

Lecture 18

Ο Κανόνας του Chebychev

Αυτός ο κανόνας ισχύει για όλες τις συλλογές δεδομένων ανεξάρτητα αν αυτές είναι συμμετρικές.

“ Σε απόσταση k τυπικών αποκλίσεων από τον μέσο όρο υπάρχουν τουλάχιστον

$$\left(1 - \frac{1}{k^2}\right)$$

ποσοστό τιμών του δείγματος”.

Παράδειγμα:

1). Αν $k=2$

$$\left(\bar{X} - 2S, \bar{X} + 2S\right) \Rightarrow 1 - \frac{1}{4} = \frac{3}{4} \rightarrow 75\%$$

$k=3$

$$\left(\bar{X} - 3S, \bar{X} + 3S\right) \Rightarrow 1 - \frac{1}{9} = \frac{8}{9} \rightarrow 89\%$$

$k=4$

$$\left(\bar{X} - 4S, \bar{X} + 4S\right) \Rightarrow 1 - \frac{1}{16} = \frac{15}{16} \rightarrow 94\%$$

2). Για μια συλλογή δεδομένων έχω ότι : δειγματικός μέσος όρος =11 και $S=2$. Ας υποθέσουμε ότι η κατανομή είναι άγνωστη. Μεταξύ ποιών ορίων υπάρχει το 85% των τιμών του δείγματος;

Έχω ότι:

$$1 - \frac{1}{k^2} = \frac{85}{100} \Rightarrow k = 2.85$$

Άρα

$$\left(\bar{X} - 5.8S, \bar{X} + 5.8S\right) = (11 - 2.58 \cdot (2), 11 + 2.58 \cdot (2)) = (5.84, 16.16)$$

Εύρος Τεταρτημορίων

$$IQR=Q3-Q1$$

Πως περιγράφουμε το σχήμα μιας κατανομής;

Από την στατιστική συνάρτηση Λοξότητα η οποία μας δείχνει πόσο απέχει μια συλλογή δεδομένων από την συμμετρία.

Συντελεστής Λοξότητας:

$$S_k = 3 \frac{(\bar{X} - \text{διάμεσος})}{S}$$

Αν

$S_k=0 \Rightarrow$ συμμετρική κατανομή


$S_k<0 \Rightarrow$ αρνητικά λοξή κατανομή

$S_k>0 \Rightarrow$ θετικά λοξή κατανομή


α) συμμετρική : διάμεσος = μέσο = επικρατούσα τιμή




β) αρνητικά λοξή ή λοξή προς τα αριστερά




γ) θετικά λοξή ή λοξή προς τα δεξιά





Box-Plots:

Τα Box-Plots είναι διαγράμματα τα οποία κάνουν χρήση του τεταρτημόριου για να δώσουν μια γραφική παράσταση μιας συλλογής δεδομένων.



Σημεία τα οποία μπορεί να είναι μεγαλύτερα από $Q3 + I.S * (IQR)$ ή μικρότερα από $Q1 - I.S * (IQR)$ ονομάζονται outliers.

Παράδειγμα :

Η ηλικία νέων διευθυντικών στελεχών:

35	37	37	39	40	40
41	41	43	43	43	43
44	44	44	44	44	45
45	46	46	46	46	48

$$Q_1 = \frac{25}{100} \times 24 = 6$$

$$Q_1 = \frac{40 + 41}{2} = 40.5$$


$$Q_3 = \frac{75}{100} \times 24 = 18$$

$$Q_3 = \frac{45 + 45}{2} = 45$$

$$\text{Διάμεσος} = \frac{43 + 44}{2} = 43.5$$

$$\text{min} = 35$$

$$\text{max} = 48$$



Ο μέσος όρος σαν τυχαία μεταβλητή

Έστω $X_1, X_2 \sim f(X)$ ανεξάρτητες με :

$$EX_1 = EX_2 = \mu$$

και

$$VarX_1 = VarX_2 = \sigma^2$$

Ο μέσος όρος είναι:

$$\left(\bar{X} = \frac{X_1 + X_2}{2} \right)$$

Είναι μια τυχαία μεταβλητή με :

$$E\left(\bar{X}\right) = \frac{1}{2}\mu + \frac{1}{2}\mu = \mu$$

και

$$\text{Var}X = \frac{\sigma^2}{2}$$

Γενικά αν X_1, \dots, X_n ανεξάρτητες και ισόνομες τότε

$$E(\bar{X}) = E(X_1) = \mu$$

και

$$\text{Var}(\bar{X}) = \frac{\sigma^2}{n}$$

Επιπλέον αν

$$X_1, \dots, X_n \sim N(\mu, \sigma^2)$$

τότε ισχύει ότι:

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

γιατί ο γραμμικός συνδιασμός είναι κανονική.