

Κεφάλαιο 6

ΜΟΝΤΕΛΑ ΑΝΑΛΥΣΗΣ ΔΙΑΚΥΜΑΝΣΗΣ

Η ανάλυση διακύμανσης μελετά την επίδραση μιας ή περισσότερων ποσοτικών ανεξάρτητων μεταβλητών στην εξαρτημένη μεταβλητή. Δεν κατασκευάζεται κάποια σχέση μεταξύ εξαρτημένης και ανεξάρτητων αλλά το ενδιαφέρον επικεντρώνεται στο να αναλυθούν οι επιδράσεις μιας ή περισσότερων ανεξάρτητων στην εξαρτημένη.

Ορολογία:

Παράγοντας: ο όρος αυτός χρησιμοποιείται για να περιγράψει την ανεξάρτητη μεταβλητή. Κάθε τιμή του αποτελεί ένα επίπεδο του παράγοντα.

Όταν εξετάζεται μόνο ένας παράγοντας τότε λέμε ότι έχουμε ΑΝΑΔΙΑ κατά ένα παράγοντα (ΑΝΑΔΙΑ = ανάλυση διακύμανσης)

Όταν εξετάζονται δύο παράγοντες τότε λέμε ότι έχουμε ΑΝΑΔΙΑ κατά δύο παράγοντες.

• ΑΝΑΔΙΑ ΚΑΤΑ 1 ΠΑΡΑΓΟΝΤΑ: αποτελεί ουσιαστικά χνίκευση του ελέγχου $h_1 = h_2$ όταν τα επίπεδα του παράγοντα είναι περισσότερα από ένα.

Έστω ένας παράγοντας (π.χ. μορφωτική κατάσταση) με I επίπεδα (π.χ. ΔΗΜΟΤΙΚΟ, ΓΥΜΝΑΣΙΟ - ΛΥΚΕΙΟ, ΑΕΙ - ΤΕΙ).

Σε κάθε επίπεδο του παράγοντα υπάρχουν διαδοχικές n_1, n_2, \dots, n_I παρατηρήσεις αντίστοιχα για την υπό μελέτη εξαρτημένη μεταβλητή (π.χ. κέρδη σε ευρώ)

Έτσι

ΕΠΙΠΕΔΟ	ΠΑΡΑΤΗΡΗΣΕΙΣ
1	$Y_{11}, Y_{12}, \dots, Y_{1n_1}$
2	$Y_{21}, Y_{22}, \dots, Y_{2n_2}$
⋮	⋮
I	$Y_{I1}, Y_{I2}, \dots, Y_{In_I}$

Άρα Y_{ij} είναι η j -οστή παρατήρηση από το i -επίπεδο
 $i=1, \dots, I$ $j=1, \dots, n_i$

Συμβολίζουμε τότε:

$Y_{i.}$ = άθροισμα παρατηρήσεων στο δείγμα από το i -επίπεδο

δηλαδή n_i
 $Y_{i.} = \sum_{j=1}^{n_i} Y_{ij}$ και

$$\bar{Y}_{i.} = \frac{1}{n_i} \sum_{j=1}^{n_i} Y_{ij}$$

$Y_{..}$ = το άθροισμα όλων των διαθέσιμων παρατηρήσεων

δηλαδή I n_i
 $Y_{..} = \sum_{i=1}^I \sum_{j=1}^{n_i} Y_{ij}$ και

$$\bar{Y}_{..} = \frac{1}{N} \sum_{i=1}^I \sum_{j=1}^{n_i} Y_{ij} \quad \text{όπου } N = \sum_{i=1}^I n_i$$

ΣΧΗΜΑΤΙΚΑ

ΕΠΙΠΕΔΟ	ΠΑΡΑΤΗΡΗΣΕΙΣ	ΣΥΝΟΛΟ	Μ.Ο.
1	$Y_{11}, Y_{12}, \dots, Y_{1n_1}$	$Y_{1.}$	$\bar{Y}_{1.}$
2	$Y_{21}, Y_{22}, \dots, Y_{2n_2}$	$Y_{2.}$	$\bar{Y}_{2.}$
⋮	⋮	⋮	⋮
I	$Y_{I1}, Y_{I2}, \dots, Y_{In_I}$	$Y_{I.}$	$\bar{Y}_{I.}$

και $Y_{..} = Y_{1.} + \dots + Y_{I.}$

ενώ $\bar{Y}_{..} = \frac{Y_{..}}{N}$

$N \rightarrow$ το σύνολο / πλήθος όλων των παρατηρήσεων.

Θεωρούμε το μοντέλο:

$$Y_{ij} = \mu_i + \varepsilon_{ij}, \quad i = 1, \dots, I$$

\downarrow
εφάλμα

$$j = 1, \dots, n_i$$

απόλυτη μέση τιμή
του i -οστού πληθυσμού

Πρόσοχή: Μπορεί σε κάποια βήματα να δείτε το μοντέλο αυτό ως

$$Y_{ij} = \mu_j + \varepsilon_{ij}$$

όπως εκεί Y_{ij} είναι η i -οστή τιμή στο j -επίπεδο, ενώ εκείς έχασκε συμβολιστεί

Y_{ij} : την j -οστή παρατήρηση του i -οστού επιπέδου

Δεν διαφοροποιείται κάτι στον τρόπο έκφησης που θα ακολουθήσει.
Είναι

$$Y_{ij} = \mu_i + \varepsilon_{ij}, \quad i = 1, \dots, I$$

$j = 1, \dots, n_i$

Εκτίμηση των άγνωστων παραμέτρων

Θα χρησιμοποιηθεί η μέθοδος ελαχίστων τετραγώνων.

Θα προσδιοριζόμαστε

$$S(\mu_1, \dots, \mu_I) = \sum_{i=1}^I \sum_{j=1}^{n_i} \varepsilon_{ij}^2$$

η ισοδύναμα

$$S(\mu_1, \dots, \mu_I) = \sum_{i=1}^I \sum_{j=1}^{n_i} (Y_{ij} - \mu_i)^2$$

να γίνει ελαχιστοποίηση ως προς $\mu_1, \mu_2, \dots, \mu_I$.

Ουσιαστικά αυτό εμβαίνει ότι $\hat{\mu}_I$ είναι τ/ω να επαληθεύεται το:

$$\frac{\partial S}{\partial \mu_i} = 0, \quad i = 1, 2, \dots, I$$

Η παραχώρηση αυτή θα μπορούσε να γίνει απευθείας αλλά ...
 ως τμήμα δείτε πιο αναλυτικά

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

$$S(\mu_1, \dots, \mu_I) = \sum_{i=1}^I \sum_{j=1}^{n_i} Y_{ij}^2 - 2 \sum_{i=1}^I \mu_i \sum_{j=1}^{n_i} Y_{ij} + \sum_{i=1}^I \mu_i^2 \sum_{j=1}^{n_i} 1$$

$$S(\mu_1, \dots, \mu_I) = \sum_{i=1}^I \sum_{j=1}^{n_i} Y_{ij}^2 - 2 \sum_{i=1}^I \mu_i Y_{i\cdot} + \sum_{i=1}^I \mu_i^2 n_i$$

Αρα

$$S(\mu_1, \dots, \mu_I) = \sum_{i=1}^I \sum_{j=1}^{n_i} Y_{ij}^2 - 2(\mu_1 Y_{1\cdot} + \mu_2 Y_{2\cdot} + \dots + \mu_I Y_{I\cdot}) + (n_1 \mu_1^2 + \dots + n_I \mu_I^2)$$

Επομένως

$$\frac{\partial S}{\partial \mu_i}(\mu_1, \dots, \mu_I) = -2 Y_{i\cdot} + 2 n_i \mu_i \quad i=1, \dots, I$$

$\partial \mu_i$

Αρα $\frac{\partial S}{\partial \mu_i}(\mu_1, \dots, \mu_I) = 0 \Rightarrow \hat{\mu}_i = \frac{Y_{i\cdot}}{n_i} = \bar{Y}_i \quad i=1, \dots, I$

και επιπλέον

$$\frac{\partial^2 S}{\partial^2 \mu_i}(\mu_1, \dots, \mu_I) = 2 n_i > 0$$

Επομένως ο εκτιμητής ελαχίστων τετραγώνων

$$\hat{\mu}_i = \bar{Y}_i \quad i=1, \dots, I$$

ο στατιστικός μέσος του i -οστού πληθυσμού (λογικό αποτέλεσμα)

Παρατήρηση (απουθίας): Προφανώς

$$\frac{\partial S}{\partial \mu_i} (\mu_1 \dots \mu_I) = \frac{\partial}{\partial \mu_i} \sum_i \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 = -2 \sum_{j=1}^{n_i} (y_{ij} - \mu_i)$$

Άρα πρέπει:

$$\sum_{j=1}^{n_i} (y_{ij} - \hat{\mu}_i) = 0 \Rightarrow \sum_{j=1}^{n_i} y_{ij} = n_i \hat{\mu}_i \Rightarrow \hat{\mu}_i = \bar{y}_i.$$

Επίσης

$$\frac{\partial S}{\partial \mu_i} (\mu_1 \dots \mu_I) = 2n_i > 0 \text{ (άρα έχουμε ελάχιστο)}$$

Επομένως στο

$$y_{ij} = \mu_i + \varepsilon_{ij}, \quad \begin{matrix} i=1, \dots, I \\ j=1, \dots, n_i \end{matrix}$$

οι Ε.Ε.Τ. είναι

$$\hat{\mu}_i = \bar{y}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} y_{ij} \quad i=1, \dots, I$$

Ιδιότητες των Ε.Ε.Τ.

Υποθέτουμε ότι $E(\varepsilon_{ij}) = 0$, $\text{Var}(\varepsilon_{ij}) = \sigma^2$ και

$$\text{Cov}(\varepsilon_{ij}, \varepsilon_{kl}) = 0 \quad \forall (i, j) \neq (k, l)$$

Τότε:

$$\left. \begin{array}{l} \textcircled{1} E\hat{\mu}_i = \mu_i \\ \textcircled{2} \text{Var} \hat{\mu}_i = \sigma^2/n_i \end{array} \right\} \text{Απόδειξη εύκολη}$$