

## Βιοστατιστική

# Περιγραφική Στατιστική

Αριστοτέλης Παπαγεωργίου, Τμ. ΜΒΓ ΔΠΘ, [apapage@mbg.duth.gr](mailto:apapage@mbg.duth.gr)

# Πηγές υλικού

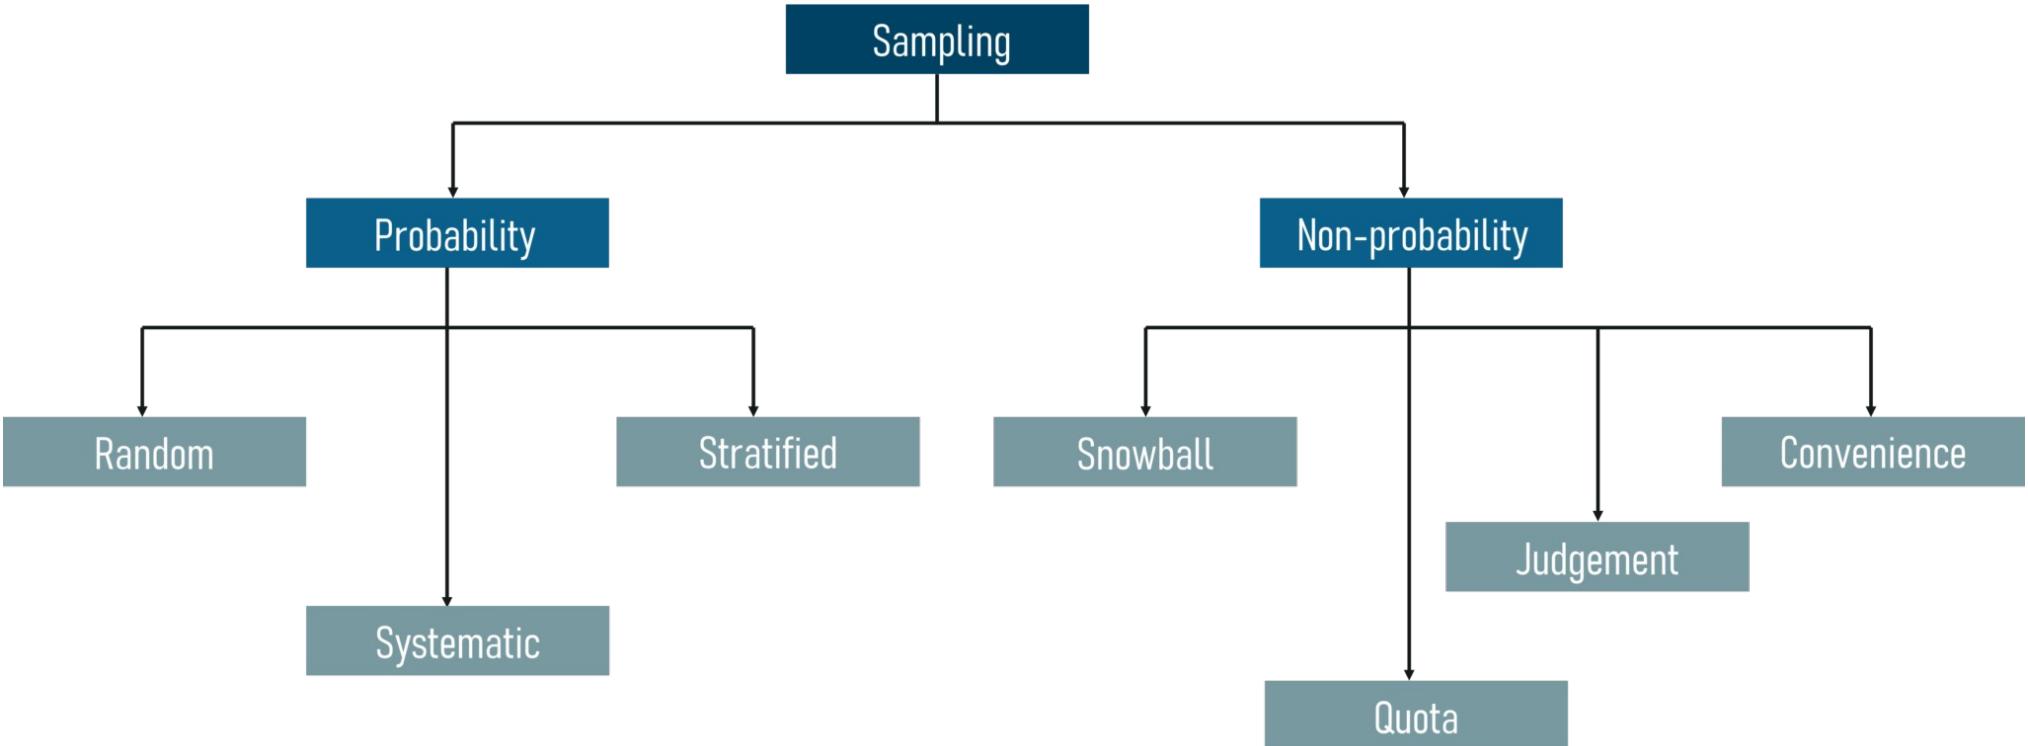
- Διαφάνειες και ασκήσεις του Theophanis Tsandilas (National Institute for Research in Digital Science and Technology, INRIA, Γαλλία)
- Διαφάνειες και ασκήσεις του Σπύρου Γαλατσίδα (Τμ. Δασολογίας & Διαχείρισης Περιβάλλοντος & Φυσικών Πόρων, ΔΠΘ)

# Η στατιστική

- Ο κλάδος της επιστήμης που ασχολείται με:
  - Το σχεδιασμό της συλλογής δεδομένων
  - Την οργάνωση, επεξεργασία και παρουσίαση δεδομένων και αποτελεσμάτων επεξεργασίας
  - Την ανάλυση των δεδομένων, τη διατύπωση συμπερασμάτων και τη λήψη αποφάσεων

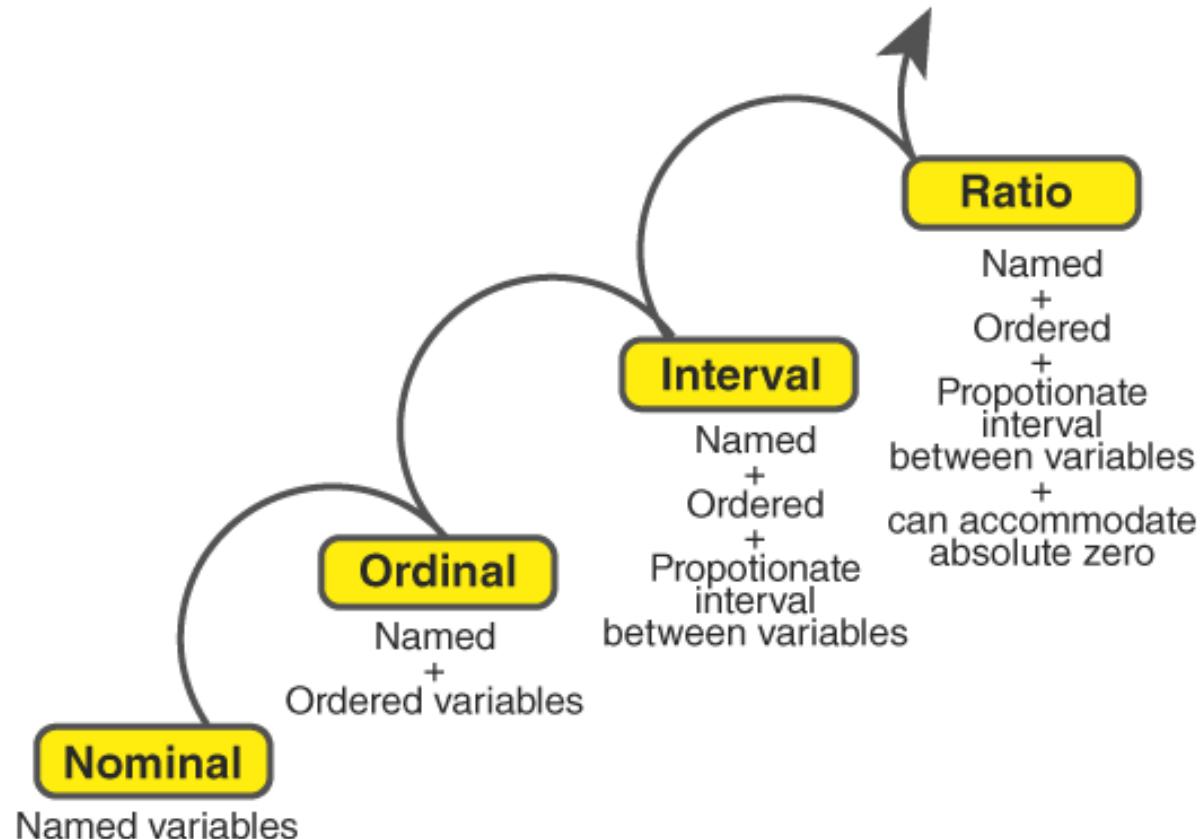


# Τυχαία & μη τυχαία δειγματοληψία



# LEVELS OF MEASUREMENT

---



# Περιγραφική στατιστική

- Descriptive (or summary) statistics
  - ελάχιστο (*min*), μέγιστο (*max*), μέσος (*mean*), διάμεσος (*median*), τυπική απόκλιση (*standard deviation*) και άλλα...
- Ένας τρόπος για να συνοψίσουμε και να παρουσιάσουμε πληροφορίες σχετικά με ένα σύνολο δεδομένων
  - “Πρώτη αίσθηση” για ένα σύνολο δεδομένων
- Επιβεβαιώνουμε κάποια σαφή μοτίβα (πρότυπα) στα δεδομένα, αν υπάρχουν
- Εντοπισμός τυχόν παρατυπιών και προβλημάτων κατά τη δειγματοληψία
- Μας οδηγεί στην επιλογή του κατάλληλου στατιστικού μοντέλου

# Μέτρα κεντρικής τάσης

- Περιγραφή ενός συνόλου δεδομένων με μία τιμή
  - Η πιο “τυπική” ή η πιο “κοινή” ή η πιο “μέση” τιμή
- Μέτρα κεντρικής τάσης
  - Τύπος (mode): η πιο κοινή τιμή
  - Διάμεσος (median): η κεντρική τιμή
  - Μέσος (mean, average)
- Ο τύπος, η διάμεσος ή ο μέσος όρος ενός δείγματος, τις περισσότερες φορές διαφέρουν από τα αντίστοιχα μέτρα του πληθυσμού

# Παράμετροι και στατιστικά

- Μια **παράμετρος** είναι ιδιότητα του πληθυσμού
- Ένα **στατιστικό** είναι ιδιότητα του δείγματος
  - Παρέχει μια εκτίμηση μιας πληθυσμιακής παραμέτρου
  - Όσο το μέγεθος  $n$  του δείγματος πλησιάζει το μέγεθος  $N$  του πληθυσμού, τα στατιστικά τείνουν να μοιάζουν με τις παραμέτρους
- Συνήθως χρησιμοποιούμε ελληνικά γράμματα για την παράμετρο ενός πληθυσμού και ένα λατινικό γράμμα για το στατιστικό ενός δείγματος
  - π.χ, το  $\mu$  προσδιορίζει τον μέσο του πληθυσμού, ενώ το  $M$  δηλώνει τη μέση τιμή του δείγματος

# Παράμετροι και στατιστικά

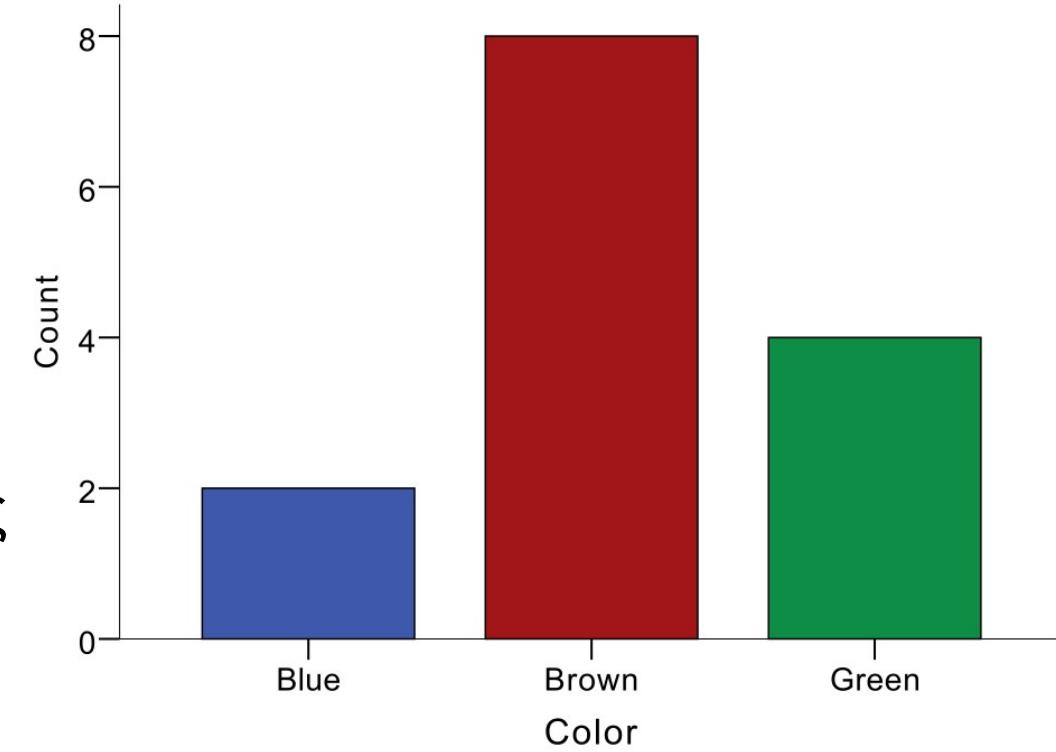
- Ένας άλλος συμβολισμός είναι η χρήση του “καπέλου” για το δείγμα:
  - Το  $\mu$  προσδιορίζει τον μέσο του πληθυσμού
  - Το  $\hat{\mu}$  προσδιορίζει τον μέσο του δείγματος

# Τύπος

- Η πιο κοινή τιμή
  - Ο τύπος αυτού του συνόλου τιμών είναι 10:
    - 16 **10** 12 **10** 9 14 13
- Ο τύπος είναι η καλύτερη τιμή για να μαντέψουμε
  - Καλύτερα για διακριτά και όχι για συνεχή δεδομένα, ειδικά για κατηγορικά δεδομένα, όπου δεν υπάρχει ιεραρχική σχέση

# Τύπος

- Καταγράψαμε σε 14 ανθρώπους το χρώμα των ματιών τους
- Ποιος είναι ο τύπος του δείγματος;
- Ποια είναι η καλύτερη “υπόθεση” για το χρώμα ενός τυχαίου ανθρώπου του δείγματος;
- Εφαρμογή στη γενετική...



# Διάμεσος

- Η κεντρική τιμή σε ένα σύνολο αριθμών
  - Όταν οι αριθμοί είναι τοποθετημένοι με τη σειρά, η διάμεσος είναι η μεσαία τιμή: **12 20 24 34 35 80 83**
  - Εάν το μέγεθος του δείγματος είναι ζυγός αριθμός, λαμβάνεται το μέσο σημείο μεταξύ των δύο κεντρικών τιμών ως διάμεσος: **5 6 8 9 12 15**, οπότε η διάμεσος είναι  $(8+9)/2 = 8,5$
- Η διάμεσος δεν είναι ευαίσθητη σε ακραίες τιμές
  - Πλεονέκτημα: εξαλείφει την επίδραση των ακραίων τιμών
  - Μειονέκτημα: αγνοεί τις μη κεντρικές τιμές

# Αριθμητικός μέσος

- Είναι το πιο ευρέως χρησιμοποιούμενο μέτρο κεντρικής τάσης
  - γνωστό και ως μέσος ή μέσος όρος
- Ο μέσος όρος του ακόλουθου συνόλου δεδομένων:  
**10 16 10 12 9 14** είναι  $(16+10+12+10+9+14+13) / 7 = 12$

- Για ένα σύνολο αριθμών  $x_i$  με  $i=1,2,\dots,n$  ισχύει:
- Ο μέσος αξιοποιεί όλες τις τιμές του δείγματος

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

# Ερωτήσεις

- Ποιο είναι το καλύτερο μέτρο κεντρικής τάσης για καθένα από τα ακόλουθα:
  - 1) Βάρος 50 τυχαίων φοιτητών
  - 2) Εισόδημα οικογενειών στην Ελλάδα
  - 3) Έξοδα για στέγαση 100 φοιτητών, σε τρεις κατηγορίες:
    - (a) χαμηλότερα από 200 ευρώ
    - (b) μεταξύ 200 και 500 ευρώ
    - (c) υψηλότερα από 500 ευρώ

# Μέτρα διασποράς

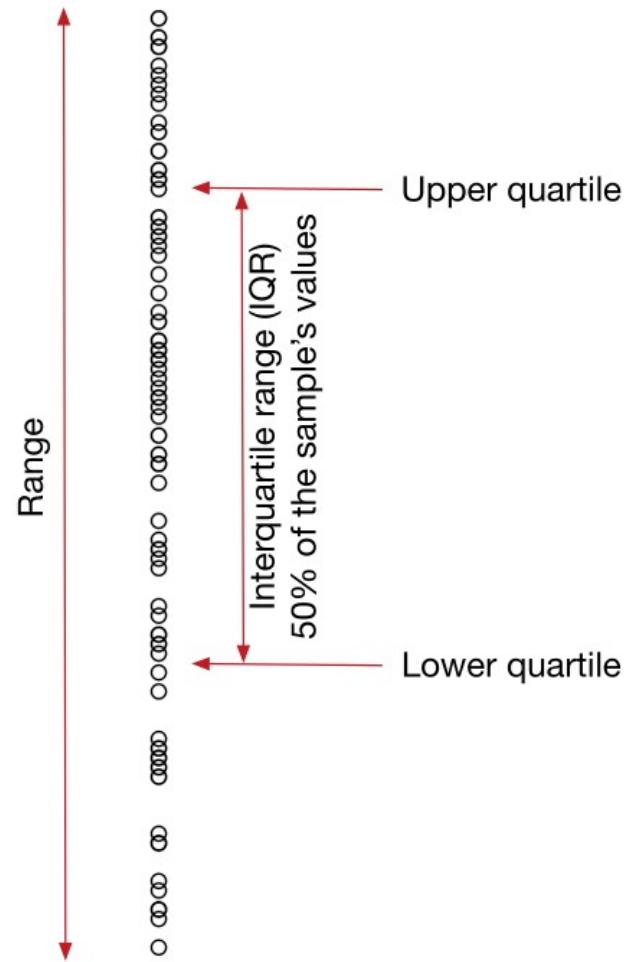
- Συγκρίνετε τα δύο σύνολα δεδομένων:
  - D1: 12 13 13 14 15 14
  - D2: 5 9 12 15 20 20
    - Έχουν σχεδόν ίδιους μέσους και διάμεσους αλλά είναι πολύ διαφορετικά
- Οι αριθμοί στο D2 είναι πιο απλωμένοι
  - Έχουν μεγαλύτερη **διασπορά**
- Μέτρα διασποράς:
  - εύρος, τεταρτημόρια, διακύμανση, τυπική απόκλιση...

# Εύρος

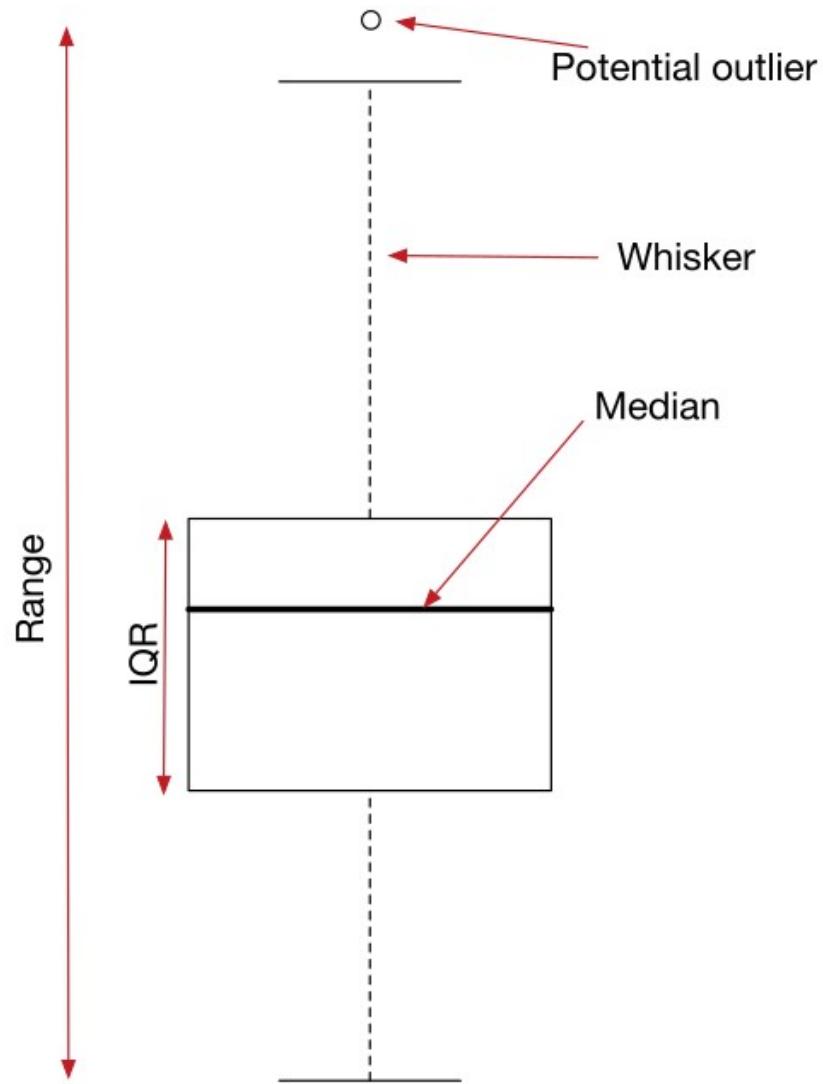
- Είναι η διαφορά ανάμεσα στη μέγιστη και την ελάχιστη τιμή:
  - D1: 12 13 13 14 15 14
  - D2: 5 9 12 15 20 20
- D1:  $15 - 12 = 3$
- D2:  $20 - 5 = 15$
- Το εύρος είναι πολύ ευαίσθητο στις ακραίες τιμές

# Τεταρτημόρια

- Τα τεταρτημόρια είναι οι **τρεις τιμές** που χωρίζουν ένα σύνολο από *n* ταξινομημένους ιεραρχικά αριθμούς σε τέσσερα ίσα υποσύνολα
  - Το πρώτο (κατώτερο) τεταρτημόριο διαχωρίζει το 25% των χαμηλότερων αριθμών
  - Το δεύτερο (μεσαίο) τεταρτημόριο είναι ο διάμεσος
  - Το τρίτο (ανώτερο) τεταρτημόριο διαχωρίζει ο 25% των υψηλότερων αριθμών



# Boxplot



# Διακύμανση (variance)

**Variance**

$$Var = \frac{\sum_{i=1}^n (x_i - M)^2}{n}$$

sum of squares

sample size

# Τυπική απόκλιση (standard deviation)

**Standard deviation** (scaled to use the same units as the original data)

$$SD = \sqrt{Var} = \sqrt{\frac{\sum_{i=1}^n (x_i - M)^2}{n}}$$

Είναι η τετραγωνική ρίζα της διακύμανσης

Η πιο διαδεδομένη μέτρηση διασποράς των τιμών

# Παράδειγμα

Consider the following dataset that gives the weight of six 15-month old babies (in kilograms):

$$8 \quad 10 \quad 10 \quad 12 \quad 9 \quad 11$$

$$M = \frac{(8+10+10+12+9+11)}{6} = 10$$

$$Var = \frac{(8-10)^2 + (10-10)^2 + (10-10)^2 + (12-10)^2 + (9-10)^2 + (11-10)^2}{6} = 1.667$$

$$SD = \sqrt{1.667} = 1.29$$

# Ας λύσουμε την άσκηση με R

- Δημιουργούμε ένα σετ δεδομένων με τις τιμές της άσκησης (βάρος βρεφών 15 μηνών)

```
> data <- c(8,10,10,12,9,11)
> data
[1]  8 10 10 12  9 11
> □
```

# Μέσος και διάμεσος

```
> mean <- mean(data)
> mean
[1] 10
> median <- median(data)
> median
[1] 10
>
> □
```

# Διακύμανση και τυπική απόκλιση

```
> variance <- var(data)
> variance
[1] 2
> sd <- sd(data)
> sd
[1] 1.414214
```

Γιατί υπάρχει διαφορά στην τιμή που υπολογίσαμε με το χέρι και στην τιμή από το R;

# Υπολειμματικές τιμές (residuals)

- Οι ακατέργαστες αποκλίσεις της κάθε τιμής από τον μέσο όρο λέγονται **υπολειμματικές τιμές**

$$x_i - M$$

For the following dataset ( $M = 10$ )

8      10      10      12      9      11

The residuals are as follows:

-2      0      0      2      -1      1

Το άθροισμα όλων των υπολειμματικών τιμών ενός δείγματος είναι πάντα **0**

# Εκτιμητές πληθυσμιακών παραμέτρων

- Πώς εκτιμούμε τον μέσο όρο ενός πληθυσμού, τη διακύμανση ή την τυπική του απόκλιση από ένα δείγμα;
- Ερωτήματα:
  - Είναι ο μέσος όρος ενός δείγματος ένας καλός εκτιμητής του πληθυσμιακού μέσου;
  - Είναι η τυπική απόκλιση ενός δείγματος ένας καλός εκτιμητής της τυπικής απόκλισης του πληθυσμού;

# Αποτελεσματικοί και αμερόληπτοι εκτιμητές

- Ένα καλό στατιστικό θα πρέπει να είναι ένας αποτελεσματικός και αμερόληπτος εκτιμητής της αντίστοιχης παραμέτρου του πληθυσμού
- Ένα **αποτελεσματικό στατιστικό** έχει μικρότερο σφάλμα
  - τείνει να είναι κοντά στην παράμετρο του πληθυσμού
  - παρουσιάζει μικρότερες διακυμάνσεις από δείγμα σε δείγμα
- Ένα **αμερόληπτο στατιστικό** δεν έχει bias (είναι αντικειμενικό)
  - Μακροπρόθεσμα (σταθερά), δεν υπερεκτιμά ούτε υποτιμά την πραγματική παράμετρο του πληθυσμού

# Αμερόληπτοι και μεροληπτικοί εκτιμητές

- Τα στατιστικά των δειγμάτων κεντρικής τάσης όπως οι μέσοι και οι διάμεσοι είναι **αμερόληπτοι** εκτιμητές
  - Έτσι, χρησιμοποιούμε συχνά για το  $\hat{\mu}$  για να προσεγγίσουμε τη μέση τιμή του πληθυσμού  $\mu$
- Όμως τα στατιστικά για τη διασπορά είναι **μεροληπτικά**
  - Τείνουν να υποτιμούν την πραγματική παράμετρο του πληθυσμού
  - Ένα μικρό δείγμα είναι απίθανο να συλλάβει τα άκρα ενός πληθυσμού

# Αμερόληπτοι εκτιμητές διασποράς

The population variance is usually represented as  $\sigma^2$  and its unbiased estimator is:

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (x_i - \hat{\mu})^2}{n - 1}$$

degrees of freedom

The unbiased estimator of the population standard deviation  $\sigma$  is:

$$\hat{\sigma} = \sqrt{\hat{\sigma}^2} = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{\mu})^2}{n - 1}}$$

degrees of freedom

# Βαθμοί ελευθερίας

- Βαθμοί ελευθερίας
  - ο αριθμός των παραμέτρων στον υπολογισμό ενός στατιστικού που μπορούν να ποικίλουν ελεύθερα
- Γιατί ***n-1***:
  - Όταν είναι γνωστός ο μέσος, απαιτούνται μόνο  $n-1$  ανεξάρτητες παρατηρήσεις για να υπολογίσουμε τη διακύμανση (ή την τυπική απόκλιση)
  - Αυτό γίνεται αν θεωρήσουμε τις υπολειμματικές τιμές ενός δείγματος

$$x_n = \hat{\mu} - (x_1 + x_2 + \dots + x_{n-1})$$

# Περιγραφικά και συμπερασματικά στατιστικά

- Οι αμερόληπτες εκτιμήσεις της διακύμανσης ενός πληθυσμού (ή της τυπικής του απόκλισης) είναι γνωστά ως **συμπερασματική** (inferential) διακύμανση ή **συμπερασματική τυπική απόκλιση**
  - Λέγεται και “επαγωγική”
- Τα περιγραφικά στατιστικά απλά περιγράφουν το δείγμα
- Με τα συμπερασματικά στατιστικά, προσπαθούμε να συμπεράνουμε τις πληθυσμιακές παραμέτρους από ένα δείγμα

# Άθροισμα τετραγώνων

- Γιατί στα στατιστικά της διασποράς χρησιμοποιούμε το άθροισμα τετραγώνων των υπολειμματικών τιμών...

$$\sum_{i=1}^n (x_i - \hat{\mu})^2$$

- και όχι το άθροισμα των απόλυτων τιμών τους;

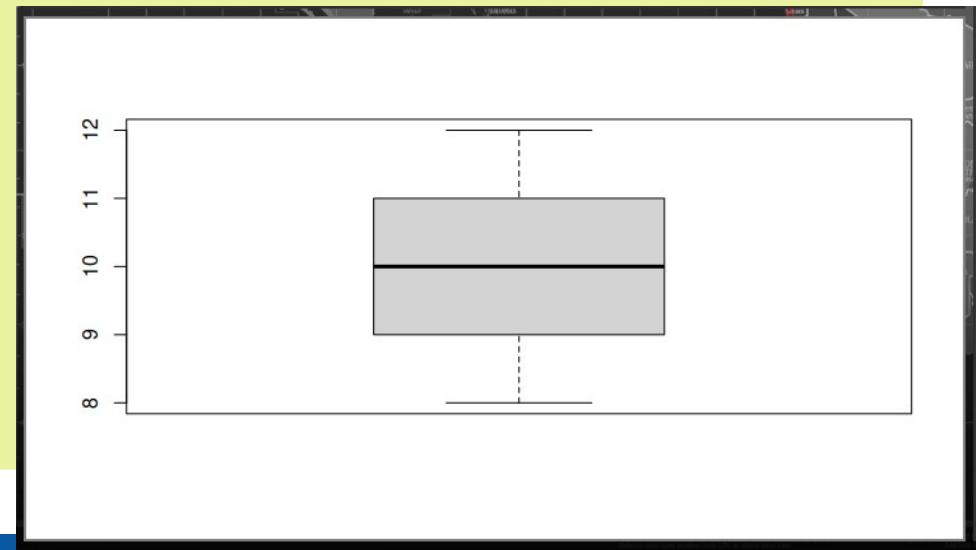
$$\sum_{i=1}^n |x_i - \hat{\mu}|$$

# Άθροισμα τετραγώνων

- Οι υπολογισμοί με απόλυτες τιμές είναι επίπονοι αλλά δεν είναι αυτός ο κύριος λόγος...
- Το μέτρο κεντρικής τάσης που μειώνει το άθροισμα των απόλυτων τιμών των υπολειμματικών τιμών είναι η διάμεσος και όχι ο μέσος
  - Καθώς ο μέσος χρησιμοποιείται πιο συχνά στις αναλύσεις δεδομένων, οδηγούμαστε στο άθροισμα των τετραγώνων
  - Στις περιπτώσεις αναλύσεων με διάμεσους, μπορούμε να χρησιμοποιούμε το άθροισμα των απόλυτων τιμών

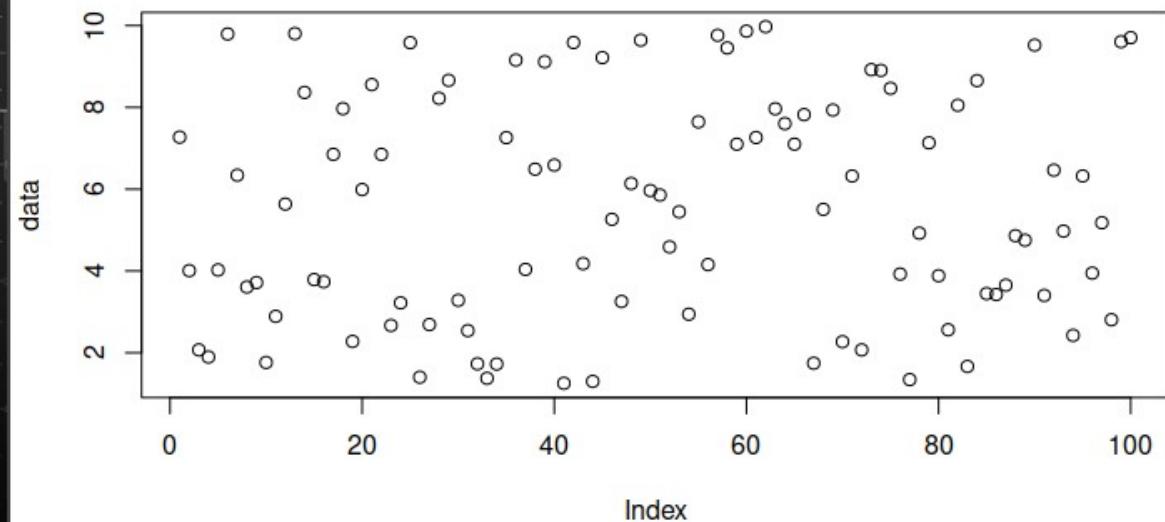
# Summary

```
> summary(data)
   Min. 1st Qu. Median     Mean 3rd Qu.    Max.
 8.00    9.25   10.00   10.00   10.75   12.00
> boxplot(data)
```

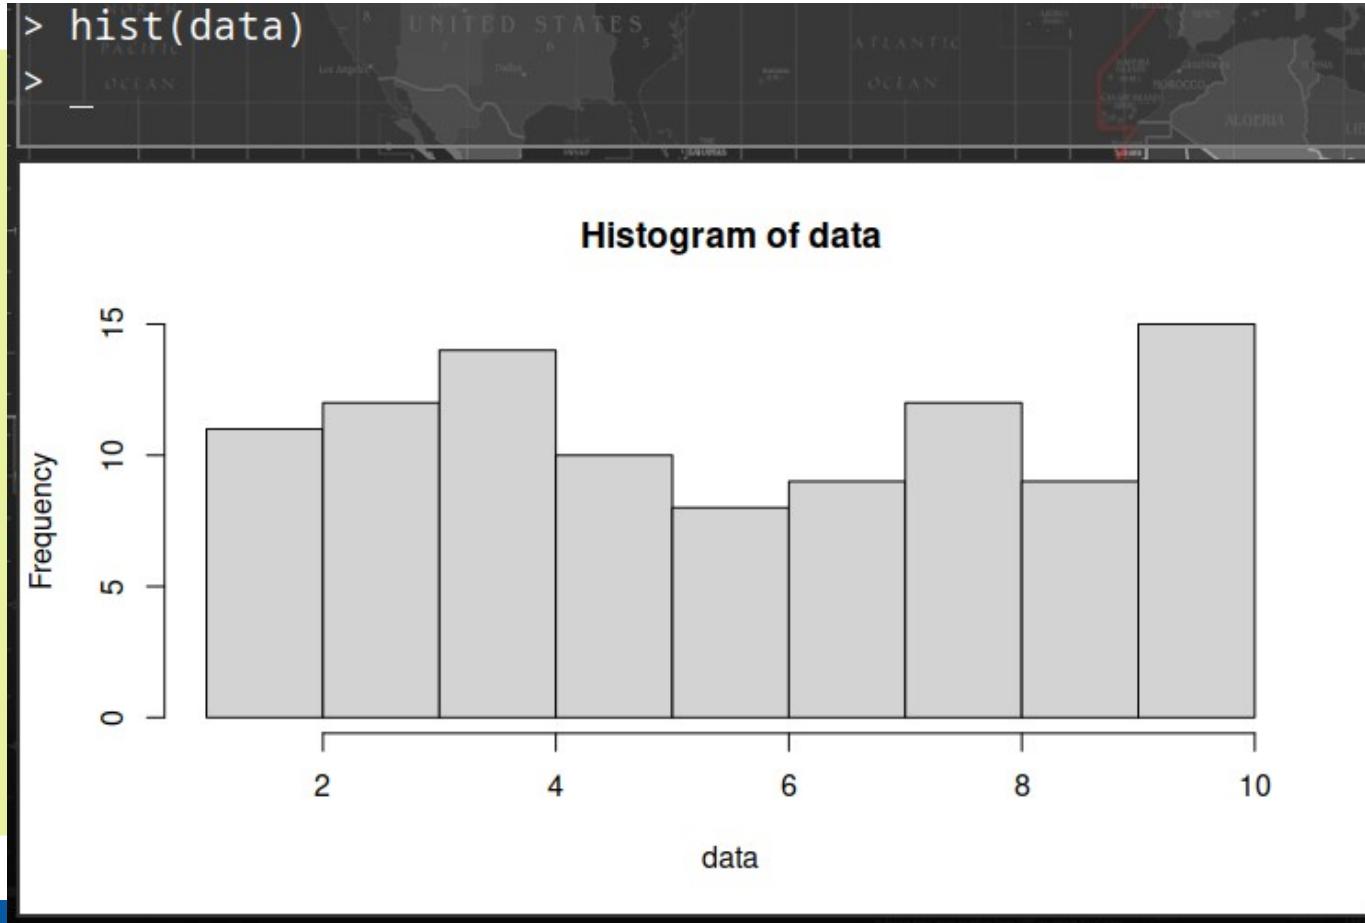


# Νέα ποσοτικά δεδομένα

```
> data = runif(100,1,10)  
> plot(data)
```



# Νέα ποσοτικά δεδομένα

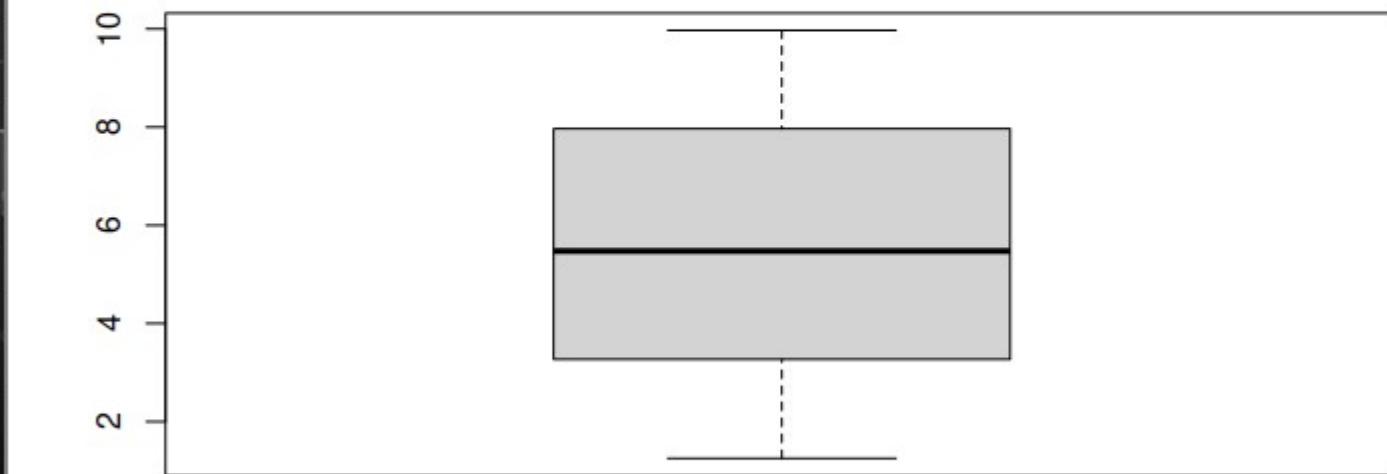


# Περιγραφική στατιστική

```
> mean <- mean(data)
mean
[1] 5.560556
> median <- median(data)
median
[1] 5.47571
> variance <- var(data)
variance
[1] 7.441719
> sd <- sd(data)
sd
[1] 2.727951
> summary(data)
   Min. 1st Qu. Median Mean 3rd Qu. Max.
1.254   3.276   5.476  5.561  7.965  9.971
```

```
> boxplot(data)
```

```
>
```



# Πληθυσμός και δείγμα

- Ορίζουμε πληθυσμό αριθμών από το 1 ως το 1000 και καλούμε ένα τυχαίο δείγμα 20 ατόμων

```
> population <- 1:1000
> sample <- sample(population, 20)
> sample
[1] 892 295 984 565 463 875 953 56 487 598 65 368 72
[13] 623 315 608 869 235 721
[20] 280
>
```

# Ιδιότητες του δείγματος

- Μέγεθος και εύρος δείγματος

```
> length(sample)
[1] 20
> range(sample)
[1] 56 984
>
```

```
> IQR(sample)
[1] 466.75
```

# Περιγραφικά στατιστικά του δείγματος

- Μέτρα κεντρικής τάσης

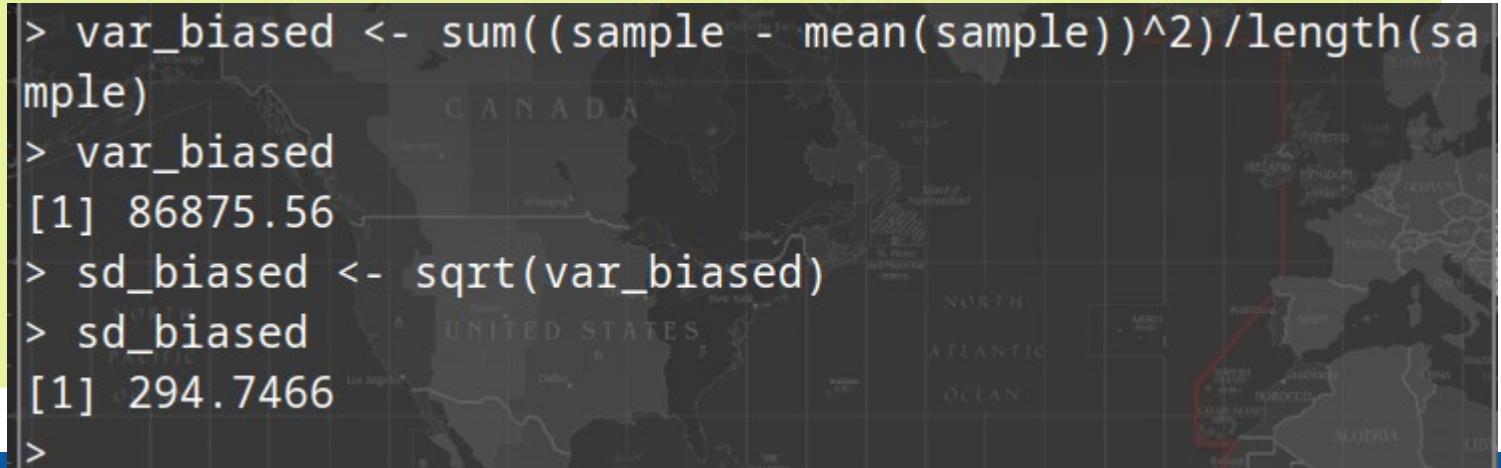
```
> mean(population)
[1] 500.5
> median(population)
[1] 500.5
> mean(sample)
[1] 516.2
> median(sample)
[1] 526
>
```

# Περιγραφικά στατιστικά του δείγματος

- Μέτρα διασποράς (αμερόληπτα)
- Μέτρα διασποράς (μεροληπτικά)

```
> var(sample)
[1] 91447.96
> sd(sample)
[1] 302.4036
>
```

```
> var_biased <- sum((sample - mean(sample))^2)/length(sample)
> var_biased
[1] 86875.56
> sd_biased <- sqrt(var_biased)
> sd_biased
[1] 294.7466
>
```



# Υπολειμματικές τιμές

- Αποκλίσεις από τον μέσο όρο (άθροισμα)

```
> sum(population - mean(population))
[1] 0
> sum(sample - mean(sample))
[1] -9.094947e-13
```

- Αποκλίσεις από τον μέσο όρο (άθροισμα τετραγώνων)

```
> sum((sample - mean(sample))^2)
[1] 1737511
```

- Αποκλίσεις από τον μέσο όρο (άθροισμα απόλυτων τιμών)

```
> sum(abs(sample - mean(sample)))
[1] 5052
```

# Homework

- **Άσκηση 1**

- Δημιουργήστε έναν πληθυσμό αριθμών από το 1 ως το 2000 και ένα τυχαίο δείγμα μεγέθους 40
- Υπολογίστε τα στατιστικά στο δείγμα:
  - εύρος
  - IQR
  - μέσο
  - διάμεσο
  - διακύμανση
  - τυπική απόκλιση

# Homework

- **Άσκηση 2**
  - Για τον ίδιο πληθυσμό αριθμών από το 1 ως το 2000:
    - Δημιουργήστε τρία δείγματα μεγέθους 10, 50 και 100
    - Για κάθε ένα δείγμα υπολογίστε τον μέσο και τη διακύμανση

6

Άσκηση περιγραφικής στατιστικής

Αρχείο Επεξεργασία Προβολή Εισαγωγή Μορφή Δεδομένα Εργαλεία Επεκτάσεις Βοήθεια

B33

A	B	C	D	E	F	G	H	
1	Παρακαλώ, συμπληρώστε τις τιμές που βρήκατε για το δικό σας δείγμα, για τα παρακάτω στατιστικά							
2								
3	sample nr.	sample size	range	IQR	mean	median	variance	standard deviation
4	1							
5	2							
6	3							
7	4							
8	5							
9	5							
10	6							

**Συμπληρώστε τις τιμές που βρήκατε στο:**

[https://docs.google.com/spreadsheets/d/1jnXQPbJKkIEyyhSNf48KmA\\_a2kofTBJJvLRDvxItlgE/edit?usp=sharing](https://docs.google.com/spreadsheets/d/1jnXQPbJKkIEyyhSNf48KmA_a2kofTBJJvLRDvxItlgE/edit?usp=sharing)



## Άσκηση περιγραφικής στατιστικής



Αρχείο

Επεξεργασία

Προβολή

Εισαγωγή

Μορφή

Δεδομένα

Εργαλεία

Επεκτάσεις

Βοήθεια

🔍 Μενού



100%



€

%

.0

.00

123



Προε...



-

10



+



H6

fx

	A	B	C	D	E	F	G	
1	Παρακαλώ, συμπληρώστε τις τιμές που βρήκατε για τα στατιστικά των τριών δειγμάτων							
2	sample size = 10			sample size = 50		sample size = 100		
3	Nr.	mean	standard deviation	mean	standard deviation	mean	standard deviation	
4	1							
5	2							
6	3							
7	4							
8	5							
9	5							
10	6							
11								
12								
13								
14								
15								
16								
17								
18								
19								
20								
21								
22								
23								
24								
25								

**Συμπληρώστε τις τιμές που βρήκατε στο:**

[https://docs.google.com/spreadsheets/d/1jnXQPbJKkIEyyhSNf48KmA\\_a2kofTBJJvLRDvxItIgE/edit?usp=sharing](https://docs.google.com/spreadsheets/d/1jnXQPbJKkIEyyhSNf48KmA_a2kofTBJJvLRDvxItIgE/edit?usp=sharing)



Thank you