

# Ανάλυση διακύμανσης (Μονοδιάστατη)

One-Way ANOVA

# Ανάλυση διακύμανσης

---

- ▶ Η μονοδιάστατη ανάλυση διακύμανσης εξετάζει εάν δύο ή περισσότεροι ανεξάρτητοι πληθυσμοί έχουν τον ίδιο η διαφορετικό μέσο όρο.
- ▶ Στην περίπτωση που έχουμε μόνο δύο ανεξάρτητους πληθυσμούς μπορούμε να διερευνήσουμε το ίδιο ερώτημα με το ανάλογο t-test
- ▶ Γιατί δεν μπορούμε να κάνουμε πολλαπλά t-test??



# Ανάλυση διακύμανσης

---

- ▶ Η εξαρτημένη μεταβλητή (*dependent ή response variable*) είναι η μεταβλητή που συγκρίνουμε
- ▶ Η ανεξάρτητη μεταβλητή (*factor ή grouping variable*) είναι η μεταβλητή που ομαδοποιεί τα δείγματα στους διαφορετικούς πληθυσμούς που συγκρίνουμε
  - ▶ Η ανεξάρτητη μεταβλητή έχει  $k$  επίπεδα (όπου  $k \geq 2$ )
- ▶ Η ανάλυση διακύμανσης αναφέρεται ως μονοδιάστατη (*one way ANOVA*) γιατί έχουμε μία μόνο ανεξάρτητη μεταβλητή.



# Προϋποθέσεις μονοδιάστατης ανάλυσης διακύμανσης

---

- ▶ Τα δεδομένα είναι αντιπροσωπευτικά
- ▶ Ομοιογένεια διακυμάνσεων
- ▶ Ακολουθούν την κανονική κατανομή



# Μηδενική υπόθεση

---

- ▶ Η *μηδενική υπόθεση* στη μονοδιάστατη ανάλυση διακύμανσης είναι ότι όλοι οι μέσοι όροι είναι ίσοι

$$H_0 : \mu_1 = \mu_2 = \mu_3 = \dots = \mu_k$$

- ▶ Η *εναλλακτική υπόθεση* είναι ότι τουλάχιστον ένας μέσος όρος διαφέρει σημαντικά.



# Παράδειγμα

---

- ▶ Έχει παρατηρηθεί ότι οι μαθητές στην αίθουσα διδασκαλίας μπορεί να διακριθούν ανάλογα με το που κάθονται (είτε στις μπροστά θέσεις, είτε στις μεσαίες, είτε στις πίσω)
- ▶ Έχει παρατηρηθεί ότι οι μαθητές των τελευταίων εδράνων είναι συνήθως πιο ανήσυχοι, κάνουν περισσότερο βαβούρα, παίζουν με τα κινητά τους, κ.ο.κ.
- ▶ Το ερώτημα λοιπόν είναι **εάν το που κάθεται ο μαθητής επηρεάζει τις επιδόσεις του**



# Ανάλυση διακύμανσης

---

Η ανάλυση διακύμανσης δεν εξετάζει εάν ο ένας μέσος όρος είναι μικρότερος από τον άλλο, αλλά εάν είναι ίσοι ή διαφέρουν.



## Παράδειγμα συνέχεια

---

- ▶ Έστω ότι πήραμε τυχαίο δείγμα από μαθητές ανάλογα με το που κάθονται
- ▶ Καταγράψαμε τις επιδόσεις τους σε μια δοκιμασία κατανόησης του μαθήματος και έχουμε σκορ:
  - ▶ Πρώτα: 82, 83, 97, 93, 55, 67, 53
  - ▶ Μέσσια: 83, 78, 68, 61, 77, 54, 69, 51, 63
  - ▶ Τελευταία: 38, 59, 55, 66, 45, 52, 52, 61





# Περιγραφικά στατιστικά δείγματος

---

	Πρώτα	Μεσαία	Τελευταία
Μέγεθος δείγματος			
Μέσος όρος			
Τυπική απόκλιση			
Διακύμανση			



# Περιγραφικά στατιστικά δείγματος

---

	<b>Πρώτα</b>	<b>Μεσαία</b>	<b>Τελευταία</b>
<b>Μέγεθος δείγματος</b>	<b>7</b>	<b>9</b>	<b>8</b>
<b>Μέσος όρος</b>	<b>75.71</b>	<b>67.11</b>	<b>53.50</b>
<b>Τυπική απόκλιση</b>	<b>17.63</b>	<b>10.95</b>	<b>8.96</b>
<b>Διακύμανση</b>	<b>310.90</b>	<b>119.86</b>	<b>80.29</b>



# Διακύμανση

---

- ▶ Είναι όλες οι τιμές ίδιες?
  - ▶ Όχι άρα υπάρχει διακύμανση στα δεδομένα
  - ▶ Η διακύμανση μπορεί να μετρηθεί για το σύνολο των δεδομένων
  - ▶ Ως  $SS(\text{Total})$  αναφερόμαστε στο άθροισμα των τετραγώνων των αποκλίσεων από το μέσο όρο
  - ▶ Το άθροισμα αυτό είναι ο αριθμητής στον υπολογισμό της διακύμανσης



# Διακύμανση

---

- ▶ Είναι οι τιμές του κάθε πληθυσμού ίδιες?
  - ▶ Όχι υπάρχει διακύμανση των παρατηρήσεων και σε κάθε επιμέρους πληθυσμό
  - ▶ Ως  $SS(\text{Within})$  αναφερόμαστε στο μέρος του αθροίσματος των τετραγώνων που οφείλεται ακριβώς στη διακύμανση μεταξύ των ατόμων του κάθε πληθυσμού



# Διακύμανση

---

- ▶ Είναι η διακύμανση των επιμέρους πληθυσμών ίδια με τη συνολική διακύμανση?
  - ▶ Υπάρχει μέρος της διακύμανσης που παρατηρείται **εντός** του κάθε επιμέρους πληθυσμού και υπάρχει επιπλέον διακύμανση **μεταξύ** των πληθυσμών
  - ▶ Με τον όρο  $SS(\text{Between})$  αναφερόμαστε στο μέρος του αθροίσματος των τετραγώνων που οφείλεται ακριβώς στη διακύμανση μεταξύ των πληθυσμών



# Ανάλυση διακύμανσης

---

- ▶ Άρα υπάρχουν δύο πηγές διακύμανσης
  - ▶ Η διακύμανση εντός του κάθε πληθυσμού,  $SS(W)$ , ή αλλιώς η φυσική διακύμανση των ατόμων ή η διακύμανση που οφείλεται στο τρόπο εκτίμησης κ.ο.κ. (άρα διακύμανση που δεν οφείλεται στον παράγοντα ενδιαφέροντος)
  - ▶ Η διακύμανση μεταξύ των πληθυσμών,  $SS(B)$ , που είναι η διακύμανση που οφείλεται στη δράση του παράγοντα που μελετάμε (της ανεξάρτητης μεταβλητής)



# Ανάλυση διακύμανσης

---

- ▶ Ο βασικός πίνακας της ανάλυσης διακύμανσης

Πηγή	SS	df	MS	F	p
Εντός					
Μεταξύ					
Συνολικά					



# Συνολικά

---

- ▶ Ο μέσος όρος όλων των δεδομένων
- ▶ Ο μέσος όρος αυτός υπολογίζεται εάν αγνοήσουμε τον παράγοντα ενδιαφέροντος
- ▶ Στο παράδειγμά μας είναι 65.08





# Διακύμανση μεταξύ των πληθυσμών

---

## ▶ SS(Between)

- ▶ Η διακύμανση μεταξύ του μέσου όρου του κάθε επιμέρους πληθυσμού και του συνολικού μέσου όρου
- ▶ Η διαφορές αυτές είναι σταθμισμένες με το μέγεθος δείγματος κάθε πληθυσμού

$$SS(B) = \sum_{i=1}^k n_i (\bar{x}_i - \bar{\bar{x}})^2$$



## Διακύμανση μεταξύ των πληθυσμών (παράδειγμα)

---

$$SS(B)=1902$$

$$SS(B) = 7(75.71 - 65.08)^2 + 9(67.11 - 65.08)^2 + 8(53.50 - 65.08)^2$$



# Διακύμανση εντός των πληθυσμών

---

## ▶ **SS(Within)**

- ▶ Είναι το άθροισμα των σταθμισμένων διακυμάνσεων κάθε επιμέρους πληθυσμού
- ▶ Η στάθμιση γίνεται με τους βαθμούς ελευθερίας (df)
- ▶ Οι βαθμοί ελευθερίας (df) για κάθε επιμέρους πληθυσμό είναι το μέγεθος δείγματος (κάθε πληθυσμού) μείον ένα



# Διακύμανση εντός των πληθυσμών

---

$$SS(W) = \sum_{i=1}^k df_i s_i^2$$

$$SS(W) = df_1 s_1^2 + df_2 s_2^2 + \cdots + df_k s_k^2$$

- ▶ Στο παράδειγμά μας  $SS(W_{\text{within}})$  3386



# Ανάλυση διακύμανσης

---

- ▶ Ο βασικός πίνακας της ανάλυσης διακύμανσης διαμορφώνεται ως εξής

Πηγή	SS	df	MS	F	p
Μεταξύ	1902				
Εντός	3386				
Συνολικά	5288				



# Βαθμοί ελευθερίας (df)

---

- ▶ Ένας βαθμός ελευθερίας αντιστοιχεί σε κάθε τιμή που μπορεί να ποικίλει μέχρις ότου οι υπόλοιπες τιμές γίνουν υποχρεωτικές
- ▶ Συχνά οι βαθμοί ελευθερίας υπολογίζονται ως το μέγεθος δείγματος μείον ένα



# Βαθμοί ελευθερίας

---

- ▶ Οι βαθμοί ελευθερίας για μεταξύ των πληθυσμών είναι ο αριθμός των ανεξάρτητων πληθυσμών που συγκρίνουμε μείον ένα
  - ▶ Στο παράδειγμα έχουμε 3 πληθυσμούς άρα  $df(B) = 2$
- ▶ Οι βαθμοί ελευθερίας εντός των πληθυσμών είναι το άθροισμα των βαθμών ελευθερίας των επιμέρους πληθυσμών (όπου για κάθε πληθυσμός είναι μέγεθος δείγματος μείον 1)
  - ▶  $df(W) = 6 + 8 + 7 = 21$
- ▶ Οι βαθμοί ελευθερίας συνολικά είναι το συνολικό μέγεθος δείγματος μείον ένα
  - ▶  $df(\text{Total}) = 24 - 1 = 23$



# Ανάλυση διακύμανσης

---

- ▶ Ο βασικός πίνακας της ανάλυσης διακύμανσης διαμορφώνεται ως εξής

Πηγή	SS	df	MS	F	p
Μεταξύ	1902	2			
Εντός	3386	21			
Συνολικά	5288	23			

---





# Σταθμισμένο άθροισμα τετραγώνων

---

- ▶  $MS = SS / df$



# Παράδειγμά μας

---

- ▶  $MS(B) = 1902 / 2 = 951.0$
- ▶  $MS(W) = 3386 / 21 = 161.2$
- ▶  $MS(T) = 5288 / 23 = 229.9$ 
  - ▶  $MS(\text{Total})$  **δεν** είναι το άθροισμα του  $MS(\text{Between})$  και του  $MS(\text{Within})$ .



# Ανάλυση διακύμανσης

---

- ▶ Ο βασικός πίνακας της ανάλυσης διακύμανσης διαμορφώνεται ως εξής

Πηγή	SS	df	MS	F	p
Μεταξύ	1902	2	951.0		
Εντός	3386	21	161.2		
Συνολικά	5288	23	229.9		

---



# Ανάλυση διακύμανσης

---

- ▶ Η ανάλυση διακύμανσης στηρίζεται στον επιμερισμός της διακύμανσης εντός του κάθε πληθυσμού και μεταξύ των πληθυσμών
- ▶ F test statistic (αντίστοιχο του t)
  - ▶ Το F είναι ο λόγος των δύο σταθμισμένων αθροισμάτων τετραγώνων
  - ▶  $F = MS(B) / MS(W)$
- ▶ Για το παράδειγμά μας,  $F = 951.0 / 161.2 = 5.9$



# Ανάλυση διακύμανσης

---

- ▶ Ο βασικός πίνακας της ανάλυσης διακύμανσης διαμορφώνεται ως εξής

Πηγή	SS	df	MS	F	p
Μεταξύ	1902	2	951.0	5.9	
Εντός	3386	21	161.2		
Συνολικά	5288	23	229.9		

---



# Ανάλυση διακύμανσης

---

- ▶ Το ερώτημα λοιπόν είναι **πόσο πιθανό να παρατηρηθεί αυτή η τιμή F εάν οι μέσοι όροι ήταν ίσοι?**
- ▶ Για το λόγο αυτό χρησιμοποιούμε την **κατανομή F** με βαθμούς ελευθερίας τόσο για το εντός όσο και για το μεταξύ (άρα στο παράδειγμά μας df (Between) 2 & df(Within) 21)
- ▶  $P(F_{2,21} > 5.9) = 0.009$



# Ανάλυση διακύμανσης

---

- ▶ Ο βασικός πίνακας της ανάλυσης διακύμανσης διαμορφώνεται ως εξής

Πηγή	SS	df	MS	F	p
Μεταξύ	1902	2	951.0	5.9	0.009
Εντός	3386	21	161.2		
Συνολικά	5288	23	229.9		

---



## Συμπέρασμα

---

- ▶ Αφού  $p = 0.009$ , (άρα  $p < 0.05$ ), μπορούμε να απορρίψουμε τη μηδενική υπόθεση.
- ▶ Άρα δεν μπορούμε να ισχυριστούμε ότι όλοι οι μέσοι όροι είναι ίσοι





# Συμπέρασμα

---

- ▶ Τα στοιχεία επαρκούν για τον ισχυρισμό ότι υπάρχει διαφορά στο μέσο όρο των επιδόσεων των φοιτητών αναλόγως με το που κάθονται στην αίθουσα
- ▶ Το αποτέλεσμα της ANOVA δε μας λέει ποια είναι η διαφορά (μόνο ότι υπάρχει)
- ▶ Για να περιγράψουμε τη διαφορά χρειαζόμαστε άλλα tests

