

Διάστημα εμπιστοσύνης της $\mu_1 - \mu_2$

δύο ανεξάρτητων τ.μ. X_1 και X_2

Μέσες τιμές: μ_1 και μ_2

Διασπορές: σ_1^2 και σ_2^2

Δείγμα μεγέθους n_1, n_2 από τον πληθυσμό της X_1, X_2

Δειγματικές μέσες τιμές: \bar{x}_1 και \bar{x}_2

Δειγματικές διασπορές: s_1^2 και s_2^2

Θέλουμε να εκτιμήσουμε τη διαφορά των μέσων τιμών μ_1 και μ_2

Σημειακή εκτίμηση της διαφοράς $\mu_1 - \mu_2$: $\bar{x}_1 - \bar{x}_2$

Γνωστές διασπορές σ_1^2 και σ_2^2

Υποθέτουμε

είτε $n_1 > 30$ και $n_2 > 30$

ή X_1 και X_2 ακολουθούν κανονική κατανομή

→ εκτιμήτρια $\bar{x}_1 - \bar{x}_2$ ακολουθεί κανονική κατανομή

μέση τιμή $\mu_{\bar{x}_1 - \bar{x}_2} \equiv E[\bar{x}_1 - \bar{x}_2] = \mu_1 - \mu_2$

διασπορά $\sigma_{\bar{x}_1 - \bar{x}_2}^2 \equiv \text{Var}[\bar{x}_1 - \bar{x}_2] = \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$

Αν X_1 και X_2 ομοσκεδαστικές ($\sigma_1^2 = \sigma_2^2 = \sigma^2$)

$$\sigma_{\bar{x}_1 - \bar{x}_2}^2 = \sigma^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)$$

Εκτιμήτρια \bar{x}	\Rightarrow	$\bar{x}_1 - \bar{x}_2$
Μέση τιμή εκτιμήτριας μ	\Rightarrow	$\mu_1 - \mu_2$
Διασπορά εκτιμήτριας $\frac{\sigma^2}{n}$	\Rightarrow	$\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$

$(1-\alpha)\%$ δ.ε. της $\mu_1 - \mu_2$:

$$(\bar{x}_1 - \bar{x}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$$

Ερμηνεία του δ.ε.:

Αν **περιέχει** το 0 \rightarrow μ_1 και μ_2 **δε** διαφέρουν

(για το επίπεδο εμπιστοσύνης που χρησιμοποιήσαμε και με βάση τα συγκεκριμένα δεδομένα)

Αν είναι **θετικό** \rightarrow η τ.μ. X_1 είναι κατά μέσο όρο μεγαλύτερη από τη X_2 κατά ένα ποσό που κυμαίνεται στα όρια του διαστήματος που εκτιμήσαμε

[αντίστοιχα για αρνητικό δ.ε.]

Παράδειγμα

Μελετήσαμε το χρόνο ανάφλεξης σε δύο δείγματα από δύο υλικά ταπετσαρίας A και B μεγέθους $n_1=30$ και $n_2=20$.

Είναι ο χρόνος ανάφλεξης του υλικού A κατά μέσο όρο διαφορετικός από αυτόν του υλικού B;

Θεωρούμε πως η διασπορά είναι κοινή και γνωστή: $\sigma^2 = 4s^2$

Συνθήκες:

Είναι τα 2 δείγματα μεγάλα;

Ακολουθεί ο χρόνος ανάφλεξης για τα δύο υλικά κανονική κατανομή;

Υλικό 1		Υλικό 2
Φύλλο	Μίσχος	Φύλλο
5	1.	8
3	2.	38
86440	3.	44445
985441	4.	566688
99500	5.	069
8732	6.	07
6533	7.	5
64	8.	
40	9.	

Δειγματικές μέσες τιμές A: $\bar{x}_1 = 5.59\text{s}$ B: $\bar{x}_2 = 4.46\text{s}$

$$\bar{x}_1 - \bar{x}_2 = 1.13\text{s}$$

$$z_{0.025} = 1.96 \quad \text{και} \quad \sigma_1^2 = \sigma_2^2 = \sigma^2 = 4\text{s}^2$$

95% δ.ε. της $\mu_1 - \mu_2$

$$(\bar{x}_1 - \bar{x}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$$

$$1.13 \pm 1.96 \cdot \sqrt{4 \cdot \left(\frac{1}{30} + \frac{1}{20} \right)} = 1.13 \pm 1.132 \quad \mapsto \quad (-0.002, 2.262)$$

Υπάρχει σημαντική διαφορά μεταξύ των δύο υλικών;

Άγνωστες διασπορές, μεγάλο μέγεθος δείγματος

Όταν το δείγμα είναι μεγάλο:

$$s_1^2 \rightarrow \sigma_1^2 \quad \text{και} \quad s_2^2 \rightarrow \sigma_2^2$$

$$(1-\alpha)\% \text{ δ.ε. της } \mu_1 - \mu_2 : \quad (\bar{x}_1 - \bar{x}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$$

Άγνωστες διασπορές, μικρό μέγεθος δείγματος

Περίπτωση 1

Οι κατανομές των X_1 και X_2 δε είναι κανονικές \rightarrow
δε μπορούμε να προσδιορίσουμε την κατανομή της διαφοράς $\bar{x}_1 - \bar{x}_2$

για να εκτιμήσουμε το δ.ε. \rightarrow μη-παραμετρική προσέγγιση.

Περίπτωση 2

Υποθέτουμε

1. Οι κατανομές των X_1 και X_2 είναι κανονικές
2. X_1 και X_2 ομοσκεδαστικές ($\sigma_1^2 = \sigma_2^2 = \sigma^2$)

Εκτίμηση της κοινής διασπορά σ^2
Δειγματική κοινή διασπορά :

$$s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$$

Εκτίμηση της διασποράς της $\bar{x}_1 - \bar{x}_2$

$$s_p^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)$$

Μετασχηματισμός

$$t \equiv \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{s_p \cdot \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t_{n_1 + n_2 - 2}$$

$(1-\alpha)\%$ δ.ε. της $\mu_1 - \mu_2$:

$$(\bar{x}_1 - \bar{x}_2) \pm t_{n_1 + n_2 - 2, \alpha/2} \cdot s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

Παράδειγμα

Άγνωστη διασπορά του χρόνου ανάφλεξης για τα δύο υλικά ταπετσαρίας.

Δειγματικές διασπορές: A: $s_1^2 = 4.12 \text{ s}^2$, B: $s_2^2 = 2.11 \text{ s}^2$

Δεχόμαστε ότι η διασπορά δε διαφέρει σημαντικά στα δύο υλικά.

Δεχόμαστε επίσης ότι ο χρόνος ανάφλεξης και για τα δύο υλικά ακολουθεί κανονική κατανομή.

Τα δείγματα είναι σχετικά μικρά $\rightarrow \bar{x}_1 - \bar{x}_2$ ακολουθεί κατανομή student

Δειγματική κοινή διασπορά: $s_p^2 = \frac{29 \cdot 4.12 + 19 \cdot 2.11}{48} = 3.324$ $s_p = 1.823$

Βαθμοί ελευθερίας: $n_1 + n_2 - 2 = 48$ $t_{48,0.025} = 2.01$

$$\bar{x}_1 - \bar{x}_2 = 1.13$$

Το 95% δ.ε. είναι

$$(\bar{x}_1 - \bar{x}_2) \pm t_{n_1+n_2-2, a/2} \cdot s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

$$1.13 \pm 2.01 \cdot 1.823 \sqrt{\frac{1}{30} + \frac{1}{20}} = 1.13 \pm 1.058 \quad \mapsto \quad (0.072, 2.188)$$

Παρατηρήσεις

Υπάρχει φανερή αντιστοιχία των περιπτώσεων για το δ.ε. της μέσης τιμής μ και το δ.ε. της διαφοράς δύο μέσων τιμών $\mu_1 - \mu_2$.

Για τη διαφορά μέσων τιμών υπάρχει ακόμα η περίπτωση των άνισων κι αγνώστων διασπορών σε συνδυασμό με μικρά δείγματα.

διασπορές των X_1, X_2	κατανομές των X_1, X_2	n_1, n_2	κατανομή της $\bar{x}_1 - \bar{x}_2$	δ.ε.της $\bar{x}_1 - \bar{x}_2$
γνωστές	κανονική		$z \equiv \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0,1)$	$(\bar{x}_1 - \bar{x}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$
γνωστές	μη κανονική	μεγάλα	$z \equiv \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0,1)$	$(\bar{x}_1 - \bar{x}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$
γνωστές	μη κανονική	μικρά	μη-παραμετρική	μη-παραμετρικό
άγνωστες άνισες ή ίσες		μεγάλα	$z \equiv \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \sim N(0,1)$	$(\bar{x}_1 - \bar{x}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$
άγνωστες και ίσες	κανονική	μικρά	$t \equiv \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{s_p \cdot \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t_{n_1+n_2-2}$	$(\bar{x}_1 - \bar{x}_2) \pm t_{n_1+n_2-2, \alpha/2} \cdot s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$
άγνωστες και ίσες	μη κανονική	μικρά	μη-παραμετρική	μη-παραμετρικό
άγνωστες και άνισες		μικρά	----	----

Διάστημα της διαφοράς δύο αναλογιών $p_1 - p_2$

Συγκρίνουμε δύο πληθυσμούς ως προς μια ιδιότητα

Μελετάμε τη διαφορά αναλογιών $p_1 - p_2$

m_1 είναι το πλήθος «επιτυχιών» στο δείγμα
μεγέθους n_1 από τον πρώτο πληθυσμό

$$\hat{p}_1 = \frac{m_1}{n_1}$$

m_2 είναι το πλήθος «επιτυχιών» στο δείγμα
μεγέθους n_2 από το δεύτερο πληθυσμό

$$\hat{p}_2 = \frac{m_2}{n_2}$$

Εκτίμηση της διαφοράς $p_1 - p_2$: $\hat{p}_1 - \hat{p}_2$

Για μεγάλα n_1 και n_2 \Rightarrow $\hat{p}_1 - \hat{p}_2$ ακολουθεί κανονική κατανομή

μέση τιμή $E[\hat{p}_1 - \hat{p}_2] = p_1 - p_2$ διασπορά $\text{Var}[\hat{p}_1 - \hat{p}_2] = \frac{p_1 \cdot (1 - p_1)}{n_1} + \frac{p_2 \cdot (1 - p_2)}{n_2}$

Μετασχηματισμός σε τυπική
κανονική κατανομή

$$z \equiv \frac{(\hat{p}_1 - \hat{p}_2) - (p_1 - p_2)}{\sqrt{\frac{p_1 \cdot (1 - p_1)}{n_1} + \frac{p_2 \cdot (1 - p_2)}{n_2}}} \sim N(0,1)$$

Αντικαθιστούμε

$$\hat{p}_1 \rightarrow p_1$$

$$\hat{p}_2 \rightarrow p_2$$

$(1-\alpha)\%$ δ.ε. της $p_1 - p_2$:

$$(\hat{p}_1 - \hat{p}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{\hat{p}_1 \cdot (1 - \hat{p}_1)}{n_1} + \frac{\hat{p}_2 \cdot (1 - \hat{p}_2)}{n_2}}$$

Παράδειγμα

Θέλουμε να εκτιμήσουμε αν υπάρχει διαφορά στο ποσοστό των μικρών διαμερισμάτων σε δύο περιοχές Α και Β.

Περιοχή Α: $m_1 = 48$ μικρά διαμερίσματα (με ένα ή δύο δωμάτια) σε $n_1 = 120$ διαμερίσματα

Περιοχή Β: $m_2 = 60$ μικρά διαμερίσματα σε $n_2 = 100$ διαμερίσματα

Περιοχή Α: Δειγματική αναλογία : $\hat{p}_1 = \frac{48}{120} = 0.4$

Περιοχή Β: Δειγματική αναλογία : $\hat{p}_2 = \frac{60}{100} = 0.6$

Σημειακή εκτίμηση της διαφοράς αναλογίας των μικρών διαμερισμάτων στις δύο περιοχές: $\hat{p}_1 - \hat{p}_2 = -0.2$ (το ποσοστό είναι -20%)

95% δ.ε. της $p_1 - p_2$: ($z_{\alpha/2} = 1.96$)

$$(\hat{p}_1 - \hat{p}_2) \pm z_{\alpha/2} \cdot \sqrt{\frac{\hat{p}_1 \cdot (1 - \hat{p}_1)}{n_1} + \frac{\hat{p}_2 \cdot (1 - \hat{p}_2)}{n_2}}$$

$$-0.2 \pm 1.96 \cdot \sqrt{\frac{0.4 \cdot (1 - 0.4)}{120} + \frac{0.6 \cdot (1 - 0.6)}{100}} = -0.2 \pm 0.13 \quad \mapsto \quad (-0.33, -0.07)$$

Το 95% δ.ε. **δεν περιέχει** το 0 \rightarrow με βάση αυτά τα δείγματα και σ' αυτό το επίπεδο εμπιστοσύνης συμπεραίνουμε ότι η αναλογία μικρών διαμερισμάτων είναι **από 0.07 ως 0.33 μικρότερη** στην περιοχή Α