναν πληθυσμό με β.π.π. ή β.π. $f(x, \theta)$ όπου θ άγνωστη παράμετρος

$$f(x, \lambda) = \lambda e^{-\lambda x}, \quad x \geq 0$$

$$\lambda = 5$$

Έστω x_1, \dots, x_n από θ άγνωστη παράμετρος. Ο στόχος είναι να εξαγάγουμε υπεραρκάματα για την άγνωστη παράμετρο θ , με την βοήθεια συναρτήσεων των x_1, x_2, \dots, x_n . Προφανώς αυτές οι συναρτήσεις δεν περιέχουν άγνωστες παραμέτρους. Λέγονται στατιστικές συναρτήσεις ή απλώς στατιστικά.

$T = T(x_1, \dots, x_n) \rightarrow$ είναι τ.μ. \rightarrow έχουν κατανομή \rightarrow πρέπει να την προσδιορίσω

$$N(\mu, \sigma^2) \quad \sigma^2 : \text{γνωστή} \quad \sum \frac{x_i}{6}$$

Αυτές οι κατανομές συνήθως λέγονται δειγματικές κατανομές και μας βοηθούν στην εξαγωγή υπεραρκάτων από το δείγμα για τον πληθυσμό (επαγωγική στατιστική).

Στη συνέχεια θα μελετήσουμε κάποιες κατανομές που προκύπτουν από την κανονική κατανομή και εμφανίζονται συχνά ως δειγματικές κατανομές.

χ^2 - κατανομή με n βαθμούς ελευθερίας τυπική κατανομή

Ορισμός: Έστω x_1, x_2, \dots, x_n τ.δ. από την $N(0,1)$. Τότε η κατανομή της $Y = x_1^2 + x_2^2 + \dots + x_n^2$ λέμε ότι ακολουθεί χ^2 κατανομή με n βαθμούς ελευθερίας και συμβολίζεται χ_n^2


$$\left. \begin{aligned} X_1 &\sim N(0,1) \\ X_2 &\sim N(0,1) \end{aligned} \right\} \text{ανεξάρτητα}$$

$$Z = X_1^2 + X_2^2$$

$$Z \sim \chi^2_2$$

$$\chi^2_n \equiv \text{Gamma}\left(\frac{n}{2}, 2\right)$$

↓
ταυτιζόταν



$$E \chi^2_n = \frac{n}{2} \cdot 2, \quad \text{Var } \chi^2_n = 2^2 \cdot \frac{n}{2} = 2n$$

Όταν $Z \sim N(0,1)$ συμβολίζουμε Z_α το σημείο εκείνο τ.ω. $P(Z \geq Z_\alpha) = \alpha$


Όταν χ^2_n συμβολίζω με $\chi^2_{n,\alpha}$
 $P(\chi^2_n \geq \chi^2_{n,\alpha}) = \alpha$

t-κατανομή με n βαθμούς ελευθερίας

Έστω $X \sim N(0,1)$ και $Y \sim \chi^2_n$. Επιπλέον X, Y ανεξάρτητες. Τότε η κατανομή της $Z = \frac{X}{\sqrt{Y/n}} \sim t_n$. Λέμε ότι ακολουθεί την t με n


βαθμούς ελευθερίας.

Παρατήρηση: Η κατανομή αυτή είναι γνωστή ως κατανομή Student που είναι το ψευδώνυμο του Gosset.



συμμετρική γύρω από το 0.
(σελ. 75)

Όσο αυξάνονται οι βαθμοί ελευθερίας ($n \rightarrow \infty$) η t_n με n βαθμούς ελευθερίας τείνει στην $N(0,1)$. $t_{n,\alpha}$ είναι εκείνο το σημείο $P(t_n \geq t_{n,\alpha}) = \alpha$



$-t_{n, \alpha}$ είναι το αντίστοιχο εκείνο $P(t_n \geq \underbrace{-t_{n, \alpha}}_{t_{n, 1-\alpha}}) = 1 - \alpha$

$$-t_{n, \alpha} = t_{n, 1-\alpha}$$

$$P(t_n \leq -t_{n, \alpha}) = \alpha$$

Η μέση τιμή της t_n : $E(t_n) = 0$, $n > 1$

$$EX = \int_{\pi.o.} x f_X(x) dx$$

$t_1 \rightarrow$ Cauchy δεν υπάρχει η $E(t_1)$

$$\text{Var}(t_n) = \frac{n}{n-2}, \quad n > 2$$