

Ανάλυση διακύμανσης κατά ένα κριτήριο

One-Way Analysis of Variance

Είναι ευείνη η μεθοδολογία που ασχολείται με την εξέταση και τον προσδιορισμό των πηγών των αποκλίσεων που παρατηρούνται σε δειγματικά δεδομένα. Είναι η μέθοδος διαχωρισμού της επιρροής των διαφορετικών υποσυνόλων των παραμέτρων πάνω στις μετρήσεις. Με τον όρο "παράγοντες" συνήθως εννοούμε το αποτέλεσμα κάποιων επιδράσεων (treatments) σε μία μεταβλητή Y .

π.χ. Τι είναι η επίδραση και πως επηρεάζει ένα πείραμα;

Έστω $Y :=$ παραγωγή σταριού από κάποιο συγκεκριμένο κορράκι χωραφιού

Επίδραση := προσθήκη λιπάσματος στο κορράκι του χωραφιού κατά τη σπορά.

Ο ερευνητής εξάγει συμπεράσματα μελετώντας κορράκια χωραφιού που έχουν υποστεί την επίδραση και άλλα που δεν την έχουν υποστεί.

Πρόβλημα που απασχολεί τον ερευνητή: Η "επίδραση" δηλαδή η χρήση του λιπάσματος επιφέρει στατιστικά σημαντική βελτίωση της παραγωγής; ΝΑΙ ή ΟΧΙ;

<u>π.χ.</u>	Toyota	Datsun	Mazda	$Y :=$ μέση κατανάλωση βενζίνης σε Km/lt
$n_1=6$	27.1 25.5 27 26.9 27.7 27.3	$n_2=5$ 25.3 26.5 26.4 26.8 26.5	$n_3=4$ 23.1 24.3 23.4 24.2	

Δεδομένα: Μέση κατανάλωση βενζίνης τριών ειδών διαφορετικών αυτοκινήτων. Υπάρχει στατιστικά σημαντική διαφορά στη μέση κατανάλωση βενζίνης μεταξύ των τριών αυτών διαφορετικών αυτοκινήτων;

Βάζουμε οδηγούς να οδηγήσουν τα αυτοκίνητα σε μία διαδρομή (ίδια για όλα τα αυτοκίνητα) μήκους 300 km με σταθερή ταχύτητα 55 km/h. Ποιες είναι οι αιτίες που οδηγούν στη διακύμανση των αποτελεσμάτων;

Διαφορετικών κατασκευαστών αυτοκίνητα έχουν διαφορετική απόδοση λόγω διαφορετικής κατασκευής,

π.χ. Κατανάλωση MAZDA < κατανάλωση TOYOTA DATSUN

Μεταξύ αυτοκινήτων του ίδιου κατασκευαστή παρουσιάζονται αποκλίσεις. 6 αυτοκίνητα οδηγήθηκαν από 6 διαφορετικούς οδηγούς. Αυτοκίνητα με διαφορετικά λάστιχα (διαφορετική πίεση αέρα). Τελευταίο service σε διαφορετική χρονική στιγμή. Ενδεχομένως διαφορετικές καιρικές συνθήκες κάτω από τις οποίες έγινε το πείραμα. Άρα, τα δεδομένα περιέχουν ένα σχετικά αραιό πηχών διακύμανσης

Στόχος: Να καθοριστούν οι κύριες πηγές διακύμανσης και η ποσότητα της διακύμανσης που οφείλεται σε καθένα από τους διαφορετικούς λόγους που μας ενδιαφέρουν να εξετάσουμε. Η υπόλοιπη διακύμανση των δεδομένων θεωρείται από τον ερευνητή ότι οφείλεται σε τυχαίους παράγοντες και καλείται σφάλμα (error).

Στόχος: Μείωση στο ελάχιστο του λάθους ώστε η ποσότητα της διακύμανσης που οφείλεται στους λόγους που έχουμε καθορίσει να προσδιοριστούν όσον το δυνατόν ακριβέστερα.

Άρα, η ανάληψη διαυόρασης προσπαθεί να καθορίσει όλες τις πηγές διαυόρασης και το ποσό της διαυόρασης που μπορεί να αποδοθεί σε καθένα από τις πηγές αυτές.

Η πιο απλή περίπτωση ανάληψης διαυόρασης είναι η ανάληψη διαυόρασης κατά ένα κριτήριο (μία μόνο επίδραση). Έχουμε K ανεξάρτητα δείγματα από K πληθυσμούς. Υποθέτουμε ότι $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_K^2 = \sigma^2$. Ελέγχουμε την υπόθεση:

$$H_0: \mu_1 = \mu_2 = \dots = \mu_K$$

H_1 : τουλάχιστον δύο μέσοι διαφέρουν

π.χ. K διαφορετικά λιπάσματα

K διαφορετικά είδη αυτοκινήτων $\longrightarrow$ 1 επίδραση
 K σόκολο βαθμών από K διαφορετικούς μαθηγυτες $\longrightarrow$ (π.χ. μέση κατανάλωση)

1	2	...	i	...	K	K ανεξάρτητα δείγματα
y_{11}	y_{21}		y_{i1}		y_{K1}	μέσους $\mu_1, \mu_2, \dots, \mu_K$.
y_{12}	y_{22}		y_{i2}		y_{K2}	<u>π.χ.</u> Κάθε γάρμα αυτοκινήτων i
						περιέχει παρατηρήσεις που
						θα συγκριθούν περισσότερες
						ή λιγότερο γύρω από το
y_{1n_i}	y_{2n_i}		y_{in_i}		y_{Kn_i}	μέσο μ_i (i: γάρμα αυτοκινήτων)
						μαθώς εντός από το είδος

αυτοκινήτων, η μέτρηση επηρεάζεται και από άλλους παράγοντες. Ερώτημα: Είναι όλα τα μ_i ίδια; Μήπως οι διαφορές στις παρατηρήσεις y_{ij} , $j=1, \dots, n_i$, $i=1, \dots, K$, θα μπορούσαν να προέρχονται από τυχαίες αποκλίσεις γύρω από το ίδιο μέσο μ_i ; Δηλαδή, το πρόβλημα που τίθεται είναι αν οι μέσες τιμές των πληθυσμών από τους οποίους προέρχονται τα δείγματα (οι πληθυσμοί θεωρούνται κανονικοί και με κοινή (άγνωστη) διασπορά) διαφέρουν στατιστικά

-4-

σημαντικά ή όχι.

Έστω οι παρατηρήσεις y_{ij} είναι μετρήσεις ανεξάρτητων τυχαίων μεταβλητών με αναμενόμενη τιμή μ_i . y_{ij} : τ.τ.

$$\text{σηλ. } EY_{11} = EY_{12} = \dots = EY_{1n_1} = \mu_1$$

$$EY_{k1} = EY_{k2} = \dots = EY_{kn_k} = \mu_k$$

Θεωρούμε ότι όλες οι τ.τ. έχουν κοινή (άγνωστη) διασπορά σ^2 σηλ. $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2 = \sigma^2$.

Το μοντέλο μπορεί να γραφεί:

$$y_{ij} = \mu_i + \varepsilon_{ij}, \quad i=1, \dots, k \\ j=1, \dots, n_i$$

$$E(\varepsilon_{ij}) = 0, \text{ var}(\varepsilon_{ij}) = \sigma^2, \varepsilon_{ij} \text{ ανεξάρτητα}$$

ε_{ij} : τυχαίο λάθος (μεγάλην απόκλιση της j -παρατήρησης στο i -δείγμα από τον αντίστοιχο μέσο του i -δείγματος).

$$\text{Έλεγχος υπόθεσης: } H_0: \mu_1 = \mu_2 = \dots = \mu_k = \bar{\mu}_k$$

(σηλ. τα k -δείγματα προέρχονται από τον ίδιο πληθυσμό)

H_1 : τουλάχιστον ένα μ_i

διαφορετικό από τα άλλα

$$\bar{\mu} = \frac{1}{n_+} \sum_{i=1}^k n_i \mu_i, \quad n_+ = \sum_{i=1}^k n_i$$

$$a_i = \mu_i - \bar{\mu} \Rightarrow \mu_i = \bar{\mu} + a_i, \quad \sum_{i=1}^k n_i a_i = 0$$

$$H_0: a_1 = a_2 = \dots = a_k = 0$$

$H_1: a_i \neq 0$ για ένα τουλάχιστον $i, i=1, \dots, k$.

$$y_{i.} = \frac{1}{n_i} \sum_{j=1}^{n_i} y_{ij}, i=1, \dots, k$$

$$y_{..} = \frac{1}{n_+} \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} = \sum_{i=1}^k \frac{n_i}{n_+} y_{i.} \text{ (δειγματικός μέσος όλων των παρατηρήσεων)}$$

$$y_{ij} = \mu + \alpha_i + \varepsilon_{ij}, \varepsilon_{ij} \sim N(0, \sigma^2)$$

Ερώτηση: Γιατί δεν λαμβάνουμε τα δείγματα ανά δύο για να κάνουμε το t-test?

$$H_0: \mu_1 = \mu_2 \quad n_1, n_2 \leq 30 \quad \sigma_1^2 = \sigma_2^2 = \sigma^2$$

$$H_1: \mu_1 \neq \mu_2$$

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{1}{n_1} + \frac{1}{n_2}} \sqrt{\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1 + n_2 - 2}}}$$

$$\sim t_{n_1+n_2-2; \alpha/2}$$

Πληθυσμοί από τους οποίους προέρχονται τα δείγματα κανονικοί. Θα χρειαζόταν να κάνουμε $\binom{k}{2}$ ελέγχους. Αν το κάθε test γινόταν σε ε.σ.σ. α τότε το σφάλμα τύπου I

$$P(\text{απόρριψη της } H_0 \mid H_0 \text{ σωστή}) \text{ για τη συνολική διαδικασία}$$

θα ήταν $k\alpha$. Για να ελέγξω το συνολικό λάθος τύπου I σε ε.σ.σ. 5% θα έπρεπε να κάνω κάθε t-test σε ε.σ.σ. $5\%/k$. Έτσι, όπως θα είρασαν αρκετά συντηρητικοί στην απόρριψη της H_0 . Ο ταυτόχρονος έλεγχος της σύνθετης υπόθεσης γίνεται με το F-test.

$$\text{Συνολική απόκλιση: } \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - y_{..})^2$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} [(Y_{ij} - Y_{i.}) + (Y_{i.} - Y_{..})]^2$$

$$= \sum_{i=1}^K \sum_{j=1}^{n_i} (Y_{ij} - Y_{i.})^2 + \sum_{i=1}^K \sum_{j=1}^{n_i} (Y_{i.} - Y_{..})^2 + 2 \sum_{i=1}^K (Y_{i.} - Y_{..}) \sum_{j=1}^{n_i} (Y_{ij} - Y_{i.})$$

$$n_i Y_{i.} - n_i Y_{i.} = 0$$

$$\Rightarrow \sum_{i=1}^K \sum_{j=1}^{n_i} (Y_{ij} - Y_{..})^2 = \sum_{i=1}^K \sum_{j=1}^{n_i} (Y_{ij} - Y_{i.})^2 + \sum_{i=1}^K n_i (Y_{i.} - Y_{..})^2$$

(συνολική διακύβανση)

(διακύβανση των παρατηρήσεων γύρω από το μέσο κάθε δείγματος)

(διακύβανση των μέσων των δειγμάτων γύρω από τον κοινό μέσο)

$$SST = SST_r + SSE$$

↑
διακύβανση που εξηγείται από το μοντέλο

Η νέα χρήση του F-test βασίζεται στις σχέσεις:

$$(i) E(SSE) = \sigma^2 (n_+ - K)$$

$$(ii) E(SS Tr) = \sigma^2(k-1) + \sum_{i=1}^k n_i a_i^2$$

-7-

$$MSSE = \frac{1}{(n_+ - k)} SSE \Rightarrow E(MSSE) = \sigma^2$$

↑
μέσο
τετραγωνικό
σφάλμα
σφαλμάτων

$$MSSTr = \frac{1}{(k-1)} SS Tr \Rightarrow E(SS Tr) = \sigma^2 + \frac{1}{k-1} \sum_{i=1}^k n_i a_i^2$$

↑
μέσο
τετράγωνο
των διαφάσεων

Ορίζουμε $F = \frac{MSSTr}{MSSE} \rightarrow$ μέγιστο όταν κάποια $a_i \neq 0$
(αυτό που θέλουμε)

Όταν ισχύει η $H_0: a_1 = a_2 = \dots = a_k = 0$

$$F \sim F_{k-1, n_+ - k} \quad \text{γιατί} \quad SSE \sim \sigma^2 \chi^2_{n_+ - k}$$

$$SS Tr \sim \sigma^2 \chi^2_{k-1}$$

$SSE, SS Tr$ ανεξάρτητες
z.f.

Σε ε.σ.σ. α απορρίπτουμε την H_0 αν

$$F > F_{k-1, n_+ - k; 1-\alpha}. \quad \text{Τα αθροίσματα τετραγώνων,}$$

οι β.ε., τα μέσα τετράγωνα και η σ.σ. F συγκεντρώνονται
σε έναν πίνακα που καλείται πίνακας ανάλυσης
διασποράς (ANOVA table).

ANOVA TABLE

ΠΙΝΑΚΑΣ ΑΝΑΛΥΣΗΣ ΔΙΑΣΠΟΡΑΣ

Αντία διασποράς	Άθροισμα τετραγώνων	Βαθμοί Ελευθερίας	Μέση Τετραγωνική Σφάλμα
Μεταξύ δείγματος	$SSTr$	$u-1$	$MSSTr = \frac{SSTr}{u-1}$
Μέσα στα δείγματα	SSE	n_+-k	$MSSE = \frac{SSE}{n_+-k}$

$$\left. \begin{array}{l} MSSTr \\ MSSE \end{array} \right\} F_{u-1, n_+-k}$$

Αν ισχύει η H_0 :
$$F = \frac{MSSTr}{MSSE} = \frac{SSTr / (u-1)}{SSE / (n_+-k)}$$

$$= \frac{SSTr (n_+-k)}{SSE (u-1)} \sim F_{u-1, n_+-k}$$

Αν H_0 δεν ισχύει, ο παράγοντας $SSTr$ θα πρέπει να είναι μεγάλος δηλαδή το $SSTr$ πρέπει να είναι μεγάλο σε σχέση με το $MSSE$ κάτι που δικαιολογεί την επιλογή της συχνομετρικής σ.σ.

Παράδειγμα (με τα αυτοκίνητα)

$H_0: \mu_1 = \mu_2 = \mu_3$ (τα τρία είδη αυτοκινήτων έχουν την ίδια μέση κατανάλωση)

$H_1: H_0$ δεν ισχύει

$n_+ = 15$ παρατηρήσεις ($n_1 = 6, n_2 = 5, n_3 = 4$)

$$\bar{y}_{..} = \frac{1}{n_+} \sum_{i=1}^3 \sum_{j=1}^{n_i} y_{ij} = 26 \Rightarrow \underline{\bar{y}_{..} \approx 26}$$

$$SST = \sum_{i=1}^3 \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{..})^2 = 30,673$$

$$y_{1.} = 26,9167, y_{2.} = 26,3, y_{3.} = 23,75, \bar{y}_{..} \approx 26 (\approx 25.8667)$$

$$\sum_{j=1}^6 (y_{1j} - \bar{y}_{1.})^2$$

$$\sum_{j=1}^5 (y_{2j} - \bar{y}_{2.})^2$$

$$\sum_{j=1}^4 (y_{3j} - \bar{y}_{3.})^2$$

Τα τρία αθροίσματα είναι μέτρα απόδοσης της απόδοσης για κάθε είδος αυτοκινήτου.

$$SSE = \sum_{i=1}^3 \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i.})^2 = 5,198$$

Αν η H_0 δεν απορριφθεί τότε τα στοιχεία του δείγματος παρέχουν ενδείξεις ότι τα τρία είδη αυτοκινήτων θα την ίδια περίπου ρέση κατανάλωση και επομένως η ρύση αιτία απομείωση θα είναι η φυσιολογική διακύβανση που παρατηρείται σε διαφορετικά αυτοκίνητα της ίδιας κλάσης, και αποδίδεται με το SSE.

Το SSE είναι σημαντικά μικρότερο του SST κάτι που αποτελεί ένδειξη ότι η H_0 δεν είναι αληθινή και ότι υπάρχει στατιστικά σημαντική διαφορά στους ρέσους των υπό εξέταση πληθυσμών. Αν η H_0 απορριφθεί, αυτό θα σημαίνει ότι μέρος της διασποράς οφείλεται σε διαφορές απόδοσης των διαφορετικών πληθυσμών. Το SSTr είναι μέτρο της διασποράς αυτής.

$$SSTr = \sum_{i=1}^3 n_i (\bar{y}_{i.} - \bar{y}_{..})^2 = 25,475$$

$$SST = SST_r + SSE = 25,475 + 5,198 = 30,673$$

ΠΙΝΑΚΑΣ ANOVA

Αιτία διασποράς	SS	β.ε	MS	F	Sig
μεταξύ ομάδων	25,475	2	12,737	29,404	2=0
μέσα στα ομάδια	5,198	12	0,433		
Σύνολο	30,673	14			

$$F_{2,12} = 3,89 < F_{2,12, \alpha=0.05} = 3.89$$

σε ε.σ.σ. α

Απορρίπτουμε την H_0 σε ε.σ.σ. α.

SPSS

Analyze → Compare Means

→ One-Way Anova

→ Options (✓ Descriptives

✓ Homogeneity of variance test)

• Exclude cases listwise

Levene's test of homogeneity of variance is computed by SPSS to test the ANOVA assumption that each group (category, mark) has the same variance.

-11-
If the Levene statistic is significant at e.g. the $\alpha = 0.05$ (or $\alpha = 0.01$) level, the researcher rejects the H_0 hypothesis that the auto marks have equal variances. The Levene statistic is not significant in our case and the researcher concludes that the three marks are homogenous in variance satisfying an important assumption of ANOVA. Note that using the 0.01 level, the H_0 hypothesis of equal variances is not rejected, too.

