





# KATANOMES (Distributions)



Τι είναι μια **κατανομή (πιθανότητων** αλλά συχνά ξεχνάμε να το λέμε έτσι )?

Οι πιθανές τιμές που μπορεί να πάρει μια μεταβλητή και  
πόσο συχνά μπορεί να πάρει τις τιμές αυτές



Τι είναι μια **κατανομή**?

Παράδειγμα: ποια είναι η κατανομή επιπέδων χοληστερόλης σε ένα αριθμό δειγμάτων

208, 187, 192, 187, 198, 202, 185, 205, 211, 215, 235, 195, 207, 206, 222, 177, 225

1. Τοποθετούμε τα δείγματα κατά σειρά και ομαδοποιούμε αυτά που βρίσκονται μεταξύ κάποιων ορίων → 170-179, 180-189, 190-199, 200-209, 210-219, 220-229, 230-239
2. Διαιρούμε με τον συνολικό αριθμό δειγμάτων, η πιθανότητα ένα δείγμα να ανήκει μεταξύ κάποιων ορίων π.χ. για την ομάδα 180-189 → 187, 187 (2 δείγματα) / σύνολο δειγμάτων 17 =  $2/17 = 0.12$

Τι είναι μια **κατανομή**?


Παράδειγμα: ποια είναι η κατανομή επιπέδων χοληστερόλης χοληστερόλης σε ένα αριθμό δειγμάτων

208, 187, 192, 187, 198, 202, 185, 205, 211, 215, 235, 195, 207, 206, 222, 177, 225

3. Δημιουργούμε ένα **ΠΙΝΑΚΑ ΣΥΧΝΟΤΗΤΩΝ**

170-179	180-189	190-199	200-209	210-219	220-229	230-239
0.06	0.12	0.17	0.29	0.12	0.12	0.06


4. Δημιουργούμε το διάγραμμα (συνήθως ένα ιστόγραμμα... για αρχή)




# Ιδιότητες μιας **κατανομής (πιθανότητων)**

Θα μιλήσουμε για τις τρεις βασικές ιδιότητες

Αλλά για να είναι χρήσιμη μια κατανομή πιθανοτήτων πρέπει να ακολουθεί ένα αναγνωρίσιμο μαθηματικό μοντέλο



Μοντέλο Gauss



Μοντέλο οτιναί

Αν δεν μπορούμε να την μοντελοποιήσουμε είναι ελάχιστα χρήσιμη  
(δεν μπορούμε να τη χρησιμοποιήσουμε...)

# Ιδιότητες μιας **κατανομής (πιθανότητων)**

Με  $P$  συμβολίζεται η πιθανότητα

Η γενική πιθανότητα συμβολίζεται με  $Y \rightarrow P(Y)$

και η συγκεκριμένη πιθανότητα μιας τιμής με  $y \rightarrow P(Y=y)$

Στο προηγούμενο παράδειγμα πιθανότητα να έχει κάποιος επίπεδα χοληστερόλης 187 είναι  $P(Y=187)$  ή για συντομία  $P(187)=0.12$

$P(y) \rightarrow$  η ΣΥΝΑΡΤΗΣΗ ΠΙΘΑΝΟΤΗΤΑΣ

# Ιδιότητες μιας **κατανομής (πιθανοτήτων)**

Δυο βασικές ιδιότητες χαρακτηρίζουν τις κατανομές


Μέση τιμή και τυπική απόκλιση

Αλλά πρωταρχικά το σχήμα καθορίζει τη μαθηματική σχέση


Υπάρχουν πολλές κατανομές




# Common Distributions




**Uniform**  
Rolling a dice




**Normal**  
Central Limit  
Theorem




**Binomial**  
Flipping a coin




**Poisson**  
Calls in a call  
center




**Exponential**  
Product failure



**Student-t**  
Small-data  
samples



**Lognormal**  
Mass, size,  
positive values




**Skewnormal**  
Generic  
skewed dist


# Common Distributions




**Uniform**  
Rolling a dice




**Binomial**  
Flipping a coin



**Exponential**  
Product failure



**Lognormal**  
Mass, size,  
positive values



**Normal**

Central  
Theorem


- Μπορούμε να έχουμε μια αρχική, εκτίμηση της κατανομής από το σχήμα της αν δεν έχουμε δεδομένα για τον τρόπο που εκτελέσθηκε το πείραμα



**Poisson**

Calls in  
center


- Δηλαδή
- Από μια άγνωστη χημική διαδικασία, ποια κατανομή τα δεδομένα ακολουθούν τα δεδομένα



**Student's**

Small  
sample

- Η αρχική έμπνευση υπάρχει από το σχήμα της κατανομής- φυσικά χρειάζεται να επιβεβαιωθεί η εκτίμησή μας με στατιστικές δοκιμασίες – αλλά βοηθά αν ξέρουμε από που να βρούμε την πρώτη ακρη



**Skewed**

General  
skewed

# Ιδιότητες μιας **κατανομής (πιθανοτήτων)**

Επανάληψη


Δυο βασικές ιδιότητες χαρακτηρίζουν τις κατανομές

Μέση τιμή και διακύμανση





# Ιδιότητες μιας **κατανομής (πιθανότητων)**

Μέση τιμή  $\rightarrow$  στα μαθηματικά ο αριθμητικός μέσος όρος – είναι μέτρο θέσης – μας λέει που βρίσκεται η κατανομή μας – ποια τιμή έχει



# Ιδιότητες μιας **κατανομής (πιθανότητων)**

Διακύμανση → πόσο στενά είναι διατεταγμένες οι τιμές γύρω από το μέσο όρο – μέτρο «πλάτους» που το λέμε μέτρο διασποράς



# Ιδιότητες μιας **κατανομής (πιθανότητων)**

Μια διευκρίνηση

Αντιμετωπίζουμε διαφορετικά ένα πληθυσμό και διαφορετικά ένα δείγμα

Ο όρος πληθυσμός αναφέρεται στο σύνολο των αντικειμένων (των δεδομένων)

Ο όρος δείγμα αναφέρεται σε ένα μέρος των αντικειμένων → μέσω του δείγματος προσπαθούμε να προσεγγίζουμε τις ιδιότητες του πληθυσμού

Π.χ. μια παρτίδα φαρμάκων αποτελείται από 100.000 δισκία – Αυτός είναι ο πληθυσμός 100.000 δισκία

Το δείγμα είναι ένα μέρος των δισκίων που θα αναλύσουμε από τον πληθυσμό π.χ. 30 δισκία – ελπίζουμε (και προσπαθούμε να το διασφαλίσουμε με τη στατιστική) ότι το δείγμα είναι αντιπροσωπευτικό του πληθυσμού - δεν διαφέρουν στις ιδιότητες τους – π.χ. έχουν την ίδια κατανομή βάρους

Όμως τα συμβολίζουμε διαφορετικά άλλα σύμβολα ιδιοτήτων έχει ο πληθυσμός και άλλα το δείγμα

πληθυσμός



δείγμα



# Ιδιότητες μιας **κατανομής (πιθανότητων)**

Μέση τιμή



Η μέση τιμή του πληθυσμού συμβολίζεται ως  $\mu$  - Η μέση τιμή του δείγματος ως  $\bar{x}$



Διακύμανση



Η διακύμανση του πληθυσμού συμβολίζεται ως  $\sigma^2$  - Η διακύμανση του δείγματος ως  $s^2$



# Ιδιότητες μιας **κατανομής (πιθανοτήτων)**

Η διακύμανση μετριέται σε δείγμα<sup>2</sup> – οδηγεί σε περίεργα αποτελέσματα – πχ μετρήσεις σε g<sup>2</sup>

Για το λόγο αυτό εισάγεται μια νέα εκτιμήτρια συνάρτηση – η τυπική απόκλιση  $\rightarrow \sqrt{\sigma^2} = \sigma$  που ονομάζεται (πληθυσμιακή) τυπική απόκλιση και  $\sqrt{s^2} = s$  που ονομάζεται (δειγματική) τυπική απόκλιση

Συσχέτιση μεταξύ  $\sigma^2$  και  $\mu$

$$\sigma^2 = E((Y - \mu)^2)$$

Όπου  $E$  ονομάζεται αναμενόμενη τιμή (expectation value) και είναι ο ζυγισμένος με τις πιθανότητες μέσος όρος (ακριβέστερα η πιο πιθανή τιμή που θα πάρουμε ως αποτέλεσμα – αντιληπτικά δεν είναι ο μέσος όρος που προέρχεται από πολλές τιμές αλλά μια τιμή που προβλέπει το πιθανότερο αποτέλεσμα του επόμενου πειράματος – έχουν όμως την ίδια αριθμητική τιμή – ας πούμε ότι η αναμενόμενη τιμή είναι a priori πρόβλεψη και ο μέσος όρος a posteriori γνώση μετά την εκτέλεση πειραμάτων)

$$E(x) = \sum x P(x)$$

# Ιδιότητες μιας **κατανομής (πιθανοτήτων)**

Στην αρχή είχαμε πει τρεις ιδιότητες... Είναι αλήθεια? Υπάρχει 3<sup>η</sup> ιδιότητα?




# Ιδιότητες μιας **κατανομής (πιθανοτήτων)**

Είναι αλήθεια Υπάρχει 3<sup>η</sup> ιδιότητα. Η κύρτωση που φαίνεται από τη συμμετρία



# Ιδιότητες μιας **κατανομής (πιθανοτήτων)**



Η λοξότητα (skewness) είναι το πόσο συμμετρική είναι η κατανομή.  
Συνήθως εκτιμάται στη μέση του ύψους

$$Pearson\ skewness = 3 \times \frac{\mu - \text{διαμεση τιμη}}{\sigma}$$

Θα δούμε διάφορες κατανομές

Σε κάθε κατανομή υπάρχουν δύο ειδών διαγράμματα

Η συνάρτηση πυκνότητας πιθανότητας (probability density function - pdf) και η αθροιστική συνάρτηση πυκνότητας πιθανότητας (cumulative density function - cdf)

συνάρτηση πυκνότητας πιθανότητας ο συνολικός αριθμός πιθανοτικών περιστατικών για κάθε τιμή

ομοιόμορφη κατανομή  
(uniform distribution)

Κατανομή όπου κάθε αποτέλεσμα έχει την ίδια πιθανότητα να παρατηρηθεί

$$f(x) = \begin{cases} \frac{1}{b-a} & , a \leq x \leq b, \\ 0 & , x < a \text{ or } x > b \end{cases}$$

← Αν το  $x$  βρίσκεται μεταξύ δυο ορίων  $a$  και  $b$  η πιθανότητα να παρατηρηθεί ένα αποτέλεσμα είναι  $1/b-a$

← Αν το  $x$  βρίσκεται εκτός δυο ορίων  $a$  και  $b$  η πιθανότητα είναι  $0$




Η ολική πιθανότητα είναι 1 και το πλάτος είναι  $b-a$

$$1 = (b-a) \times p(a) \Leftrightarrow p(a) = 1/b-a$$




Το Γράφημα της ομοιόμορφης κατανομής είναι ένα άθροισμα παραλληλόγραμμων



Ο μέσος όρος είναι  $\mu = \frac{a+b}{2}$

Η διασπορά είναι  $\sigma = \frac{(b-a)^2}{12}$

Το Γράφημα της κανονικής κατανομής είναι ένα άθροισμα παραλληλόγραμμων



Ο μέσος όρος είναι  $\mu = \frac{a+b}{2}$

Η διασπορά είναι  $\sigma = \frac{(b-a)^2}{12}$

Η ομοιόμορφη κατανομή είναι γενικά μικρής χρησιμότητας (ως και πολύ μικρής)

Δεν δίνει πολλές πληροφορίες πέραν εκείνων που διαισθητικά διαθέτουμε

ΔΙΩΝΥΜΙΚΗ ΚΑΤΑΝΟΜΗ

Ονομάζεται διωνυμική γιατί μπορεί να πάρει μόνο δύο τιμές όπως πχ στο στρίψιμο ενός νομίσματος, κλπ

Όταν κάνουμε το πείραμα μία και μόνη φορά

p πιθανότητα να συμβεί ένα φαινόμενο (επιτυχία) άρα η πιθανότητα να μην συμβεί είναι 1-P=q (αποτυχία)

Αν επαναλάβουμε το πείραμα n φορές, η πιθανότητα P να συμβεί το φαινόμενο x φορές (άρα να μην συμβεί n-x) δίνεται από τη σχέση

$$P(x) = \frac{n!}{x! (n-x)!} p^x q^{n-x}$$

Όταν κάνουμε το πείραμα μια φορά η κατανομή πιθανοτήτων ονομάζεται **Bernouli** (δεν θα ασχοληθούμε)

Πως αναγνωρίζουμε μια διωνυμική κατανομή?

1. Δύο ΜΟΝΟ αποτελέσματα (σωστό-λάθος, 0-1, pass-fail κλπ)
2. Ανεξαρτησία πειραμάτων (αν το  $n-1$  πείραμα έχει ως αποτέλεσμα λάθος, το  $n$  θα διατηρήσει την ελευθερία του να βγάλει σωστό / λάθος, δεν θα επηρεαστεί από το προηγούμενο πείραμα)
3. Καθορισμένος (μικρός) αριθμός επαναλήψεων  $n$
4. Η πιθανότητα επιτυχίας  $p$  ενός αποτελέσματος παραμένει σταθερή

## 1° ΚΕΦΑΛΑΙΟ

1. Το μικρότερο σωματίδιο της ύλης που μπορεί να υπάρχει σε ελεύθερη κατάσταση και να διατηρεί τις ιδιότητες της ουσίας στην οποία ανήκει είναι :

- α. το άτομο
- β. το μόριο
- γ. το ιόν
- δ. το πρωτόνιο

2. Τα ιόντα είναι:

- α. ηλεκτρικά φορτισμένα σωματίδια
- β. ηλεκτρικά φορτισμένα άτομα
- γ. ηλεκτρικά φορτισμένα συγκροτήματα ατόμων
- δ. άτομα ή συγκροτήματα ατόμων με ηλεκτρικό φορτίο.

3. Ο ατομικός αριθμός εκφράζει:

- α. τον αριθμό των πρωτονίων και νετρονίων στον πυρήνα ενός ατόμου.
- β. τον αριθμό των ηλεκτρονίων ενός μονοατομικού ιόντος
- γ. τον αριθμό των νετρονίων στον πυρήνα ενός ατόμου
- δ. τον αριθμό των πρωτονίων στον πυρήνα κάθε ατόμου ενός στοιχείου

4. Ο μαζικός αριθμός εκφράζει:

- α. τον αριθμό των πρωτονίων και νετρονίων στον πυρήνα ενός ατόμου.
- β. τον αριθμό των ηλεκτρονίων ενός μονοατομικού ιόντος
- γ. τον αριθμό των νετρονίων στον πυρήνα ενός ατόμου
- δ. τον αριθμό των πρωτονίων στον πυρήνα κάθε ατόμου ενός στοιχείου

5. Το κατιόν  $\text{Ca}^{2+}$  περιέχει 20 νετρόνια και 18 ηλεκτρόνια. Ο μαζικός αριθμός του Ca είναι :

- α. 40
- β. 38
- γ. 20
- δ. 18

6. Το ανιόν  $\text{Cl}^-$  περιέχει 20 νετρόνια και 18 ηλεκτρόνια. Ο μαζικός αριθμός του Cl είναι :

- α. 20
- β. 37
- γ. 38
- δ. 17

7. Τα ισότοπα άτομα έχουν:

- α. ίδιο αριθμό πρωτονίων και νετρονίων
- β. ίδιο μαζικό και διαφορετικό ατομικό αριθμό
- γ. ίδιο αριθμό πρωτονίων και διαφορετικό αριθμό νετρονίων
- δ. ίδιο αριθμό πρωτονίων και διαφορετικό αριθμό ηλεκτρονίων.

8. Σε ποια από τις παρακάτω περιπτώσεις δε θα σχηματιστεί μείγμα;

- α. κατά την προσθήκη ζάχαρης σε νερό
- β. κατά την προσθήκη νερού σε λάδι
- γ. κατά την ανάμειξη ζεστού με κρύο νερό
- δ. κατά το επιφανειακό σκούρισμα του σιδήρου

9. Ποια από τις παρακάτω ιδιότητες που αναφέρονται στα ομογενή μείγματα δεν ισχύει ;

- α. έχουν ίδια πυκνότητα σε όλη την έκταση του όγκου τους
- β. έχουν μεταβλητή πυκνότητα, ανάλογα με την αναλογία με την οποία αναμείχτηκαν τα συστατικά τους
- γ. η πυκνότητά τους ισούται με το άθροισμα των πυκνοτήτων των συστατικών τους
- δ. η πυκνότητά τους αυξάνεται όταν ψύχονται με σταθερή πίεση.

κατανομή Bernoulli

Ένα τεστ ερωτήσεων πολλαπλής επιλογής

- Σε κάθε μια ερώτηση ακολουθεί (ποια είναι η πιθανότητα να απαντήσουμε σωστά σε μία από τις ερωτήσεις)
- Στο σύνολο ακολουθεί (ποια είναι η πιθανότητα να απαντήσουμε σωστά στο 70% των ερωτήσεων του τεστ)

διωνυμική κατανομή

Ονομάζεται διωνυμική γιατί μπορεί να πάρει μόνο δύο τιμές όπως πχ στο στρίψιμο ενός νομίσματος κλπ

Όταν κάνουμε το πείραμα μία και μόνη φορά

p πιθανότητα να συμβεί ένα φαινόμενο (επιτυχία) άρα η πιθανότητα να μην συμβεί είναι 1-p=q (αποτυχία)

Αν επαναλάβουμε το πείραμα n φορές, η πιθανότητα P να συμβεί το φαινόμενο x φορές (άρα να μην συμβεί n-x) δίνεται από τη σχέση

$$P(x) = \frac{n!}{x!(n-x)!} p^x q^{n-x}$$

Που είναι η συνάρτηση πιθανότητας της διωνυμικής κατανομής

Τι είναι  
αυτό?



Ας θέσουμε το ερώτημα



1  
Ποια είναι η πιθανότητα

Ένα κέρμα  
2

3  
Μετά από  $n$  επαναλήψεις

$$P(x) = \frac{n!}{x!(n-x)!} p^x q^{n-x}$$

6  
ξέροντας ότι σε μια επανάληψη έρχεται  
 $p$  φορές από τη μεριά του κεφαλιού  
και  $q$  φορές από την άλλη μεριά

4  
να έλθει  $x$  φορές από τη μία πλευρά (άρα  $n-x$  φορές από την άλλη)

7

Ας θέσουμε το ερώτημα



Ο όρος αυτός μας δείχνει τους συνδυασμούς που μπορεί να υπάρχουν

$$P(x) = \frac{n!}{x!(n-x)!} p^x q^{n-x}$$

ξέροντας ότι σε μια επανάληψη έρχεται  $p$  φορές από τη μεριά του κεφαλιού

και  $q$  φορές από την άλλη μεριά

π.χ. Τρεις συνδυασμοί για το παραπάνω κέρμα με ένα κεφάλι και δύο γράμματα



$$\frac{n!}{x!(n-x)!} = \frac{3!}{1!(3-1)!} = \frac{3!}{1!(3-1)!}$$

3 συνδυασμοί




Ας θέσουμε το ερώτημα



Ο όρος αυτός μας δείχνει τους συνδυασμούς που μπορεί να υπάρχουν

$$P(x) = \frac{n!}{x!(n-x)!} p^x q^{n-x}$$



ξέροντας ότι σε μια επανάληψη έρχεται p φορές από τη μεριά του κεφαλιού

και q φορές από την άλλη μεριά

Αν χρησιμοποιήσω ένα κανονικό κέρμα οι πιθανότητες είναι 0.5 για κάθε πλευρά

Θα χρησιμοποιήσω ένα «πειραγμένο» που οι πιθανότητες να έλθει κεφάλι είναι 40%

Άρα  $p=0.4$  συνεπώς  $q=1-p=0.6$

Αν κάνω 4 προσπάθειες ποια είναι η πιθανότητα να φέρω 2 φορές (από τις 4) κεφάλι?

$$p^x q^{n-x} = 0.4^2 0.6^{4-2} = 0.4^2 0.6^{4-2} = 0.4 \times 0.4 \times 0.6 \times 0.6$$

Ίσως πρέπει να βάλω 4 πειράματα και στην προηγούμενη διαφάνεια



Τι λρω? Ότι η πιθανότητα είναι το 0.4 του 0.4 του 0.6 του 0.6

Το δεύτερο μέρος μας λέει τις πιθανότητες και το πρώτο? Τους συνδυασμούς των πιθανοτήτων π.χ. μα άλλη πιθανότητα είναι το 0.4 του 0.6 του 0.4 του 0.6

## Διάγραμμα της διωνυμικής κατανομής

Συνήθως χρησιμοποιούμε ένα ιστόγραμμα συχνοτήτων (είναι μη συνεχής=διακριτή κατανομή)

Αν πραγματοποιήσουμε  $n$  πειράματα θα παρασταθούν από  $n+1$  ράβδους



Διακύμανση διωνυμικής κατανομής

$$\sigma^2 = npq = np(1-p)$$

Μέσος όρος της διωνυμικής κατανομής

$$\mu = np$$


KATANOMH Poisson

KATANOMH Poisson

OXI Poison



ή



pwa·son

[https://www.youtube.com/watch?v=HeyYyfPgMmg&ab\\_channel=JulienMiquel](https://www.youtube.com/watch?v=HeyYyfPgMmg&ab_channel=JulienMiquel)

Η κατανομή Poisson περιγράφει την πιθανότητα εμφάνισης ενός αποτελέσματος σε μια συγκεκριμένη ΣΥΝΕΧΗ ποσότητα (όγκος, χρόνος, απόσταση κλπ) αν ξέρουμε τη συχνότητα εμφάνισης του φαινομένου

Πχ σεισμοί στη διάρκεια ενός έτους, πιθανότητα εμφάνισης ενός συγκεκριμένου μορίου σε μια επιφάνεια που σαρώνει ένα φασματόμετρο μάζας MALDI-TOF κλπ

Η πιθανότητας εμφάνισης αυτού του αποτελέσματος έχει κάποιο συγκεκριμένο ρυθμό που έχουμε παρατηρήσει και συμβολίζεται με

$\lambda$

Τι θέλουμε να μάθουμε? Ποια είναι η πιθανότητα αυτό το φαινόμενο να συμβεί περισσότερες ή λιγότερες φορές από την συχνότητα εμφάνισης  $\lambda$ .

Π.χ. ποια η πιθανότητα εμφάνισης τριών σεισμών την επόμενη χρονιά, όταν ο ρυθμός εμφάνισής τους είναι 2/έτος

Προϋποθέσεις για να υπάρχει κατανομή Poisson

1. Τα γεγονότα να είναι ανεξάρτητα μεταξύ τους πχ. στο πολύ ευχάριστο θέμα των σεισμών ο ένας να μην έχει προκαλέσει τον επόμενο
2. Ο ρυθμός εμφάνισης του φαινομένου  $\lambda$  να είναι σταθερός

Η συνάρτηση πιθανότητας (κανονικά για όλες τις κατανομές συνάρτηση πυκνότητας πιθανότητας Probability density function PDF) δίνεται από τον ακόλουθο τύπο

$$p(x) = \frac{\lambda^x e^{-\lambda}}{x!}$$

Όπου  $x=0, 1, 2, 3, 4, 5\dots$

Η κατανομή έχει μια ελάχιστη τιμή, το 0, αλλά στις θετικές τιμές  $\rightarrow \infty$  συνεπώς ο συντελεστής ασυμμετρίας (**skewness**) είναι  $>1$

Τι είναι το  $\lambda$  είπαμε?

Ο ρυθμός εμφάνισης ενός αποτελέσματος πχ πόσα αυτοκίνητα περνούν από ένα δρόμο σε μια ώρα

$$\lambda = \frac{\text{αριθμός αυτοκινητων}}{\text{ώρα}}$$

Ποιο είναι ο μέσος όρος (ή διασταλτικά λίγο η αναμενόμενη τιμή  $E(x)$ ) της κατανομής Poisson?

$$\mu = E(x) = \lambda$$

Ποια είναι η διασπορά  $\sigma^2$  ?

$$\sigma^2 = \lambda$$

!!!!!!!!!!!!!!!!!!!!!!

Η τυπική απόκλιση ?

$$\sigma = \sqrt{\sigma^2} = \sqrt{\lambda}$$

Σχέση της κατανομής Poisson με τη διωνυμική κατανομή

Η αναμενόμενη τιμή  $E(x)$  της διωνυμικής κατανομής είναι  $E(x) = np$

Εάν το  $n$  γίνει πολύ μεγάλο και το  $p$  γίνει πολύ μικρό τότε το  $\lim \rightarrow \infty$  της διωνυμικής κατανομής είναι η κατανομή Poisson

Ας δούμε ένα παράδειγμα






Όπως είπαμε πριν πχ πόσα αυτοκίνητα περνούν από ένα δρόμο σε μια ώρα και ας το προσεγγίσουμε με μια διωνυμική κατανομή  $E(x) = np$  όπου

$$n = \frac{\text{αριθμός αυτοκινητων}}{\text{ώρα}} \text{ και } p = \text{πιθανότητα να συμβαίνει το φαινόμενο αυτό}$$


Αν ήθελα να έχω μια καλύτερη εκτίμηση ίσως θα ήταν πιο λογικό να μειώσω το χρόνο παρατήρησης πχ να τον κάνω 1 λεπτό. Αυτό σημαίνει ότι το  $n$  θα μεγαλώνει και αντίστοιχα θα μειώνει την πιθανότητα

Ας πούμε ότι αρχικά ο αριθμός των παρατηρήσεων είναι  $n = 10$  (δηλαδή έχω ξοδέψει 10 ώρες) και η πιθανότητα να παρατηρήσω 60 αυτοκίνητα είναι 0.5 (είπαμε είναι δυαδικό φαινόμενο η διωνυμική κατανομή) βλέπω η όχι 60 αυτοκίνητα. Αν αυξήσω τον αριθμό των παρατηρήσεων (κάθε λεπτό, άρα  $n=60 \times 10=600$ ) η πιθανότητα  $p$  μικραίνει – σιγά μην δω 60 αυτοκίνητα /λεπτό με πιθανότητα 0.5. Στη σχέση το γινόμενο όμως παραμένει περίπου σταθερό. Αυτή είναι και η ψυχή της κατανομής Poisson –είναι μια ειδική διωνυμική κατανομή

# Πως μοιάζει ένα διάγραμμα κατανομής Poisson? Για $n=50$





Πως μοιάζει ένα διάγραμμα κατανομής Poisson? Για  $n=50$



**Οι κατανομή εξαρτάται από το  $\lambda$**

**Η θέση της αλλά και το πλάτος της όπως έχουμε δει**

**Για τιμές κοντά στο κέντρο του διαστήματος που εξετάζουμε γίνεται (σχεδόν) συμμετρική**




Probability ( $X = x$ )

0.08  
0.06  
0.04  
0.02  
0.00

0 10 20 30 40 50


X



$\lambda=25$

Η διαφορά στο πλάτος είναι φανερή



$\lambda=10$



Ποια είναι η εντολή στο excel για να δημιουργήσω μια κατανομή?  
 Θα την δημιουργήσουμε μαζί και στο λογισμικό JASP

mean λ	7
P(x)	
1	0.006383
2	0.022341
3	0.052129
4	0.091226
5	0.127717
6	0.149003
7	0.149003
8	0.130377
9	0.101405
10	0.070983
11	0.045171
12	0.02635
13	0.014188
14	0.007094
15	0.003311
16	0.001448
17	0.000596
18	0.000232
19	8.54E-05
20	2.99E-05

=POISSON.DIST(A5,\$B\$2,FALSE)



**KATANOMH KATA Gauss**

**Καί**

**KANONIKH KATANOMH**

Η κατανομή κατά Gauss είναι η πιο χρησιμοποιούμενη κατανομή στις φυσικές επιστήμες


Ένας μεγάλος αριθμός στατιστικών δοκιμασιών υποθέτουν την ύπαρξη κατανομής Gauss στα δεδομένα και προσπαθούν να αποδείξουν ότι τα δεδομένα ακολουθούν κανονική κατανομή (normality tests)

Πολλές χημικές δοκιμασίες εμπλέκουν την κατανομή Gauss (πολύ σπανιότερα και σε δύσκολες περιπτώσεις την κατανομή Lorentz)

Π.χ.

Οι χρωματογραφικές κορυφές, οι κορυφές των φασμάτων μάζας και πολύ συχνά του NMR, τα σημεία σε μια καμπύλη αναφοράς κλπ προσεγγίζονται με κατανομές Gauss


Η κατανομή Gauss είναι η πρώτη συνεχής (continuous) κατανομη που εξετάζουμε – δηλαδή μπορεί να πάρει απειρες τιμές (που προέρχονται από κάποια πολυπλοκη συχνά συνάρτηση)



Η ιδέα για την κατανομή Gauss προέρχεται από την κατανομή Poisson

Η γραφική παράσταση της κατανομής Poisson εξαρτάται από το  $\lambda$

Για  $\lambda > 10$  η κατανομή Poisson γίνεται σχεδόν συμμετρική (δεν μπορεί να πάρει αρνητικές τιμές – ποτέ δεν γίνεται ΑΠΟΛΥΤΑ συμμετρική) και μοιάζει με την κατανομή Gauss που είναι πάντα συμμετρική



Πως αναγνωρίζουμε μια κατανομή Gauss? (στα ελληνικά συχνά βλέπουμε τον όρο Γκαουσιανή...)

1. Είναι συνεχής συνάρτηση
2. Τα πειράματα είναι ανεξάρτητα
3. Έχει σχήμα καμπάνας
4. Έχει συμμετρία και έλλειψη κυρτότητας
5. Είναι ασυμπτωτική στον άξονα των  $x$
6. Η μέση τιμή συμπίπτει με τη διάμεση
7. Ισχύει ο κανόνας 68-96-99.7



Κανονικότητα (normality)

Στατιστικές δοκιμασίες που χρησιμοποιούνται επιπρόσθετα

Δοκιμασίες κανονικότητας


Οπτική δοκιμασία διάγραμμα QQ

Υπολογιστικές δοκιμασίες D'Agostino-Pearson, Anderson-Darling, Shapiro-Wilk and Kolmogorov-Smirnov

**ΔΥΣΚΟΛΑ ΤΑ ΠΡΑΓΜΑΤΑ**




## Έχει σχήμα καμπάνας



Μέγιστη πιθανότητα να συναντήσω την τιμή αυτή


Οι πιθανότητες να συναντήσουμε διαφορετικές τιμές δεν είναι ίδια. Πιο πιθανό να συναντήσουμε τιμές κοντά στο κέντρο της κατανομής.

Η πιθανότητα με την οποία εμφανίζονται διάφορες τιμές δεν είναι γραμμική




Μικρότερη πιθανότητα να συναντήσω την τιμή αυτή

Έχει συμμετρία και έλλειψη λοξότητας (skewness)




Συμμετρική κατανομή (προυπόθεση για να είναι κανονική)


Συμμετρία  $\alpha=\beta$




Δεν είναι κανονικές κατανομές



Η μέση τιμή συμπίπτει με τη διάμεση



Μέση τιμή  
Διάμεση τιμή  
Επικρατούσα τιμή



Επικρατούσα τιμή

Συμπίπτουν

διάμεση τιμή επικρατούσα τιμή

Μέση τιμή ή μέσος όρος (average ή mean value)

Σωστά ο αριθμητικός μέσος όρος

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum x_i}{n}$$

Αν όμως υπάρχει διαφορετική αξιολόγηση για την κάθε μέτρηση που συνεισφέρουν κατά διαφορετικό τρόπο τότε μπορούμε να χρησιμοποιήσουμε την μέση τιμή με διαφορετικό στατιστικό βάρος

$$\bar{x}_w = \frac{w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n}{w_1 + w_2 + w_3 + \dots + w_n} = \frac{\sum x_i w_i}{\sum w_i}$$

## Διάμεση τιμή

### Προβλήματα μέσης τιμής

1. Επηρεάζεται πολύ από τις έκτροπες τιμές

1, 1, 1, 1, 1  $\longrightarrow$  1

1, 1, 1, 1, 2  $\longrightarrow$  1,2 τιμή 20% μεγαλύτερη

2. Ο μέσος όρος μιας κανονικής κατανομής δεν λαμβάνει υπόψη το γεγονός ότι η πιθανότητα να συναντήσουμε τιμές όλο και μακρύτερα από το μέσο όρο μικραίνει. Στο μέσο όρο η απίθανη μακρινή τιμή έχει το ίδιο στατιστικό βάρος με την πολύ πιθανή τιμή που βρίσκεται κοντά στο μέσο όρο

### Τι είναι η διάμεση τιμή

Η τιμή που χωρίζει τον πληθυσμό στα δύο αν οι τιμές είναι μονές ή ο μέσος όρος των δυο μεσαίων τιμών αν είναι ζυγές.


Τι πλεονέκτημα έχει? Ότι (προφανώς) αδιαφορεί για έκτροπες τιμές.

Ανήκει στα ανθεκτικά στατιστικά μεγέθη (robust)

## Διάμεση τιμή

### Προβλήματα μέσης τιμής

1. Επηρεάζεται πολύ από τις έκτροπες τιμές
2. Ο μέσος όρος μιας κανονικής κατανομής δεν λαμβάνει υπόψη το γεγονός ότι η πιθανότητα να συναντήσουμε τιμές όλο και μακρύτερα από το μέσο όρο μικραίνει. Στο μέσο όρο η απίθανη μακρινή τιμής έχει το ίδιο στατιστικό βάρος με την πολύ πιθανή τιμή που βρίσκεται κοντά στο μέσο όρο



### Τι είναι η διάμεση τιμή

Η τιμή που χωρίζει τον πληθυσμό στα δύο αν οι τιμές είναι μονές ή ο μέσος όρος των δυο μεσαίων τιμών αν είναι ζυγές.

Τι πλεονέκτημα έχει? Ότι (προφανώς) αδιαφορεί για έκτροπες τιμές.

Ανήκει στα ανθεκτικά στατιστικά μεγέθη (robust)

## Διάμεση τιμή

### Προβλήματα μέσης τιμής

1. Επηρεάζεται πολύ από τις έκτροπες τιμές
2. Ο μέσος όρος μιας κανονικής κατανομής δεν λαμβάνει υπόψη το γεγονός ότι η πιθανότητα να συναντήσουμε τιμές όλο και μακρύτερα από το μέσο όρο μικραίνει. Στο μέσο όρο η απίθανη μακρινή τιμή έχει το ίδιο στατιστικό βάρος με την πολύ πιθανή τιμή που βρίσκεται κοντά στο μέσο όρο

4, 5, 1, 1, 2

Επικρατέστερη τιμή  
είναι το 1 γιατί  
εμφανίζεται δυο  
φορές

Ποια άλλη τιμή είναι χρήσιμη? Η επικρατέστερη τιμή που είναι αυτή με την υψηλότερη συχνότητα εμφάνισης

Υπάρχουν άλλα στατιστικά μεγέθη σχετιζόμενα με τον μέσο όρο

Πολλά αλλά σπανίως χρησιμοποιούμενα

1. Ο γεωμετρικός μέσος όρος

$$\bar{x}_g = \sqrt[n]{x_1 x_2 x_3 \dots x_n}$$

Χρησιμοποιείται για πολύ ασύμμετρες κατανομές

2. Ο αρμονικός μέσος όρος

Χρησιμοποιείται συχνά όταν θέλουμε να υπολογίσουμε αντίστροφες σχέσεις

$$\bar{x}_h = \frac{1}{\frac{1}{n} \left( \frac{1}{x_1} + \frac{1}{x_1} + \frac{1}{x_1} + \dots + \frac{1}{x_n} \right)} = \frac{n}{\sum \left( \frac{1}{x_i} \right)}$$

Η έννοια της επαναληπτικότητας των  
μετρήσεων

Πολύ σημαντικό πρόβλημα της χημικής ανάλυσης αλλά και της επιστήμης των μετρήσεων είναι αν οι τιμές που λαμβάνονται παρουσιάζουν προβλέψιμη τυχαιότητα.

Δηλαδή κατά την επανάληψή τους τα αποτελέσματα δεν είναι χαοτικά αλλά ακολουθούν κάποιο στατιστικό μοντέλο

Έντουαρντ Λόρεντζ

Χάος: Όταν το παρόν καθορίζει το μέλλον, αλλά η προσέγγιση του παρόντος δεν προσδιορίζει κατά προσέγγιση το μέλλον.

Wikipedia

Η θεωρία του Χάους μελετά τη συμπεριφορά ορισμένων μη γραμμικών δυναμικών συστημάτων, που είναι ιδιαίτερα ευαίσθητα στις αρχικές συνθήκες, ένα αποτέλεσμα το οποίο ευρέως αναφέρεται ως το φαινόμενο της πεταλούδας. **Μικρές διαφορές στις αρχικές συνθήκες** (όπως αυτές που οφείλονται σε σφάλματα στρογγυλοποίησης σε αριθμητικούς υπολογισμούς) **αποδίδουν πολύ διαφορετικά αποτελέσματα** για τα δυναμικά συστήματα, καθιστώντας τη **μακροπρόθεσμη πρόβλεψη αδύνατη** σε γενικές γραμμές. Αυτό συμβαίνει παρ' όλο που αυτά τα συστήματα είναι αιτιοκρατικά ("ντετερμινιστικά"), πράγμα που σημαίνει ότι η μελλοντική συμπεριφορά τους καθορίζεται πλήρως από τις αρχικές συνθήκες τους, χωρίς να εμπλέκονται τυχαίες παράμετροι. Με άλλα λόγια, **η ντετερμινιστική φύση αυτών των συστημάτων δεν τα κάνει προβλέψιμα**

[https://itp.uni-frankfurt.de/~gros/Vorlesungen/SO/simulation\\_example/](https://itp.uni-frankfurt.de/~gros/Vorlesungen/SO/simulation_example/)

<https://www.myphysicslab.com/pendulum/compare-pendulum-en.html>

Ας ορίσουμε τα μεγέθη που μας περιγράφουν την επαναληψιμότητα

Είναι αρκετά και στο τέλος θα κρατήσουμε ένα

Μέτρα επαναληψιμότητας (επαναληπτικότητα?)

Το απλούστερο είναι το εύρος

Εύρος

Διαφορά μεταξύ της μεγαλύτερης και της μικρότερης τιμής

$$R = x_{max} - x_{min}$$

SOS ισχυει για ~10 δείγματα

Είναι δυνατός ο υπολογισμός της απόκλισης (που θα δούμε στη συνέχεια) από το εύρος με τη βοήθεια της παρακάτω σχέσης

$$R\sigma_R = c \times R$$

Οι συντελεστές  $c$  δίνονται από σχετικό πίνακα




Μια ιδέα είναι

Να βρούμε την απόκλιση από τον μέσο όρο κάθε μέτρησης.

Αν το άθροισμα των αποκλίσεων είναι μεγάλο δεν επαναλαμβάνεται και πολύ το πείραμα

Μέσος όρος



$$1+2+3+4+5+6$$


Το άθροισμα των αποκλίσεων

Μια ιδέα είναι


Να βρούμε την απόκλιση από τον μέσο όρο κάθε μέτρησης.

Αν το άθροισμα των αποκλίσεων είναι μεγάλο δεν επαναλαμβάνεται και πολύ το πείραμα


Μέσος όρος



Μέσος όρος



Μέσος όρος



## Μέση απόκλιση

Θα μπορούσε η απόκλιση αντί να τετραγωνίζεται εναλλακτικά να παρέχεται ως απόλυτη τιμή. Έτσι ορίζουμε την μέση απόκλιση  $\bar{d}$

$$\bar{d} = \frac{|\bar{x} - x_i|}{n} = \frac{|\bar{x} - x_i| + |\bar{x} - x_i| + |\bar{x} - x_i| + \dots + |\bar{x} - x_i|}{n}$$

## Πρόβλημα της μέσης απόκλισης

Δίνει την ίδια σημασία σε όλες της αποκλίσεις ενώ στην κανονική κατανομή αυτές που βρίσκονται κοντά στο κέντρο είναι πιθανότερες

## Τυπική απόκλιση

Θα μπορούσε η απόκλιση να τετραγωνίζεται ώστε πάντα να έχει θετικό πρόσημο (όταν παρατηρείται λάθος θα θέλαμε πάντα να αθροίζεται). Ορίζουμε την μέση (ΔΕΙΓΜΑΤΙΚΗ) απόκλιση  $s$

$$s = \sqrt{\frac{\sum(\bar{x} - x_i)^2}{n - 1}}$$

Αν  $s \rightarrow \infty$  τότε ο μέσος όρος γίνεται  $\bar{x} \rightarrow \mu$  (ο πληθυσμιακός μέσος όρος) και το  $s \rightarrow \sigma$  (η πληθυσμιακή τυπική απόκλιση)

$$\sigma = \sqrt{\frac{\sum(\mu - x_i)^2}{n}}$$

Οι τρεις διαφορές

Οι δύο είναι αναμενόμενες  $\sigma$  και  $\mu$

Η τρίτη  $n \rightarrow n-1$  οφείλεται στην αμελητέα συμμετοχή του  $-1$  σε άπειρο πλήθος παρατηρήσεων

$$\sigma = \sqrt{\frac{\sum(\mu - x_i)^2}{n}}$$

$$s = \sqrt{\frac{\sum(\bar{x} - x_i)^2}{n-1}}$$

Τι είναι το  $n-1$  όμως

Οι **βαθμοί ελευθερίας** (θα δούμε παρακάτω)

$$\sigma = \sqrt{\frac{\sum(\mu - x_i)^2}{n}}$$

**ΠΛΗΘΥΣΜΙΑΚΗ ΤΥΠΙΚΗ ΑΠΟΚΛΙΣΗ**

$$s = \sqrt{\frac{\sum(\bar{x} - x_i)^2}{n-1}}$$

**ΔΕΙΓΜΑΤΙΚΗ ΤΥΠΙΚΗ ΑΠΟΚΛΙΣΗ**

SOS

Μια πιο εύκολη σχέση υπολογισμού της τυπικής απόκλισης

$$s = \sqrt{\frac{1}{n-1} \left[ \sum x_i^2 - \frac{\sum x_i^2}{n} \right]}$$

Στη σχέση αυτή συμμετέχουν μόνο οι καταχωρίσεις μιας σειράς αριθμών (δηλαδή τιμές δειγμάτων) και όχι το  $\bar{x}$  που περιπλέκει τα πράγματα καθώς πρέπει να υπολογίζεται και αυτό κάθε φορά που μεταβάλλονται οι καταχωρίσεις

Τι γίνεται για δείγματα διαφορετικών πληθυσμών μιας μεθόδου

$$s = \sqrt{\frac{\sum (\bar{x}_1 - x_{i,1})^2 + (\bar{x}_2 - x_{i,2})^2 + (\bar{x}_3 - x_{i,3})^2 + \dots + (\bar{x}_k - x_{i,k})^2}{n - k}}$$

ή πιο συνεπτυγμένα

$$s = \sqrt{\frac{\sum \sum (x_j - x_{j,i})^2}{n - k}}$$

$x_{i,1}$  τα δείγματα του πρώτου υποπληθυσμού που χρησιμοποιούμε στη μέθοδο και  $\bar{x}_1$  ο μέσος όρος του πρώτου υποπληθυσμού κλπ

$n$  ο συνολικός αριθμός των μετρήσεων και

$k$  ο συνολικός αριθμός των δειγμάτων

A large crowd of people is gathered at night, with confetti scattered on the ground. In the background, city lights and buildings are visible. The text "%RSD" is overlaid in the center of the image.

%RSD

% σχετική τυπική απόκλιση (% relative standard deviation)


Ίσως το πιο χρησιμοποιούμενο μέγεθος

Τι μας λέει? Πόσο % είναι μεγαλύτερη η τυπική απόκλιση από τον μέσο όρο


$$\% s_{rel} = \frac{s}{\bar{x}} \times 100$$

Βαθμοί ελευθερίας (ένα δύσκολα κατανοήσιμο διαισθητικό μέγεθος)

Ας δούμε ένα παράδειγμα από τη φυσική



3 βαθμοί ελευθερίας



2 βαθμοί ελευθερίας




1 βαθμός ελευθερίας

Μια ευθεία έχει  $n-2$  βαθμούς ελευθερίας γιατί δύο τουλάχιστον σημεία της είναι καθορισμένα


Μια κατανομή με πεπερασμένα σημεία?  $N-1$  πχ τρεις μετρήσεις  $x_1 + x_2 + x_3 = \bar{x}$  και ξέρουμε τις δύο πρώτες η Τρίτη είναι αυστηρά καθορισμένη

Επιστρέφουμε στην  
κατανομή Gauss


Η κατανομή Gauss έχει την εξαιρετική δυνατότητα να είναι καθοριζόμενη από την τυπική απόκλιση




Πως? Αν κινηθούμε **μια** τυπική απόκλιση από τον μέσο όρο αριστερά ή δεξιά τότε ξέρουμε ότι 68 στις 100 φορές που θα κάνουμε μια μέτρηση ο μέσος όρος θα βρίσκεται στην περιοχή αυτή



Δύο τυπικές αποκλίσεις τότε 95.55%



τρεις τυπικές αποκλίσεις τότε 99.73%



Δηλαδή ξέρουμε με σιγουριά ο μέσος όρος βρίσκεται στο όριο των τριών τυπικών αποκλίσεων

Αυτός είναι και ο κανόνας 68-96-99.7 (που αναφέρεται σε τυπικές αποκλίσεις)


Τι σημαίνει τελικά η κανονική κατανομή?

Είναι η έκφραση της τυχαιότητας. Όταν κάτι είναι τυχαίο λемέ ότι η πιθανότητα να το παρατηρήσουμε ακολουθεί κανονική κατανομή και συνεπώς και τα σφάλματα του  $\bar{x} - x_i$  ακολουθούν και αυτά κανονική κατανομή.

Αλλιώς το ίδιο

Υπάρχει διασπορά τιμών γύρω από την αληθή τιμή. Η διασπορά των τιμών ακολουθεί κατανομή κατά Gauss.

Κατανομή κατά Gauss η κανονική κατανομή. Δεν είναι πολύ σαφές. Υπάρχει η κατανομή που έχει  $\bar{x} = 0$  και  $\sigma^2 = 1$ . Συχνά ονομάζεται κανονικοποιημένη κατανομή Gauss.



## Εξίσωση της κατανομής Gauss

$$P_x = \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Όπου





$\mu$  η αληθής τιμή του πληθυσμού

$\sigma$  ο πληθυσμιακή τυπική απόκλιση

και  $x$  η εκάστοτε τιμή

Τι βλέπουμε? Ότι η κατανομή εξαρτάται από δυο όρους το  $\mu$  και το  $\sigma$

Το  $\mu$  καθορίζει τη θέση της κατανομής ενώ το  $\mu$  το πλάτος της



Πως υπολογίζεται η πιθανότητα μια τιμή να βρίσκεται μεταξύ κάποιων ορίων (intervals)?

Από πίνακες (στην επόμενη σελίδα) ή με τη βοήθεια υπολογιστή (

ΑΛΛΑ

Πρώτα πρέπει να κανονικοποιήσουμε τις τιμές της κατανομής. Πως γίνεται αυτό?

Με τις τιμές  $z$

Πως τις υπολογίζουμε? Απλά

$$z = \frac{(x - \mu)}{\sigma}$$

Δηλαδή πόσες φορές η απόσταση από τη μέση τιμή είναι μεγαλύτερη από την τυπική απόκλιση?

Γιατί χρησιμοποιούμε αυτή την κανονικοποίηση?

Γιατί οι κατανομές έχουν άπειρο πλήθος τιμών  $\mu$  και  $\sigma$ . Θα επρεπε να υπολογίσουμε έτσι άπειρο πλήθος κατανομών. Με την  $z$  κανονικοποίηση, όλες οι κατανομές λύνονται καθώς όλες αποκτούν  $\mu=0$  και  $\sigma=1$

Παράδειγμα

Επαναλαμβανόμενες μετρήσεις μια χημικής ανάλυσης μας δίνουν μέσο όρο 10.15mL με τυπική απόκλιση 0.02 mL. Πόσο ποσοστό των μετρήσεων θα βρίσκεται μεταξύ 10.12 mL και 10.20 mL?

$Z=(10.12-10.15)/0.02=-1.5 \rightarrow$  πίνακας επόμενης σελίδας  $F(-1.5) = 0.0668$  η ΣΥΝΟΛΙΚΗ πιθανότητα να βρεθεί μια μέτρηση 10.12mL

$Z=(10.20-10.15)/0.02=2.5 \rightarrow$  πίνακας επόμενης σελίδας  $F(2.5) = 0.9938$  η ΣΥΝΟΛΙΚΗ πιθανότητα να βρεθεί μια μέτρηση 10.20mL

Διαφορά=0.927 η ΣΥΝΟΛΙΚΗ πιθανότητα να βρεθεί μια μέτρηση 10.12mL και 10.20 mL



## ΚΕΝΤΡΙΚΟ ΟΡΙΑΚΟ ΘΕΩΡΗΜΑ

Σε απλά λόγια ο μέσος όρος των μέσων όρων πολλών μετρήσεων είναι ακριβέστερος από τον μέσο όρο όλων των μετρήσεων

Δεν φαίνεται απλό αλλά ως παράδειγμα είναι αλούστερο

Αν έχουμε 50 μετρήσεις τότε έχουμε ένα μέσο όρο  $\bar{x}$  που πλησιάζει την πραγματική τιμή  $\mu$

Αν χωρίσουμε τις μετρήσεις σε πεντάδες (10 πεντάδες προφανώς) και υπολογίσουμε τον μέσο όρο κάθε πεντάδας προκύπτουν δέκα αριθμοί. Ο μέσος όρος αυτών των δέκα αριθμών είναι πλησιέστερος στην πραγματική τιμή  $\mu$

Δηλαδή προτιμούμε αντί για τον μέσο όρο ΟΟΟΟΟΛΩΝ των παρατηρήσεων να χωρίσουμε τις παρατηρήσεις  $p_x$  σε πεντάδες, να καταγράψουμε τον μέσο όρο της κάθε πεντάδας και μετά να βγάλουμε τον μέσο όρων των καταγεγραμμένων μέσων όρων.

## ΚΕΝΤΡΙΚΟ ΟΡΙΑΚΟ ΘΕΩΡΗΜΑ

Σε απλά λόγια ο μέσος όρος των μέσων όρων πολλών μετρήσεων είναι ακριβέστερος από τον μέσο όρο όλων των μετρήσεων

Δεν φαίνεται απλό αλλά ως παράδειγμα είναι αλούστερο

Αν έχουμε 50 μετρήσεις τότε έχουμε ένα μέσο όρο  $\bar{x}$  που πλησιάζει την πραγματική τιμή  $\mu$

ες προφανώς) και υπολογίσουμε τον μέσο όρο κάθε πεντάδας προκύπτουν  
ν είναι πλησιέστερος στην πραγματική τιμή  $\mu$

ΩΝ των παρατηρήσεων να χωρίσουμε τις παρατηρήσεις  $x_i$  σε πεντάδες, να  
μετά να βγάλουμε τον μέσο όρων των καταγεγραμμένων μέσων όρων.



Ο μέσος όρος της κατανομής παραμένει ό ίδιος θέλοντας να προσεγγίσει την πραγματική τιμή  $\mu$   
Τι αλλάζει? Η τυπική απόκλιση


Ποια είναι η τυπική απόκλιση των μέσων όρων σε μια διαδικασία που εμπλέκει την κατανομή του μέσου όρου των  
δειγμάτων? Το τυπικό σφάλμα του μέσου όρου ή αλλιώς standard error of the mean (SEM)

$$SEM = \frac{\sigma}{\sqrt{n}}$$

Έστω μια κανονική κατανομή με μέσος όρο  $\mu=0$  και τυπική απόκλιση  $\sigma=1$  από 50 δείγματα

Στο σχήμα φαίνεται η κατανομή όταν υπολογίσουμε τα δείγματα σε πεντάδες και δεκάδες μαζί με τον αρχικό πληθυσμό.

Βλέπουμε ότι ο μέσος όρος είναι ίδιος και στις τρεις περιπτώσεις αλλά η τυπική απόκλιση μικραίνει. Μας βοηθά δηλαδή να  
υπολογίζουμε τους μέσους όρους



Density

1.0  
0.8  
0.6  
0.4  
0.5  
0.4  
0.3  
0.2  
0.1  
0.0

-3

-2

-1

0

1

2


3

x

$\sigma=1/\sqrt{20}$

$\sigma=1$

$\sigma=1/\sqrt{5}$



Έχουμε δει ότι μεταξύ  $2\sigma$  και  $-2\sigma$  από τον μέσο όρο  $\mu$  βρίσκονται το 95.55% των τιμών όταν κάνουμε ένα πείραμα. Είναι ενδιαφέρον ότι έχουμε επιλέξει να μιλάμε για το 95% (όχι το 95.55%) γιατί είναι στρογγυλός αριθμός. Αυτό μεταφράζεται σε 19/20 τιμές. Αν το υπολογίσουμε είναι

**1.96σ**

Άρα η υπολογιζόμενη τιμή του πληθυσμού από το δείγμα  $\bar{x}$  έχει διαφορά  $\bar{x} - \mu$  από την πραγματική του πληθυσμού.

Το  $\bar{x} - \mu$  είναι το **σφάλμα** με το οποίο υπολογίζουμε την πραγματική διαφορά του πληθυσμού.

Όπως έχουμε πει το σφάλμα είναι **κανονικά κατανομημένο**.

Άρα το σφάλμα ακολουθεί κανονική κατανομή, οπότε στο 95 % των περιπτώσεων (από  $-1,96\sigma$  ως  $+1,96\sigma$ ) θα περιέχεται μεταξύ των δύο αυτών ορίων

Ας το γράψουμε – το σφάλμα 95 στις 100 φορές θα περιέχεται μεταξύ  $-1,96\sigma$  και  $+1,96\sigma$


$$-1,96\sigma < \mu - \bar{x} < +1,96\sigma$$

Αν χρησιμοποιήσουμε τους μέσους όρους του κεντρικού οριακού θεωρήματος

$$-1,96\sigma\sqrt{n} < \mu - \bar{x} < +1,96\sigma\sqrt{n}$$

Προσθέτουμε  $\bar{x}$  και στους τρεις όρους

$$\bar{x} - 1,96\sigma\sqrt{n} < \mu - \bar{x} + \bar{x} < \bar{x} + 1,96\sigma\sqrt{n} \Rightarrow \bar{x} - 1,96\sigma\sqrt{n} < \mu < \bar{x} + 1,96\sigma\sqrt{n}$$



Ας το σημειώσουμε λίγο διαφορετικά

$$\mu = \bar{x} \pm z \frac{\sigma}{\sqrt{n}}$$

Όπου  $z=1.96$  για επίπεδο εμπιστοσύνης 95%  
 $z=2.58$  για επίπεδο εμπιστοσύνης 99%  
 $z=2.97$  για επίπεδο εμπιστοσύνης 99.7%

Αυτά ισχύουν για μεγάλο αριθμό δειγμάτων.

Τι κάνουμε όμως αν έχουμε πεπερασμένο αριθμό δειγμάτων

????

ΚΑΤΑΝΟΜΗ  $t$   
(κατανομή του Student)

Αν έχουμε μικρό αριθμό δειγμάτων η κατανομή Gauss δεν ισχύει. Αυτό το έδειξε ένα ντροπαλός μαθηματικός ο Gosset που υπέγραψε με το όνομα Student.

Ποιο είναι το βασικό γνώρισμα μιας κατανομής Student?

Ο πεπερασμένος πληθυσμός.

Πρόβλημα που οδήγησε στη δημιουργία της κατανομής. Έστω ότι έχω ένα κανονικό πληθυσμό. Μπορώ όμως να κάνω λίγα πειράματα (π.χ. 5) και από αυτά να βγάλω συμπέρασμα για την τιμή  $\mu$  του πληθυσμού.

Τι σημαίνει αυτό? Σημαίνει ότι δεν μπορώ να υπολογίσω το  $\mu$  (γιατί πρέπει να μετρήσω όλο τον πληθυσμο όπως έχουμε δει) αλλά δεν μπορώ να υπολογίσω και το  $\sigma$  (γιατί θα πρέπει να κάνω αρκετές πχ. 5αδες πειραμάτων για να έχω μια καλή εκτίμηση αλλά έχω μόνο 5). Τι έχω τελικά στη διάθεση μου? Το  $\bar{x}$  και το  $s$  (για πεπερασμένο ΜΙΚΡΟ αριθμό δειγμάτων  $n$ )

Η κατανομή Student ισχύει με τις ίδιες προϋποθέσεις όπως και η κανονική κατανομή. Βασικά είναι μια κανονική κατανομή σε μια πιο γενική περίπτωση (γιατί ισχύει και για μικρά και για μεγάλα δείγματα)

Τύπος της κατανομής Student

$$f(t) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{t^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

Τι βλέπουμε?

Τύπος της κατανομής Student



$$f(t) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{t^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

Τι βλέπουμε?


## Τύπος της κατανομής Student


$$f(t) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{t^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$


Εξαρτάται μόνο από το  $\nu$ ! (των αριθμό των δειγμάτων) χμμμμ όχι ακριβώς  $\nu=n-1$  (βαθμοί ελευθερίας δηλαδή)

Τι είναι το  $\Gamma$ ? Είναι το  $(\nu-1)!$  (ονομάζεται συνάρτηση  $\Gamma$ )

Τι είναι το  $t$ ? Μια τυχαία μεταβλητή




Είναι διαφορετική για κάθε βαθμό ελευθερίας! Στην αρχή  $\nu=1$  είναι πλατιά στα άκρα γιατί δεν ξέρουμε με τόσο λίγα δείγματα (2) την τυπική της απόκλιση. Όταν απειρίζεται σχεδόν ακουμπά στον άξονα των  $x$  μετά από 3 τυπικές αποκλίσεις (99.7...). Που το έχουμε δει αυτό? Τι σημαίνει? Για άπειρα δείγματα είναι η γνωστή μας κατανομή Gauss



κατανομή Gauss

Κατανομές Student

Περίπου στα 30 δείγματα οι δύο κατανομές είναι πολύ παρόμοιες μεταξύ τους



Μετά από 30 δείγματα θεωρούμε ότι έχουμε μια κανονική κατανομή

Πως χρησιμοποιούμε την κατανομή Student?

Είδαμε προηγουμένως ότι




$$\mu = \bar{x} \pm z \frac{\sigma}{\sqrt{n}}$$

Επειδή όμως δεν ξέρουμε πλέον το  $\sigma$  (το  $\sigma$  από 5 μόνο δείγματα είναι πολύ κακή εκτιμήτρια συνάρτηση) θα χρησιμοποιήσουμε τη δειγματική εκτιμήτρια  $s$

$$\mu = \bar{x} \pm t \frac{s}{\sqrt{v}}$$

Τώρα στον παρονομαστή βρίσκεται το  $v$ . Τι είναι το  $v$ ? Ονομάζεται βαθμοί ελευθερίας και σχετίζεται με τον αριθμό δειγμάτων με τη σχέση  $v=n-1$  στην περίπτωση του στατιστικού  $t$ .

Και το  $t$ ? Είναι αντίστοιχο του  $z$ . Είχαμε δει στην κατανομή Gauss πως το  $z$  είχε συγκεκριμένες τιμές σταθερές για κάθε επίπεδο εμπιστοσύνης, πχ 1.96 για επίπεδο εμπιστοσύνης 95%. Το  $t$  δεν έχει αυτή την πολυτέλεια... Εξαρτάται και από το  $v$  καθώς η κατανομή έχει διαφορετικό σχήμα για κάθε αριθμό δείγματος, όπως στο σχήμα παρακάτω




Κατανομή Gauss	-1.96 / +1.96	για επίπεδο εμπιστοσύνης 95%
Κατανομή Student για $v=1$	-12.706 / +12.706	για επίπεδο εμπιστοσύνης 95%
Κατανομή Student για $n=2$	-4.303 / +4.303	για επίπεδο εμπιστοσύνης 95%
Κατανομή Student για $v=5$	-2.78 / +2.78	για επίπεδο εμπιστοσύνης 95%
Κατανομή Student για $v=20$	-2.09 / +2.09	για επίπεδο εμπιστοσύνης 95%
Κατανομή Student για $v=\infty$	-1.96 / +1.96	για επίπεδο εμπιστοσύνης 95% συμπίπτει με την κατανομή Gauss

Βλέπουμε πως το  $t$  μικραίνει όσο αυξάνονται και φτάνει προς το 1.96 της κανονικής κατανομής

Γιατί? Γιατί η κατανομή Gauss «ακουμπά» τον άξονα  $x$  πιο νωρίς από όλες τις κατανομές Student, συνεπώς περιλαμβάνει γρηγορότερα την πιθανότητα π.χ. 95%. Η κατανομή Student είναι πιο πεππλατυσμένη γιατί είναι πιο αβέβαιη

Ακόμη μια κατανομή που είναι χρήσιμη



**“Can you keep a secret? I’ve been teaching this stuff for 15 years and I still don’t understand it.”**

Κατανομή F

Τι είναι η κατανομή F?

Είναι η κατανομή συχνότητας ενός λόγου  $F = \frac{s_1^2}{s_2^2}$

Συνδέεται με την κατανομή  $\chi^2$  (άλλη φορά)

Εξαρτάται από δυο βαθμούς ελευθερίας  $\nu_1$  και  $\nu_2$  και είναι μια συνεχής ασύμμετρη κατανομή.

Το κυριότερο είναι ότι συνδέεται με το λόγο των αποκλίσεων δύο κατανομών

---


- Και τι μας νοιάζει αυτό άραγε?



Είναι πολύ σημαντικό για να συγκρίνουμε δύο κατανομές!!!!

Αν έχουν διαφορετικές αποκλίσεις τότε πρέπει να κάνουμε άλλες διαδικασίες απ' ότι αν έχουν κοινή απόκλιση


Ακόμα και αν δύο διαδικασίες (πειράματα) έχουν ίσο αριθμητικό μέσο όρο αυτό μπορεί να μην λέει και πολλά



Είναι πολύ σημαντικό για να συγκρίνουμε δύο κατανομές!!!!

Αν έχουν διαφορετικές αποκλίσεις τότε πρέπει να κάνουμε άλλες διαδικασίες απ' ότι αν έχουν κοινή απόκλιση


Ακόμα και αν δύο διαδικασίες (πειράματα) έχουν ίσο αριθμητικό μέσο όρο αυτό μπορεί να μην λέει και πολλά **αν έχουν διαφορετική διασπορά**



Είναι σημαντικό να συγκρίνουμε και τη διασπορά και γι αυτό θα χρησιμοποιήσουμε στη συνέχεια την κατανομή F

Γενική περίπτωση

$$F = \frac{\frac{s_1^2}{\sigma_1^2}}{\frac{s_2^2}{\sigma_2^2}}$$



Κατανομή 1 με πληθυσμιακή απόκλιση  $\sigma_1$  από την οποία παίρνουμε  $n_1$  δείγματα. Όταν υπολογίζουμε την δειγματική τυπική απόκλιση το αποτέλεσμα είναι  $s_1$

Κατανομή 2 τα ίδια με την 1 πληθυσμιακή απόκλιση  $\sigma_2$   $n_2$  δείγματα, δειγματική τυπική απόκλιση  $s_2$

Ακόμα και αν έχουν τον ίδιο μέσο όρο, δεν μπορούμε να πούμε ότι οι δυο κατανομές είναι ίδιες αν δεν έχουν και ίδια τυπική απόκλιση. Τα λέω καλά?

Δηλαδή? Δηλαδή, στην περίπτωση της μεγαλύτερης τυπικής απόκλισης δεν έχουμε αρκετή ακρίβεια όσο στην άλλη κατανομή

Φυσικά οι δύο κατανομές θα μπορούσαν να έχουν διαφορετικούς μέσους όρους

Αυτή την απορία θα τη λύσει η κατανομή F

Στην παραπάνω εξίσωση συνήθως εξετάζουμε μια κατανομή δηλαδή  $\sigma_1 = \sigma_2$ , π.χ. θέλουμε να δούμε αν από το ίδιο πείραμα ο αναλυτής 1 προσδιορίζει με την ίδια επαναληψιμότητα με τον αναλυτή 2. Η εξίσωση παίρνει μια πιο ειδική μορφή

$$F = \frac{s_1^2}{s_2^2}$$

Αυτή την μορφή συναντάμε συνήθως και θα ασχοληθούμε

# Ποιες είναι οι παραδοχές για να έχω κατανομή F?

- Και οι δύο συγκρινόμενες κατανομές είναι κανονικές
- Και οι δύο πληθυσμοί είναι ανεξάρτητοι
- Λεπτομέρεια Η μεγαλύτερη απόκλιση ΠΑΝΤΑ βρίσκεται στον παρονομαστή – θα δούμε ότι η κατανομή είναι πάντα κυρτή προς την δεξιά πλευρά The larger sample variance always goes in the numerator to make the right-tailed test, and the right-tailed tests are always easy to calculate.

Η εξίσωση της κατανομής πιθανότητας της κατανομής F είναι

$$f_{n,m}(x) = \frac{\Gamma\left(\frac{n+m}{2}\right) n^{n/2} m^{m/2}}{\Gamma\left(\frac{n}{2}\right) \Gamma\left(\frac{m}{2}\right)} \frac{x^{n/2-1}}{(m+nx)^{(n+m)/2}}$$

Παρατηρούμε ότι εξαρτάται από τους βαθμούς ελευθερίας  $m$  και  $n$

Να τονίσω πάλι ότι πρόκειται για σύγκριση δύο κατανομών με  $s_1^2$  και  $s_2^2$

Ο μέσος όρος είναι  $\mu = \frac{m}{m-2}$

Η τυπική απόκλιση είναι  $\sigma^2 = \frac{2m^2(m+n-2)}{n(m-2)^2(m-4)}$


Να τονίσω πάλι ότι πρόκειται για σύγκριση δύο δειγματοληψιών – κάθε μια έχει τους δικούς της βαθμούς ελευθερίας π.χ. στην πρώτη μπορεί κάποιος να έχει πάρει 5 δείγματα και στην δεύτερη 7. Οι βαθμοί ελευθερίας  $(v-1)$  θα είναι  $5-1=4$  (δύσκολο μαθηματικό τερτίπι :P ) για την πρώτη κατανομή και  $7-1=6$  για την δεύτερη.

Η κατανομή F έχει ένα περίεργο τρόπο για να βρίσκουμε το εμβαδό από την πυκνότητα πιθανότητας της κατανομής

Εμβαδό που δείχνει την πιθανότητα να συναντήσουμε τις αληθείς τιμές



Υπενθυμίζω με σχήμα για να μην φαίνεται κινέζικο



πυκνότητα πιθανότητας της κατανομής

F - Distribution ( $\alpha = 0.01$  in the Right Tail)

Ξεχωριστοί πίνακες για κάθε βαθμό σημαντικότητας εδώ 0.01

df <sub>2</sub>		df <sub>1</sub> Numerator Degrees of Freedom								
		1	2	3	4	5	6	7	8	9
1	4052.2	4999.5	5403.4	5624.6	5763.6	5859.0	5928.4	5981.1	6022.5	
2	98.503	99.000	99.166	99.249	99.299	99.333	99.356	99.374	99.388	
3	34.116	30.817	29.457	28.710	28.237	27.911	27.672	27.489	27.345	
4	21.198	18.000	16.694	15.977	15.522	15.207	14.976	14.799	14.659	
5	16.258	13.274	12.060	11.392	10.967	10.672	10.456	10.289	10.158	
6	13.745	10.925	9.7795	9.1483	8.7459	8.4661	8.2600	8.1017	7.9761	
7	12.246	9.5466	8.4513	7.8466	7.4604	7.1914	6.9928	6.8400	6.7188	
8	11.259	8.6491	7.5910	7.0061	6.6318	6.3707	6.1776	6.0289	5.9106	
9	10.561	8.0215	6.9919	6.4221	6.0569	5.8018	5.6129	5.4671	5.3511	
10	10.044	7.5594	6.5523	5.9943	5.6363	5.3858	5.2001	5.0567	4.9424	
11	9.6460	7.2057	6.2167	5.6683	5.3160	5.0692	4.8861	4.7445	4.6315	
12	9.3302	6.9266	5.9525	5.4120	5.0643	4.8206	4.6395	4.4994	4.3875	
13	9.0738	6.7010	5.7394	5.2053	4.8616	4.6204	4.4410	4.3021	4.1911	
14	8.8616	6.5149	5.5639	5.0354	4.6950	4.4558	4.2779	4.1399	4.0297	
15	8.6831	6.3589	5.4170	4.8932	4.5556	4.3183	4.1415	4.0045	3.8948	
16	8.5310	6.2262	5.2922	4.7726	4.4374	4.2016	4.0259	3.8896	3.7804	
17	8.3997	6.1121	5.1850	4.6690	4.3359	4.1015	3.9267	3.7910	3.6822	
18	8.2854	6.0129	5.0919	4.5790	4.2479	4.0146	3.8406	3.7054	3.5971	
19	8.1849	5.9259	5.0103	4.5003	4.1708	3.9386	3.7653	3.6305	3.5225	
20	8.0960	5.8489	4.9382	4.4307	4.1027	3.8714	3.6987	3.5644	3.4567	
21	8.0166	5.7804	4.8740	4.3688	4.0421	3.8117	3.6396	3.5056	3.3981	
22	7.9454	5.7190	4.8166	4.3134	3.9880	3.7583	3.5867	3.4530	3.3458	
23	7.8811	5.6637	4.7649	4.2636	3.9392	3.7102	3.5390	3.4057	3.2986	
24	7.8229	5.6136	4.7181	4.2184	3.8951	3.6667	3.4959	3.3629	3.2560	
25	7.7698	5.5680	4.6755	4.1774	3.8550	3.6272	3.4568	3.3239	3.2172	

Δύο σειρές βαθμών ελευθερίας

Μικρός αριθμός βαθμών ελευθερίας

Μεγάλος αριθμός βαθμών ελευθερίας

**ΠΡΩΤΗ ΣΕΛΙΔΑ**

F - Distribution ( $\alpha = 0.01$  in the Right Tail)

Ξεχωριστοί πίνακες για κάθε βαθμό σημαντικότητας εδώ 0.01

		Numerator Degrees of Freedom									
df <sub>2</sub> \ df <sub>1</sub>		10	12	15	20	24	30	40	60	120	∞
Denominator Degrees of Freedom	1	6055.8	6106.3	6157.3	6208.7	6234.6	6260.6	6286.8	6313.0	6339.4	6365.9
	2	99.399	99.416	99.433	99.449	99.458	99.466	99.474	99.482	99.491	99.499
	3	27.229	27.052	26.872	26.690	26.598	26.505	26.411	26.316	26.221	26.125
	4	14.546	14.374	14.198	14.020	13.929	13.838	13.745	13.652	13.558	13.463
	5	10.051	9.8883	9.7222	9.5526	9.4665	9.3793	9.2912	9.2020	9.1118	9.0204
	6	7.8741	7.7183	7.5590	7.3958	7.3127	7.2285	7.1432	7.0567	6.9690	6.8800
	7	6.6201	6.4691	6.3143	6.1554	6.0743	5.9920	5.9084	5.8236	5.7373	5.6495
	8	5.8143	5.6667	5.5151	5.3591	5.2793	5.1981	5.1156	5.0316	4.9461	4.8588
	9	5.2565	5.1114	4.9621	4.8080	4.7290	4.6486	4.5666	4.4831	4.3978	4.3105
	10	4.8491	4.7059	4.5581	4.4054	4.3269	4.2469	4.1653	4.0819	3.9965	3.9090
	11	4.5393	4.3974	4.2509	4.0990	4.0209	3.9411	3.8596	3.7761	3.6904	3.6024
	12	4.2961	4.1553	4.0096	3.8584	3.7805	3.7008	3.6192	3.5355	3.4494	3.3608
	13	4.1003	3.9603	3.8154	3.6646	3.5868	3.5070	3.4253	3.3413	3.2548	3.1654
	14	3.9394	3.8001	3.6557	3.5052	3.4274	3.3476	3.2656	3.1813	3.0942	3.0040
	15	3.8049	3.6662	3.5222	3.3719	3.2940	3.2141	3.1319	3.0471	2.9595	2.8684
	16	3.6909	3.5527	3.4089	3.2587	3.1808	3.1007	3.0182	2.9330	2.8447	2.7528
	17	3.5931	3.4552	3.3117	3.1615	3.0835	3.0032	2.9205	2.8348	2.7459	2.6530
	18	3.5082	3.3706	3.2273	3.0771	2.9990	2.9185	2.8354	2.7493	2.6597	2.5660
	19	3.4338	3.2965	3.1533	3.0031	2.9249	2.8442	2.7608	2.6742	2.5839	2.4893
	20	3.3682	3.2311	3.0880	2.9377	2.8594	2.7785	2.6947	2.6077	2.5168	2.4212
	21	3.3098	3.1730	3.0300	2.8796	2.8010	2.7200	2.6359	2.5484	2.4568	2.3603
	22	3.2576	3.1209	2.9779	2.8274	2.7488	2.6675	2.5831	2.4951	2.4029	2.3055
	23	3.2106	3.0740	2.9311	2.7805	2.7017	2.6202	2.5355	2.4471	2.3542	2.2558
	24	3.1681	3.0316	2.8887	2.7380	2.6591	2.5773	2.4923	2.4035	2.3100	2.2107
	25	3.1294	2.9931	2.8502	2.6993	2.6203	2.5383	2.4530	2.3637	2.2696	2.1694

Δύο σειρές βαθμών ελευθερίας

Μεγάλος αριθμός βαθμών ελευθερίας

Μικρός αριθμός βαθμών ελευθερίας

**ΔΕΥΤΕΡΗ ΣΕΛΙΔΑ**

F - Distribution ( $\alpha = 0.025$  in the Right Tail)

Ξεχωριστοί πίνακες για κάθε βαθμό σημαντικότητας

εδώ 0.025

Δύο σειρές βαθμών ελευθερίας

Μικρός αριθμός βαθμών ελευθερίας

Μεγάλος αριθμός βαθμών ελευθερίας

df <sub>2</sub> \ df <sub>1</sub>		Numerator Degrees of Freedom								
		1	2	3	4	5	6	7	8	9
1	647.79	799.50	864.16	899.58	921.85	937.11	948.22	956.66	963.28	
2	38.506	39.000	39.165	39.248	39.298	39.331	39.335	39.373	39.387	
3	17.443	16.044	15.439	15.101	14.885	14.735	14.624	14.540	14.473	
4	12.218	10.649	9.9792	9.6045	9.3645	9.1973	9.0741	8.9796	8.9047	
5	10.007	8.4336	7.7636	7.3879	7.1464	6.9777	6.8531	6.7572	6.6811	
6	8.8131	7.2599	6.5988	6.2272	5.9876	5.8198	5.6955	5.5996	5.5234	
7	8.0727	6.5415	5.8898	5.5226	5.2852	5.1186	4.9949	4.8993	4.8232	
8	7.5709	6.0595	5.4160	5.0526	4.8173	4.6517	4.5286	4.4333	4.3572	
9	7.2093	5.7147	5.0781	4.7181	4.4844	4.3197	4.1970	4.1020	4.0260	
10	6.9367	5.4564	4.8256	4.4683	4.2361	4.0721	3.9498	3.8549	3.7790	
11	6.7241	5.2559	4.6300	4.2751	4.0440	3.8807	3.7586	3.6638	3.5879	
12	6.5538	5.0959	4.4742	4.1212	3.8911	3.7283	3.6065	3.5118	3.4358	
13	6.4143	4.9653	4.3472	3.9959	3.7667	3.6043	3.4827	3.3880	3.3120	
14	6.2979	4.8567	4.2417	3.8919	3.6634	3.5014	3.3799	3.2853	3.2093	
15	6.1995	4.7650	4.1528	3.8043	3.5764	3.4147	3.2934	3.1987	3.1227	
16	6.1151	4.6867	4.0768	3.7294	3.5021	3.3406	3.2194	3.1248	3.0488	
17	6.0420	4.6189	4.0112	3.6648	3.4379	3.2767	3.1556	3.0610	2.9849	
18	5.9781	4.5597	3.9539	3.6083	3.3820	3.2209	3.0999	3.0053	2.9291	
19	5.9216	4.5075	3.9034	3.5587	3.3327	3.1718	3.0509	2.9563	2.8801	
20	5.8715	4.4613	3.8587	3.5147	3.2891	3.1283	3.0074	2.9128	2.8365	
21	5.8266	4.4199	3.8188	3.4754	3.2501	3.0895	2.9686	2.8740	2.7977	
22	5.7863	4.3828	3.7829	3.4401	3.2151	3.0546	2.9338	2.8392	2.7628	
23	5.7498	4.3492	3.7505	3.4083	3.1835	3.0232	2.9023	2.8077	2.7313	
24	5.7166	4.3187	3.7211	3.3794	3.1548	2.9946	2.8738	2.7791	2.7027	
25	5.6864	4.2909	3.6943	3.3530	3.1287	2.9685	2.8478	2.7531	2.6766	
26	5.6586	4.2655	3.6697	3.3289	3.1048	2.9447	2.8240	2.7293	2.6528	




# ΤΡΙΤΗ ΣΕΛΙΔΑ

(ουσιαστικά επανάληψη των δύο πρώτων σελίδων για άλλα επίπεδα σημαντικότητας)



Η κατανομή F δεν έχει σταθερό σχήμα, αλλά το σχήμα εξαρτάται από του βαθμούς ελευθερίας των δύο κατανομών

Για να το δουμε




DF= degrees of freedom – βαθμοί ελευθερίας



Η κατανομή δεν έχει κάποιο σημείο καμπής όπως οι άλλες που έχουμε δει  
Οι βαθμοί ελευθερίας στον παρονομαστή δεν παίζουν πολύ σημαντικό ρόλο



Η κατανομή έχει σημείο καμπής  
Οι βαθμοί ελευθερίας στον αριθμητή καθορίζουν το σχήμα στον παρονομαστή το πλάτος



Το σημείο καμπής εξαρτάται από το Df1 και το πλάτος από το DF2.  
Για μεγάλο αριθμό δειγμάτων η κατανομή F τείνει προς την κανονική κατανομή

Γιατί κατανομή F?

Προς τιμή του Fisher



Αλλά το όνομα έδωσε  
ο George W. Snedecor

