

Γραμμικά Μοντέλα
Ανάλυση Διασποράς κατά δύο Παράγοντες

Διδάσκουσα: Λουκία Μελιγκοτσίδου
Εθνικό και Καποδιστριακό Πανεπιστήμιο Αθηνών
Τμήμα Μαθηματικών

May 11, 2020

Ανάλυση Διασποράς με Δυο Παράγοντες (two-factor ANOVA)

Έστω ότι το αποτέλεσμα ενός πειράματος εξαρτάται από 2 παράγοντες, A και B. Αρχικά υποθέτουμε ότι δεν υπάρχει αλληλεπίδραση (interaction) μεταξύ των παραγόντων. Θα μελετήσουμε τον παράγοντα A σε m επίπεδα και τον παράγοντα B σε l επίπεδα. Επομένως υπάρχουν $k = m \cdot l$ συνδυασμοί επιπέδων (treatments) για τους οποίους λαμβάνουμε παρατηρήσεις, έστω μια παρατήρηση σε κάθε treatment. Επομένως, στη συγκεκριμένη περίπτωση, και ο συνολικός αριθμός παρατηρήσεων είναι $n = m \cdot l$.

Δηλαδή

		<i>B</i>					
<i>A</i>	Y_{11}	Y_{12}	\cdots	Y_{1l}	$Y_{1\cdot}$	$\bar{Y}_{1\cdot}$	
	Y_{21}	Y_{22}	\cdots	Y_{2l}	$Y_{2\cdot}$	$\bar{Y}_{2\cdot}$	
			\vdots		\vdots	\vdots	
	Y_{m1}	Y_{m2}	\cdots	Y_{ml}	$Y_{m\cdot}$	$\bar{Y}_{m\cdot}$	
	$Y_{\cdot 1}$ $Y_{\cdot 2}$ \cdots $Y_{\cdot l}$						
$\bar{Y}_{\cdot 1}$ $\bar{Y}_{\cdot 2}$ \cdots $\bar{Y}_{\cdot l}$							

$$\begin{aligned}
 Y_{i\cdot} &= \sum_{j=1}^l Y_{ij} & Y_{\cdot j} &= \sum_{i=1}^m Y_{ij} & \bar{Y}_{\cdot\cdot} &= \frac{1}{n} \sum_{i=1}^m \sum_{j=1}^l Y_{ij} = \frac{1}{m} \sum_{i=1}^m \bar{Y}_{i\cdot} = \frac{1}{l} \sum_{j=1}^l \bar{Y}_{\cdot j} \\
 \bar{Y}_{i\cdot} &= \frac{1}{l} Y_{i\cdot} & \bar{Y}_{\cdot j} &= \frac{1}{m} Y_{\cdot j}
 \end{aligned}$$

Μοντέλο ANOVA

$$Y_{ij} = \mu_{ij} + \epsilon_{ij}, \quad i = 1, \dots, m, \quad j = 1, \dots, l$$

ϵ_{ij} : τυχαία σφάλματα, $\epsilon_{ij} \stackrel{\text{ανεξ.}}{\sim} N(0, \sigma^2)$

$$\mu_{ij} = \mu_{\cdot\cdot} + \alpha_i + \beta_j$$

α_i : επίδραση του i επιπέδου του παράγοντα A

β_j : επίδραση του j επιπέδου του παράγοντα B

$$\text{έτσι ώστε } \sum_{i=1}^m \alpha_i = 0 \text{ και } \sum_{j=1}^l \beta_j = 0$$

Δηλαδή θεωρούμε ότι το $\mu_{\cdot\cdot}$ περιέχει όλες τις σταθερές (κοινές για όλα τα treatments) επιδράσεις στη μέση τιμή της απαντητικής μεταβλητής, ενώ τα α_i και

β_j είναι οι ειδικές επιδράσεις των επιπέδων των παραγόντων A και B, αντίστοιχα.

Άρα, έχουμε $Y_{ij} \sim N(\mu_{ij}, \sigma^2)$.

Υποθέσεις :

- Κανονικότητα
- Ομοσκεδαστικότητα
- Τυχαιότητα/Ανεξαρτησία

Έχουμε υποθέσει ότι $\sum_{i=1}^m \alpha_i = 0$ και $\sum_{j=1}^l \beta_j = 0$, δηλαδή ότι οι μέσες επιδράσεις των παραγόντων A και B είναι 0 (ή αλλιώς ότι έχουν συμπεριληφθεί στο $\mu_{..}$). Αυτό φαίνεται αν θεωρήσουμε $\mu_{ij} = \mu'_{..} + \alpha'_i + \beta'_j$ και $\bar{\alpha}' = \frac{1}{m} \sum_{i=1}^m \alpha'_i$ και $\bar{\beta}' = \frac{1}{l} \sum_{j=1}^l \beta'_j$. Τότε

$$\mu_{ij} = \underbrace{\mu'_{..} + \bar{\alpha}' + \bar{\beta}'}_{\mu_{..}} + \underbrace{\alpha'_i - \bar{\alpha}'}_{\alpha_i} + \underbrace{\beta'_j - \bar{\beta}'}_{\beta_j}$$

Προφανώς $\sum_{i=1}^m \alpha_i = \sum_{i=1}^m (\alpha'_i - \bar{\alpha}') = 0$ και $\sum_{j=1}^l \beta_j = \sum_{j=1}^l (\beta'_j - \bar{\beta}') = 0$.

Έλεγχοι Υποθέσεων

Για να ελέγξουμε αν υπάρχει επίδραση του παράγοντα A κάνουμε τον έλεγχο

$$H_0 : \mu_{11} = \mu_{21} = \dots = \mu_{m1} = \mu$$

$$H_1 : 2 \text{ τουλάχιστον διαφέρουν}$$

Ισοδύναμα

$$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_m = 0$$

$$H_1 : \alpha_i \neq \alpha_j \text{ για τουλάχιστον ένα ζεύγος } i, j$$

Αντίστοιχα για να ελέγξουμε αν υπάρχει επίδραση του παράγοντα B

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_m = 0$$

$$H_1 : \beta_i \neq \beta_j \text{ για τουλάχιστον ένα ζεύγος } i, j$$

Οι παραπάνω έλεγχοι μπορούν να πραγματοποιηθούν με ανάλυση διασποράς και έλεγχο F σε αναλογία με την ANOVA κατά ένα παράγοντα.

Συνολικό άθροισμα τετραγωνικών αποκλίσεων:

$$\begin{aligned}
 SST &= \sum_{i=1}^m \sum_{j=1}^l (Y_{ij} - \bar{Y}_{..})^2 \\
 &= \sum_{i=1}^m \sum_{j=1}^l ((\bar{Y}_{i.} - \bar{Y}_{..}) + (\bar{Y}_{.j} - \bar{Y}_{..}) + (Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..}))^2 \\
 &= \sum_{i=1}^m \sum_{j=1}^l (\bar{Y}_{i.} - \bar{Y}_{..})^2 + \sum_{i=1}^m \sum_{j=1}^l (\bar{Y}_{.j} - \bar{Y}_{..})^2 + \sum_{i=1}^m \sum_{j=1}^l (Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..})^2,
 \end{aligned}$$

μπορεί να αποδειχθεί ότι όλα τα αθροίσματα διπλασίων γινομένων που σχηματίζονται από τα $(\bar{Y}_{i.} - \bar{Y}_{..})$, $(\bar{Y}_{.j} - \bar{Y}_{..})$ και $(Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..})$ είναι 0. Επομένως

$$SST = \underbrace{\sum_{i=1}^m \sum_{j=1}^l (\bar{Y}_{i.} - \bar{Y}_{..})^2}_{SSA} + \underbrace{\sum_{i=1}^m \sum_{j=1}^l (\bar{Y}_{.j} - \bar{Y}_{..})^2}_{SSB} + \underbrace{\sum_{i=1}^m \sum_{j=1}^l (Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..})^2}_{SSE}$$

SSA : άθροισμα τετραγώνων μεταξύ επιπέδων του παράγοντα A

SSB : άθροισμα τετραγώνων μεταξύ επιπέδων του παράγοντα B

SSE : άθροισμα τετραγώνων των τυχαίων σφαλμάτων.

Απόδειξη για $\sum_{i=1}^m \sum_{j=1}^l (\bar{Y}_{.j} - \bar{Y}_{..})(Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..})$

$$\begin{aligned}
 \sum_{i=1}^m \sum_{j=1}^l (\bar{Y}_{.j} - \bar{Y}_{..})(Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..}) &= \sum_{j=1}^l (\bar{Y}_{.j} - \bar{Y}_{..}) \sum_{i=1}^m (Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..}) \\
 &= \sum_{j=1}^l (\bar{Y}_{.j} - \bar{Y}_{..}) \left(\sum_{i=1}^m (Y_{ij} - \bar{Y}_{.j}) - \left(\sum_{i=1}^m \bar{Y}_{i.} - m\bar{Y}_{..} \right) \right) \\
 &= \sum_{j=1}^l (\bar{Y}_{.j} - \bar{Y}_{..}) \left((Y_{.j} - m\bar{Y}_{.j}) - \left(\sum_{i=1}^m \frac{Y_{i.}}{l} - m\frac{Y_{..}}{ml} \right) \right) \\
 &= 0
 \end{aligned}$$

Σε πλήρη αντιστοιχία με την ANOVA κατά έναν παράγοντα οι συνολικοί βαθμοί ελευθερίας είναι $ml - 1$, οι βαθμοί ελευθερίας του παράγοντα A είναι $m - 1$ και του παράγοντα B είναι $l - 1$. Τέλος οι βαθμοί ελευθερίας των σφαλμάτων είναι $ml - m - l + 1 = m(l - 1) - (l - 1) = (m - 1)(l - 1)$.

Ισχύει πάντα ότι $\frac{SSE}{\sigma^2} \sim X^2_{(m-1)(l-1)}$.

Κάτω από την $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_m = 0$ ισχύει ότι $\frac{SSA}{\sigma^2} \sim X^2(m-1)$. Άρα, για τον έλεγχο αυτής της H_0 μπορούμε να χρησιμοποιήσουμε την ελεγχοσυνάρτηση $F_A = \frac{SSA/m-1}{SSE/(m-1)(l-1)}$, η οποία κάτω από H_0 ακολουθεί $F(m-1, (m-1)(l-1))$. Απορρίπτουμε την H_0 σε επίπεδο στατιστικής σημαντικότητας α αν $F_A > F_{\alpha}(m-1, (m-1)(l-1))$.

Κάτω από την $H_0 : \beta_1 = \beta_2 = \dots = \beta_m = 0$ ισχύει ότι $\frac{SSB}{\sigma^2} \sim X^2(l-1)$. Άρα για τον έλεγχο αυτής της H_0 μπορούμε να χρησιμοποιήσουμε την ελεγχοσυνάρτηση $F_B = \frac{SSB/l-1}{SSE/(m-1)(l-1)}$, η οποία κάτω από H_0 ακολουθεί $F(l-1, (m-1)(l-1))$. Απορρίπτουμε την H_0 σε επίπεδο στατιστικής σημαντικότητας α αν $F_B > F_{\alpha}(l-1, (m-1)(l-1))$.

Πίνακας ANOVA

Πηγή μεταβλητότητας	SS	df	MS	$F = \frac{MSF}{MSE}$	p-value
Παράγοντας A	SSA	$m - 1$	$MSA = \frac{SSA}{m-1}$	$F_A = \frac{MSA}{MSE}$	★
Παράγοντας B	SSB	$l - 1$	$MSB = \frac{SSB}{l-1}$	$F_B = \frac{MSB}{MSE}$	
Σφάλμα(Error)	SSE	$(m - 1)(l - 1)$	$MSE = \frac{SSE}{(m-1)(l-1)}$		
Σύνολο(Total)	SST	$ml - 1$			

Παράδειγμα: Μας ενδιαφέρει να μελετήσουμε την κατανάλωση βενζίνης από αυτοκίνητα μιας συγκεκριμένης κατηγορίας. Έχουμε 3 μάρκες αυτοκινήτων και 4 διαφορετικούς τύπους βενζίνης. Ο αριθμός των χιλιομέτρων (km) ανά γαλόνι βενζίνης για καθέναν από τους συνδυασμούς είναι

μάρκα αυτοκινήτου	τύπος βενζίνης				\bar{Y}_i
	1	2	3	4	
1	16	18	21	21	19
2	14	15	18	17	16
3	15	15	18	16	16
$\bar{Y}_{.j}$	15	16	19	18	$\bar{Y}_{..}=17$

Μοντέλο ANOVA: $Y_{ij} = \mu + \alpha_i + \beta_j$, $i = 1, 2, 3$, $j = 1, 2, 3, 4$. Μας ενδιαφέρει να ελέγξουμε κατά πόσο η μέση κατανάλωση βενζίνης διαφέρει για τους διάφορους τύπους βενζίνης σε επίπεδο στατιστικής σημαντικότητας $\alpha = 1\%$. Δηλαδή, θέλουμε να ελέγξουμε την

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_m = 0$$

εναντι

$$H_1 : \beta_i \neq \beta_j \text{ για τουλάχιστον ένα ζεύγος } i, j$$

Πίνακας ANOVA

Πηγή μεταβλητότητας	SS	df	MS	$F = \frac{MSF}{MSE}$
Παράγοντας A	$SSA = 24$	$m - 1 = 2$	$MSA = \frac{24}{2} = 12$	$F_A = \frac{12}{2/3} = 18$
Παράγοντας B	$SSB = 30$	$l - 1 = 3$	$MSB = \frac{30}{3} = 10$	$F_B = \frac{10}{2/3} = 15$
Σφάλμα(Error)	$SSE = 4$	$(m - 1)(l - 1) = 6$	$MSE = \frac{4}{6} = \frac{2}{3}$	
Σύνολο(Total)	$SST = 58$	$ml - 1 = 11$		

Σε επίπεδο στατιστικής σημαντικότητας $\alpha = 1\%$ απορρίπτουμε την H_0 εαν $F_B > F_{0.01}(3, 6)$. Έχουμε $F_B = 15 > F_{0.01}(3, 6) = 9.78$, άρα απορρίπτουμε την H_0 . Δηλαδή η μέση κατανάλωση βενζίνης διαφέρει στατιστικά σημαντικά για τους διάφορους τύπους βενζίνης, στις 3 μάρκες αυτοκινήτων που εξετάστηκαν.

Άσκηση. Ένας κατασκευαστής τηλεοράσεων ενδιαφέρεται να ελέγξει αν η αγωγιμότητα του περιβλήματος τεσσάρων διαφορετικών τύπων καλωδίων τηλεόρασης διαφέρει. Μετρήσεις για την αγωγιμότητα των περιβλημάτων καλωδίων δίνονται στον παρακάτω πίνακα.

Τύπος καλωδίου i	Αγωγιμότητα Y_{ij}	$Y_{i.}$	$\bar{Y}_{i.}$
1	143 141 150 146	580	145
2	152 149 137 143	581	145.25
3	144 146 142 137	569	142.25
4	129 127 132 129	517	129.25
		$Y_{..} = 2247$	$\bar{Y}_{..} = 140.43$

- (a) Να ελεγχθεί σε $\alpha = 5\%$ αν υπάρχει διαφορά στην αγωγιμότητα του περιβλήματος των τεσσάρων τύπων καλωδίων.
 (b) Να κατασκευαστεί διάστημα εμπιστοσύνης συντελεστή 95% για τον μέσο του τέταρτου τύπου καλωδίου.
 (c) Ο κατασκευαστής αποφασίζει να χρησιμοποιήσει τον τέταρτο τύπο καλωδίου γιατί υποστηρίζει ότι δίνει τη μικρότερη αγωγιμότητα περιβλήματος σε σύγκριση με τους άλλους τρεις τύπους. Να ελεγχθεί σε $\alpha = 5\%$ αν ισχύει ο ισχυρισμός του κατασκευαστή.

Δίνονται $F_{0.05}(3, 12) = 3.49$, $t_{0.025}(12) = 2.179$ και $t_{0.05}(12) = 1.782$.

Λύση:

(a)

$$SST = \sum_{i=1}^m \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{..})^2 = 925.9375$$

$$SSF = \sum_{i=1}^m n_i (\bar{Y}_{i.} - \bar{Y}_{..})^2 = 689.6875$$

Άρα $SSE = SST - SSF = 236.25$.

Πίνακας ANOVA

Πηγή διασποράς	SS	df	MS	$F = \frac{MSF}{MSE}$
F	$SSF = 689.6875$	$m - 1 = 3$	$229.8958 = \frac{SSF}{m-1}$	11.6772
E	$SSE = 236.25$	$n - m = 12$	$19.6875 = \frac{SSE}{n-m}$	
T	$SST = 925.9375$	$n - 1 = 15$		

Θεωρούμε τον έλεγχο της

$$H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4$$

εναντι

$$H_1 : \mu_i \neq \mu_j \text{ για ένα τουλάχιστον ζεύγος } i, j$$

Εφόσον $F = 11.6772 > F_{0.05}(3, 12) = 3.49$ απορρίπτουμε την H_0 σε επίπεδο σημαντικότητας $\alpha = 5\%$. Άρα υπάρχει στατιστικά σημαντική διαφορά ανάμεσα στους μέσους των επιπέδων.

(b) Για τη μέση αγωγιμότητα του τέταρτου τύπου καλωδίου, δηλαδή για το μ_4 , έχουμε:

$$\begin{aligned}\bar{Y}_{4.} &= 129.25 \\ S_{\bar{Y}_{4.}}^2 &= \frac{MSE}{n_4} = 4.92219\end{aligned}$$

$$Pr[-t_{0.025}(12) \leq \frac{\bar{Y}_{4.} - \mu_4}{\sqrt{S_{\bar{Y}_{4.}}^2}} \leq t_{0.025}(12)] = 0.95$$

Το αντίστοιχο διάστημα εμπιστοσύνης, συντελεστή 95%, είναι

$$\begin{aligned}\bar{Y}_{4.} - \sqrt{S_{\bar{Y}_{4.}}^2} t_{0.025}(12) &\leq \mu_4 \leq \bar{Y}_{4.} + \sqrt{S_{\bar{Y}_{4.}}^2} t_{0.025}(12) \\ 129.25 - \sqrt{4.9219} 2.179 &\leq \mu_4 \leq 129.25 + \sqrt{4.9219} 2.179 \\ 124.4159 &\leq \mu_4 \leq 134.0841.\end{aligned}$$

σε επίπεδο

(c) Θεωρούμε το contrast $L = \frac{\mu_1 + \mu_2 + \mu_3}{3} - \mu_4$. Έχουμε

$$\begin{aligned}\hat{L} &= \frac{\bar{Y}_1 + \bar{Y}_2 + \bar{Y}_3}{3} - \bar{Y}_4 = 14.9167 \\ \sum_{i=1}^4 \frac{c_i^2}{n_i} &= \frac{1}{4} \left[\frac{1}{9} + \frac{1}{9} + \frac{1}{9} + 1 \right] = \frac{1}{3} \\ S_{\hat{L}}^2 &= MSE \left[\sum_{i=1}^4 \frac{c_i^2}{n_i} \right] = 6.5625\end{aligned}$$

Άρα το διάστημα εμπιστοσύνης δίνεται ως

$$\begin{aligned} \hat{L} - \sqrt{S_L^2} t_{0.025}(12) &\leq L \leq \hat{L} + \sqrt{S_L^2} t_{0.025}(12) \\ 14.9167 - 2.5617 \cdot 2.179 &\leq L \leq 14.9167 + 2.5617 \cdot 2.179 \\ 9.3348 &\leq L \leq 20.4986. \end{aligned}$$

Εφόσον το 0 δεν περιέχεται στο διάστημα εμπιστοσύνης η διαφορά του τέταρτου τύπου καλωδίου από τους άλλους τρεις είναι στατιστικά σημαντική σε ε.σ.σ $\alpha = 5\%$.

Ο ισχυρισμός του κατασκευαστή είναι ότι η μέση αγωγιμότητα του περιβλήματος του τέταρτου τύπου καλωδίου είναι μικρότερη από αυτή των τριών άλλων τύπων, δηλαδή $\mu_4 < \frac{\mu_1 + \mu_2 + \mu_3}{3}$. Ο ισχυρισμός μπορεί να ελεγχθεί μέσω ενός ελέγχου υποθέσεων με μονόπλευρη εναλλακτική. Συγκεκριμένα, ο έλεγχος διατυπώνεται ως

$$\begin{aligned} H_0 &: L = 0 \\ H_1 &: L > 0. \end{aligned}$$

Η ελεγχοσυνάρτηση είναι Συγκεκριμένα είναι $\frac{\hat{L}}{\sqrt{S_L^2}}$, η οποία κάτω από την ισχύ της H_0 ακολουθεί $t(12)$ κατανομή. Η παρατηρούμενη τιμή της ελεγχοσυνάρτησης είναι $\frac{\hat{L}}{\sqrt{S_L^2}} = 5.8230 > 1.782 = t_{0.05}(12)$. Επομένως, απορρίπτουμε την H_0 σε επίπεδο σημαντικότητας $\alpha = 5\%$ και άρα ισχύει ο ισχυρισμός του κατασκευαστή.

ANOVA κατά δυο παράγοντες με αλληλεπίδραση

Οι δυο παράγοντες που εξετάζουμε μπορεί να αλληλεπιδρούν μεταξύ τους. Για να ελέγξουμε για πιθανή αλληλεπίδραση (interaction) εξετάζουμε δείγμα μεγάλους c για κάθε συνδυασμό επιπέδων των δυο παραγόντων (treatment). Έχουμε δηλαδή παρατηρήσεις $Y_{ijr} \sim N(\mu_{ij}, \sigma^2)$, $i = 1, \dots, m$, $j = 1, \dots, l$ και $r = 1, \dots, c$.

Μοντέλο ANOVA

$$Y_{ij} = \mu_{..} + \alpha_i + \beta_j + \gamma_{ij}$$

έτσι ώστε $\sum_{i=1}^m \alpha_i = 0$, $\sum_{j=1}^l \beta_j = 0$ και $\sum_{i=1}^m \gamma_{ij} = 0$, $j = 1, \dots, l$ και $\sum_{j=1}^l \gamma_{ij} = 0$, $i = 1, \dots, m$.

$$\begin{aligned} \bar{Y}_{ij.} &= \frac{1}{c} \sum_{r=1}^c Y_{ijr} & \bar{Y}_{i.r} &= \frac{1}{l} \sum_{j=1}^l Y_{ijr} & \bar{Y}_{.jr} &= \frac{1}{m} \sum_{i=1}^m Y_{ijr} \\ \bar{Y}_{i..} &= \frac{1}{lc} \sum_{j=1}^l \sum_{r=1}^c Y_{ijr} & \bar{Y}_{.j.} &= \frac{1}{mc} \sum_{i=1}^m \sum_{r=1}^c Y_{ijr} & \bar{Y}_{..r} &= \frac{1}{ml} \sum_{i=1}^m \sum_{j=1}^l Y_{ijr} \\ \bar{Y}_{...} &= \frac{1}{mlc} \sum_{i=1}^m \sum_{j=1}^l \sum_{r=1}^c Y_{ijr} \end{aligned}$$

Συνολική μεταβλητότητα :

$$\begin{aligned} SST &= \sum_{i=1}^m \sum_{j=1}^l \sum_{r=1}^c (Y_{ijr} - \bar{Y}_{...})^2 \\ &= \sum_{i=1}^m \sum_{j=1}^l \sum_{r=1}^c ((\bar{Y}_{i..} - \bar{Y}_{...}) + (\bar{Y}_{.j.} - \bar{Y}_{...}) + (Y_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j.} + \bar{Y}_{...}) + (\bar{Y}_{ijr} - \bar{Y}_{ij.}))^2 \\ &= \sum_{i=1}^m lc(\bar{Y}_{i..} - \bar{Y}_{...})^2 + \sum_{j=1}^l mc(\bar{Y}_{.j.} - \bar{Y}_{...})^2 + \sum_{i=1}^m \sum_{j=1}^l c(Y_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j.} + \bar{Y}_{...})^2 \\ &\quad + \sum_{i=1}^m \sum_{j=1}^l \sum_{r=1}^c (\bar{Y}_{ijr} - \bar{Y}_{ij.})^2, \end{aligned}$$

Ορίζουμε

$$SSA = \sum_{i=1}^m lc(\bar{Y}_{i..} - \bar{Y}_{...})^2$$

SSA : άθροισμα τετραγώνων μεταξύ επιπέδων του παράγοντα A

$$SSB = \sum_{j=1}^l mc(\bar{Y}_{.j.} - \bar{Y}_{...})^2$$

SSB : άθροισμα τετραγώνων μεταξύ επιπέδων του παράγοντα B

$$SS(AB) = \sum_{i=1}^m \sum_{j=1}^l c(Y_{ij.} - \bar{Y}_{i..} - \bar{Y}_{.j.} + \bar{Y}_{...})^2$$

$SS(AB)$: άθροισμα τετραγώνων της αλληλεπίδρασης

$$SSE = \sum_{i=1}^m \sum_{j=1}^l \sum_{r=1}^c (\bar{Y}_{ijr} - \bar{Y}_{ij.})^2$$

SSE : άθροισμα τετραγώνων των τυχαίων σφαλμάτων.

Επομένως

$$SST = SSA + SSB + SS(AB) + SSE$$

Πίνακας ANOVA

Πηγή μεταβλητότητας	SS	df	MS	$F = \frac{MSF}{MSE}$
Παράγοντας A	SSA	$m - 1$	$MSA = \frac{SSA}{m-1}$	$F_A = \frac{MSA}{MSE}$
Παράγοντας B	SSB	$l - 1$	$MSB = \frac{SSB}{l-1}$	$F_B = \frac{MSB}{MSE}$
Παράγοντας AB	$SS(AB)$	$(m - 1)(l - 1)$	$MS(AB) = \frac{SS(AB)}{(m-1)(l-1)}$	$F_{AB} = \frac{MS(AB)}{MSE}$
Σφάλμα(Error)	SSE	$ml(c - 1)$	$MSE = \frac{SSE}{ml(c-1)}$	
Σύνολο(Total)	SST	$mlc - 1$		

F-test για αλληλεπίδραση

Θεωρούμε τον έλεγχο

$$H_0 : \gamma_{ij} = 0 \quad i = 1, \dots, m, \quad j = 1, \dots, l$$

$$H_1 : \gamma_{ij} \neq 0 \quad \text{για ένα τουλάχιστον } i, j$$

Απορρίπτουμε την H_0 σε επίπεδο στατιστικής σημαντικότητας α αν $F_{AB} = \frac{MS(AB)}{MSE} > F_{\alpha}((m - 1)(l - 1), ml(c - 1))$.

Ελέγχουμε πρώτα την ύπαρξη στατιστικά σημαντικής αλληλεπίδρασης και έπειτα την στατιστική σημαντικότητα των επιμέρους παραγόντων.