

Βασικά Χαρακτηριστικά Αριθμητικών Δεδομένων

- Τάση συγκέντρωσης → Μέτρα Κεντρικής Τάσης και Θέσης
- Τάση διασποράς → Μέτρα Διασποράς
- Σχήμα → Σχήμα της κατανομής

Μέτρα Κεντρικής Τάσης & Θέσης

- Αριθμητικός Μέσος
- Γεωμετρικός Μέσος
- Αρμονικός Μέσος

Μέτρα Κεντρικής Τάσης

- Διάμεσος ή Κεντρική Τιμή
- Τεταρτημόρια
- Τύπος ή Επικρατούσα Τιμή

Μέτρα Κεντρικής Θέσης

Αριθμητικός Μέσος

*Απλός ή Αστάθμιστος
Αριθμητικός Μέσος*

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

Παράδειγμα

| | | | | | |
|-----|-----|-----|-----|-----|-----|
| 2 | 2,1 | 2,3 | 3,2 | 3,2 | 2,3 |
| 3,3 | 4,1 | 3,3 | 3,5 | 3,5 | 3,5 |
| 3,7 | 3,7 | 3,7 | 5,7 | 3,9 | 3,9 |
| 3,9 | 3,9 | 4,1 | 4,3 | 4,3 | 4,3 |
| 4,4 | 4,4 | 4,5 | 5,7 | 5,7 | 6 |

$$\bar{X} = \frac{116,4}{30} = 3,88$$

Σταθμικός Αριθμητικός Μέσος

$$\bar{X} = \frac{\sum_{i=1}^n w_i X_i}{\sum_{i=1}^n w_i}$$

Παράδειγμα

| Τιμή (X) | Ποσότητα (w) | $w_i X_i$ |
|----------|--------------|----------------|
| 120 | 1000 | 120000 |
| 150 | 5000 | 750000 |
| 180 | 6000 | 1080000 |
| 200 | 3000 | 600000 |
| | 15000 | 2550000 |
| | | |

$$\bar{X} = \frac{2550000}{15000} = 170$$

Αριθμητικός Μέσος Κατανομής Συχνοτήτων

Παράδειγμα

| X_i | f_i | $f_i X_i$ |
|-------|-------|-----------|
| 2,0 | 1,0 | 2,0 |
| 2,1 | 1,0 | 2,1 |
| 2,3 | 2,0 | 4,6 |
| 3,2 | 2,0 | 6,4 |
| 3,3 | 2,0 | 6,6 |
| 3,5 | 3,0 | 10,5 |
| 3,7 | 3,0 | 11,1 |
| 3,9 | 4,0 | 15,6 |
| 4,1 | 2,0 | 8,2 |
| 4,3 | 3,0 | 12,9 |
| 4,4 | 2,0 | 8,8 |
| 4,5 | 1,0 | 4,5 |
| 5,7 | 3,0 | 17,1 |
| 6,0 | 1,0 | 6,0 |

$$\bar{X} = \frac{\sum_{i=1}^k f_i X_i}{\sum_{i=1}^k f_i}$$

$$\bar{X} = \frac{116,4}{30} = 3,88$$

*Αριθμητικός Μέσος Κατανομής
Συχνοτήτων
(Τάξεις μεγέθους)*

Παράδειγμα

| | f_i | X_i | $f_i X_i$ |
|-----------|-------|-------|-----------|
| 2,0 - 2,9 | 4 | 2.45 | 9.8 |
| 3,0 - 3,9 | 14 | 3.45 | 48.3 |
| 4,0 - 4,9 | 8 | 4.45 | 35.6 |
| 5,0 - 6,0 | 4 | 5.5 | 22 |
| | 30 | | 115.7 |

$$\bar{X} \approx \frac{\sum_{i=1}^k f_i X_i'}{\sum_{i=1}^k f_i}$$

$$\bar{X} \approx \frac{115,5}{30} = 3,85$$

- ☀ Αποτελεί το πιο σημαντικό μέτρο κεντρικής τάσης
- ☀ Επηρεάζεται από όλες τις τιμές

Γεωμετρικός Μέσος

Απλός Γεωμετρικός Μέσος

$$G = \sqrt[n]{\prod_{i=1}^n X_i}$$

ή

$$\log G = \frac{1}{n} \sum_{i=1}^n \log X_i$$

Παράδειγμα

| | | | | | |
|-----|-----|-----|-----|-----|-----|
| 2,0 | 2,1 | 2,3 | 3,2 | 3,2 | 2,3 |
| 3,3 | 4,1 | 3,3 | 3,5 | 3,5 | 3,5 |
| 3,7 | 3,7 | 3,7 | 5,7 | 3,9 | 3,9 |
| 3,9 | 3,9 | 4,1 | 4,3 | 4,3 | 4,3 |
| 4,4 | 4,4 | 4,5 | 5,7 | 5,7 | 6,0 |

$$G = e^{\left(\frac{39,62051}{30}\right)} = 3,75$$

*Γεωμετρικός Μέσος Κατανομής
Συχνοτήτων*

$$G = \sum_{i=1}^k f_i \sqrt[k]{\prod_{i=1}^k X_i^{f_i}}$$

ή

$$\log G = \frac{1}{\sum_{i=1}^k f_i} \sum_{i=1}^k f_i \log X_i$$

Ιδιότητες Γεωμετρικού Μέσου

- α) Για να υπολογιστεί απαιτείται $X_i > 0 \quad \forall i$
- β) $G \leq \bar{X}$
- γ) Επηρεάζεται λιγότερο από τις ακραίες τιμές
- δ) Δεν έχει ευρεία εφαρμογή

Αρμονικός Μέσος

Απλός Αρμονικός Μέσος

$$H = \frac{n}{\sum_{i=1}^n \frac{1}{X_i}}$$

Αρμονικός Μέσος Κατανομής Συχνοτήτων

$$H = \frac{\sum_{i=1}^k f_i}{\sum_{i=1}^k f_i \frac{1}{X_i}}$$

Ιδιότητες Αρμονικού Μέσου

$$H \leq G \leq \bar{X}$$

Παράδειγμα

Ένα προϊόν πωλείται σε τρία καταστήματα σε διαφορετική τιμή. Με 10000 δρχ. μπορούν να αγοραστούν 10 μονάδες στο 1ο κατάστημα, στο 2ο κατάστημα 8 μονάδες και στο 3ο 16 μονάδες. Ζητείται ο αριθμός των μονάδων που μπορούν να αγοραστούν κατά μέσο όρο με 10000 δρχ.

$$Α. \text{ Μέσος} = (10+8+16)/3 = 11,333 \longrightarrow \text{Μέση Τιμή} = 10000/11,333 = 882,3$$

$$\text{Πραγματική Μέση Τιμή} = (1000+1250+625)/3 = 958,3$$

$$\text{Μέσος αριθμός μονάδων} = \text{Δαπάνη} / \text{Μέση Τιμή}$$

$$\frac{\frac{10000}{10} + \frac{10000}{8} + \frac{10000}{16}}{3} = \frac{3}{\frac{1}{10} + \frac{1}{8} + \frac{1}{16}} = 10,43$$

Αρμονικός Μέσος

Διάμεσος ή Κεντρική Τιμή (Median)

Χωρίζει την σειρά των δεδομένων στην μέση αν αυτά τοποθετηθούν κατά αύξουσα ή φθίνουσα τάξη μεγέθους. Είναι η τιμή που βρίσκεται στο μέσο αυτών. Είναι χρήσιμο μέτρο για δείγματα με μεγάλο μέγεθος.

Θέση Διαμέσου $(n+1)/2$

Παράδειγμα

| | | |
|-----|-----|-----|
| 2,0 | 3,5 | 4,3 |
| 2,1 | 3,7 | 4,3 |
| 2,3 | 3,7 | 4,3 |
| 2,3 | 3,7 | 4,4 |
| 3,2 | 3,9 | 4,4 |
| 3,2 | 3,9 | 4,5 |
| 3,3 | 3,9 | 5,7 |
| 3,3 | 3,9 | 5,7 |
| 3,5 | 4,1 | 5,7 |
| 3,5 | 4,1 | 6,0 |

Αν n άρτιος η διάμεσος έχει θεωρητική τιμή

Θέση Διαμέσου $(30+1)/2=15,5$

Διάμεσος = $M= 3,9$

Μέτρα Σχετικής Τοποθεσίας

- Μέτρα Σχετικής Τοποθεσίας σχεδιάζονται για να προβάλουν πληροφόρηση σχετικά με την **τοποθεσία** κάποιων συγκεκριμένων τιμών **σε σχέση** με ολόκληρο το σύνολο των δεδομένων.
- **Ποσοστημόριο:** το P ποσοστημόριο είναι η τιμή από την οποία P ποσοστό των τιμών είναι *μικρότερο από* την τιμή αυτή και $(100-P)\%$ είναι *μεγαλύτερο από* την τιμή αυτή.
- Υποθέστε ότι ο βαθμός του πτυχίου σας είναι το 60° ποσοστημόριο στο έτος σας, το οποίο σημαίνει ότι το 60% των άλλων σκορ ήταν *κάτω* από το δικό σας, ενώ το 40% των άλλων σκορ ήταν *κάτω* από το δικό σας.

Ποσοστημόριο ...

- Έχουμε ειδικά ονόματα για το 25° , 50° , και 75° ποσοστημόριο, χαρακτηριστικά **τεταρτημόρια**.
- Το πρώτο τεταρτημόριο χαρακτηρίζει $Q_1 = 25^\circ$ ποσοστημόριο.
- Το δεύτερο τεταρτημόριο, $Q_2 = 50^\circ$ ποσοστημόριο (το οποίο είναι επίσης η διάμεσος).
- Το τρίτο τεταρτημόριο, $Q_3 = 75^\circ$ ποσοστημόριο.
- Μπορούμε επίσης να αντιστοιχίσουμε ποσοστημόρια σε πεμπτημόρια (quintiles, fifths) και δεκατημόρια (deciles, tenths).

Χρήσιμα Ποσοστημόρια ...

- Πρώτο δεκατημόριο = 10° ποσοστημόριο
 - Πρώτο τεταρτημόριο, Q_1 , = 25° ποσοστημόριο
 - Διάμεσος, Q_2 , = 50° ποσοστημόριο
 - Τρίτο τεταρτημόριο, Q_3 , = 75° ποσοστημόριο
 - Ένατο δεκατημόριο = 90° ποσοστημόριο
-
- **Σημειώστε:** Εάν ο βαθμός σου σε φέρνει στο 80° ποσοστημόριο, αυτό δεν σημαίνει ότι απάντησες το 80% των ερωτήσεων σωστά – αυτό σημαίνει ότι το 80% των συμφοιτητών σου είχε σκορ **χαμηλότερο** από το δικό σου. Δείχνει την θέση σου σε σχέση με τους άλλους.

Θέση των Ποσοστημορίων ...

- Ο ακόλουθος τύπος μας επιτρέπει να προσεγγίσουμε την θέση του κάθε ποσοστημορίου:

$$L_p = (n + 1) \frac{P}{100}$$

Όπου L_p είναι η θέση του P^o ποσοστημόριου

Θέση των Ποσοστημορίων ...

- Θεωρήστε τα δεδομένα:
- 0 0 5 7 8 9 12 14 22 33
- Ποια είναι η θέση του 25^ο ποσοστημορίου. Δηλαδή, σε ποιο σημείο είναι το 25% των τιμών μικρότερες και 75% των τιμών μεγαλύτερες;

0 0 5 7 8 9 12 14 22 33

- $L_{25} = (10+1)(25/100) = 2.75$

Το 25^ο ποσοστημόριο είναι τρία-τέταρτα της απόστασης μεταξύ της δεύτερης (που είναι 0) και της τρίτης (που είναι 5) παρατήρησης. Τα τρία-τέταρτα της απόστασης είναι: $(.75)(5 - 0) = 3.75$

Επειδή η δεύτερη παρατήρηση είναι 0, το 25^ο ποσοστημόριο είναι $0 + 3.75 = \mathbf{3.75}$

Θέση των Ποσοστημορίων ...

- Ποιο είναι το τρίτο τεταρτημόριο;

- $L_{75} = (10+1)(75/100) = 8.25$


0 0 5 7 8 9 12 14 22 33



Τοποθετείτε ένα-τέταρτο της απόστασης ανάμεσα στην όγδοη και ένατη παρατήρηση, οι οποίες είναι 14 και 22, αντίστοιχα. Το πρώτο τέταρτο της απόστασης είναι: $(.25)(22 - 14) = 2$, το οποίο σημαίνει ότι το 75^ο ποσοστημόριο είναι: $14 + 2 = \mathbf{16}$

Θέση των Ποσοστημορίων ...

- Παρακαλώ θυμηθείτε ...



L_p καθορίζει την **θέση** στο σύνολο των δεδομένων όπου η τιμή του ποσοστημορίου βρίσκεται, όχι την τιμή του ποσοστημορίου.

Διάμεσος κατανομής με διαστήματα τάξεων

$$M \approx F_i + \frac{\delta}{f_i} \left(\frac{n}{2} - \Phi_{i-1} \right)$$

F_i = το κατώτερο όριο της κλάσης που περιέχει την διάμεσο

δ = το εύρος της κλάσεως

f_i = συχνότητα της κλάσεως

Φ_{i-1} = αθροιστική συχνότητα προηγούμενης κλάσης

Παράδειγμα

| | f_i | X_i | Φ_i |
|-----------|-------|-------|----------|
| 2,0 - 2,9 | 4 | 2,45 | 4 |
| 3,0 - 3,9 | 14 | 3,45 | 18 |
| 4,0 - 4,9 | 8 | 4,45 | 26 |
| 5,0 - 6,0 | 4 | 5,45 | 30 |
| | 30 | | |

$$M \approx 3,0 + \frac{0,9}{14} \left(\frac{30}{2} - 4 \right) = 3,7$$

Τεταρτημόρια

Χωρίζουν την σειρά των δεδομένων σε 4 ίσα μέρη αν αυτά τοποθετηθούν κατά αύξουσα τάξη μεγέθους

Θέση 1ου Τεταρτημρίου $(n+1)/4$


Θέση 2ου Τεταρτημρίου $(n+1)/2$ (Διάμεσος)

Θέση 3ου Τεταρτημρίου $3(n+1)/4$

Τύπος ή Επικρατούσα Τιμή (Mode)


Η τιμή με την μεγαλύτερη συχνότητα n που παρουσιάζεται τις περισσότερες φορές

Εκτίμηση της Διαμέσου και των Τεταρτημορίων με Γραμμική Παρεμβολή



Θηκόγραμμα (Box Plot)...

- Το **θηκόγραμμα** (*box plot*) είναι μία γραφική τεχνική η οποία σχεδιάζει **πέντε** στατιστικές:
- την μικρότερη την μεγαλύτερη παρατήρηση, το πρώτο, δεύτερο, και τρίτο τεταρτημόριο.

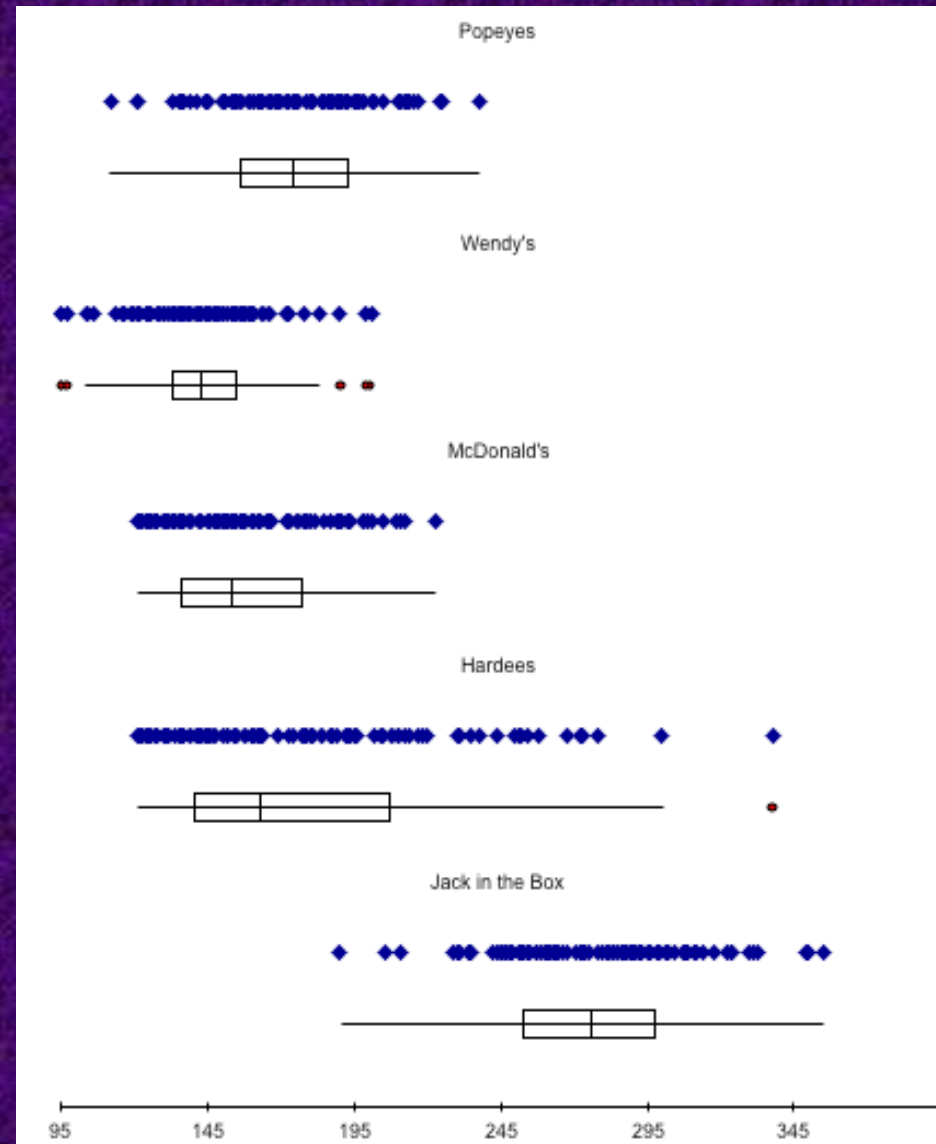


Μύστακας ($1.5 \cdot (Q_3 - Q_1)$)

Οι προεκτεινόμενες γραμμές στα αριστερά και στα δεξιά καλούνται **μύστακες** (**whiskers**). Κάθε σημείο που πέφτει έξω από τους μύστακες καλείται ακραία τιμή (outlier). Οι μύστακες επεκτείνονται προς τα έξω στο μικρότερο από το (1.5 φορά το ενδοτεταρτημοριακό εύρος) ή στην ποιο τελευταία τιμή η οποία δεν είναι ακραία.

Θηκόγραμμα (Box Plot)...

- Αυτά τα θηκογράμματα είναι από δεδομένα με χρόνος εξυπηρέτησης πελατών.
- Ο χρόνος εξυπηρέτησης στα Wendy's είναι ο μικρότερος και λιγότερο μεταβλητός.
- Στα Hardee's ο χρόνος εξυπηρέτησης έχει την μεγαλύτερη μεταβλητότητα, ενώ στα Jack-in-the-Box έχει τον μεγαλύτερο χρόνο εξυπηρέτησης.



Σύγκριση Μέτρων Κεντρικής Τάσης και Θέσης

☀ Μόνο στα μέτρα Κ. Τάσης μπορούν να γίνουν αλγεβρικές πράξεις

☀ Ο Αριθμητικός μέσος υπολογίζεται σε κάθε περίπτωση.
Ο Γεωμετρικός και Αρμονικός Μέσος δεν δέχονται τιμές ≤ 0

☀ $\bar{X} \geq G \geq H$

☀ $\bar{X} = M$

Όταν αναφερόμαστε σε ολόκληρο τον πληθυσμό. Επίσης ισχύει για τις μεταβλητές που ακολουθούν συμμετρικές κατανομές (π.χ. Κανονική, t-κατανομή, Τυπική κατανομή)

☀ $M < \bar{X}$ Στις κατανομές με σχήμα καμπύλης, κοίλης προς τα δεξιά

☀ $M > \bar{X}$ Στις κατανομές με σχήμα καμπύλης, κοίλης προς τα αριστερά