

ΑΝΑΛΥΣΗ ΔΙΑΚΥΜΑΝΣΗΣ

Αναπλ. Καθ. Στέλιος Ζήμερας

Τμήμα Στατιστικής και Αναλογιστικών –
Χρηματοοικονομικών Μαθηματικών

2020

Μοντελοποίηση

Δηλ: οι μέσες τιμές των πληθυσμών από τους οποίους λαμβάνονται τα εν λόγω δείγματα είναι ίσες μεταξύ τους

Θεωρούμε ότι $n = n_1 + n_2 + \dots + n_k$ όπου n : είναι το μέγεθος του δείγματος.

Θα έχουμε ότι για την παρατήρηση Y_{ij} που γράφεται ως

$$Y_{ij} = \mu + a_i + \beta_j + \varepsilon_{ij}, i = 1, 2, \dots, k; j = 1, 2, \dots, p$$

όπου οι τ.μ. ε_{ij} είναι ανεξάρτητες και $\varepsilon_{ij} \sim N(0, \sigma^2)$ με $\sigma^2 > 0$

$$\sum_i^k a_i = 0 \qquad \sum_j^p \beta_j = 0$$

Υποθέσεις $H_A : a_1 = a_2 = \dots = a_k = 0$

$$H_B : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

Μοντελοποίηση

Έλεγχος της υπόθεσης H_B

Παρατηρούμε ότι αφού ισχύει $\sum_j^p \beta_j = 0$

τότε η H_B γράφεται ισοδύναμα

$$H_B : \beta_1 - \beta_p = 0, \beta_2 - \beta_p = 0, \dots, \beta_{p-1} - \beta_p = 0$$

Αν θέσουμε

$$\begin{aligned} S &= (Y - X\beta)'(Y - X\beta) = \sum_i^k \sum_j^p (Y_{ij} - \mu - a_i - \beta_j)^2 = \\ &= \sum_i^k (Y_{i1} - \mu - a_i - \beta_1)^2 + \sum_i^k (Y_{i2} - \mu - a_i - \beta_2)^2 + \dots + \\ &+ \sum_i^k (Y_{ip} - \mu - a_i - \beta_p)^2 \end{aligned}$$

Μοντελοποίηση

$$\hat{\mu} = \frac{1}{n} \sum_i^k \sum_j^p Y_{ij} = Y_{..}$$



$$\hat{a}_1 = Y_{1.} - Y_{..}, \hat{a}_2 = Y_{2.} - Y_{..}, \dots, \hat{a}_k = Y_{k.} - Y_{..}$$

$$\hat{\beta}_1 = Y_{.1} - Y_{..}, \hat{\beta}_2 = Y_{.2} - Y_{..}, \dots, \hat{\beta}_p = Y_{.p} - Y_{..}$$

Μοντελοποίηση

Το άθροισμα τετραγώνων των αποκλίσεων

$$\begin{aligned} R_0^2 &= \sum_{i=1}^k \sum_{j=1}^p (Y_{ij} - \hat{\mu} - \hat{\alpha}_i - \beta_j)^2 = \\ &= \sum_{i=1}^k \sum_{j=1}^p \left[Y_{ij} - Y_{..} - (Y_{i.} - Y_{..}) - (Y_{.j} - Y_{..}) \right]^2 = \\ &= \sum_{i=1}^k \sum_{j=1}^p \left[Y_{ij} - Y_{i.} - Y_{.j} + Y_{..} \right]^2 \end{aligned}$$

Μοντελοποίηση

- Κάτω από την υπόθεση $H_B : \beta_j = 0, j=1,2,\dots,p$ έχουμε να ελαχιστοποιήσουμε το άθροισμα

$$S_B = \sum_i^k \sum_j^p (Y_{ij} - \mu - a_i)^2 = \sum_j^p (Y_{1j} - \mu - a_1)^2 + \\ + \sum_j^p (Y_{2j} - \mu - a_2)^2 + \dots + \sum_j^p (Y_{kj} - \mu - a_k)^2$$

Μοντελοποίηση

Άρα

$$\frac{\partial S_B}{\partial \mu} = -2 \sum_i^k \sum_j^p (Y_{ij} - \mu - a_i) = 0 \Rightarrow$$

$$\Rightarrow \sum_i^k \sum_j^p Y_{ij} - k p \mu = 0$$

Αφού $\sum_i^k a_i = 0$

Επομένως η εκτιμήτρια ελαχίστων τετραγώνων της παραμέτρου μ (αν θέσουμε $k p = n$) έχουμε

$$\hat{\mu} = \frac{1}{n} \sum_i^k \sum_j^p Y_{ij} = Y_{..} = \tilde{\mu}$$

Μοντελοποίηση

Θα έχουμε

$$\frac{\partial S_B}{\partial a_1} = -2 \sum_i^k (Y_{1j} - \mu - a_1) = 0$$

$$\frac{\partial S_B}{\partial a_2} = -2 \sum_i^k (Y_{2j} - \mu - a_2) = 0$$

.....

$$\frac{\partial S_B}{\partial a_k} = -2 \sum_i^k (Y_{kp} - \mu - a_k) = 0$$

Μοντελοποίηση

- Το σύστημα γράφεται ισοδύναμα αν λάβουμε υπόψη

$$p(\mu + a_1) = \sum_j^p Y_{1j}$$

$$p(\mu + a_2) = \sum_j^p Y_{2j}$$

.....

$$p(\mu + a_k) = \sum_j^p Y_{kj}$$

Μοντελοποίηση

Με βάση το παραπάνω σύστημα εξισώσεων αν οι μεταβλητές είναι εκτιμήτριες ελαχίστων τετραγώνων των $\mu, \beta_1, \beta_2, \dots, \beta_p$, τότε έχουμε

$$(\tilde{\mu} + \tilde{a}_1) = \frac{1}{p} \sum_j^p Y_{1j} = Y_1.$$

$$(\tilde{\mu} + \tilde{a}_2) = \frac{1}{p} \sum_j^p Y_{2j} = Y_2.$$

.....

$$(\tilde{\mu} + \tilde{a}_k) = \frac{1}{p} \sum_j^p Y_{kj} = Y_k.$$

Μοντελοποίηση

$$\hat{\mu} = \frac{1}{n} \sum_i^k \sum_j^p Y_{ij} = Y_{..} = \tilde{\mu}$$



$$\tilde{a}_1 = Y_{1.} - Y_{..}$$

$$\tilde{a}_2 = Y_{2.} - Y_{..}$$

.....

$$\tilde{a}_k = Y_{k.} - Y_{..}$$

Μοντελοποίηση

Παρατηρούμε ότι ισχύει

$$\tilde{\tilde{a}}_1 = \hat{a}_1$$

$$\tilde{\tilde{a}}_2 = \hat{a}_2$$

.....

$$\tilde{\tilde{a}}_k = \hat{a}_k$$

με βάση

$$\tilde{\tilde{\beta}}_1 = 0$$

$$\tilde{\tilde{\beta}}_2 = 0$$

.....

$$\tilde{\tilde{\beta}}_p = 0$$

Μοντελοποίηση

- Η ελάχιστη τιμή του S_B θα είναι

$$\begin{aligned}\tilde{R}_1^2 &= \sum_{i=1}^k \sum_{j=1}^p (Y_{ij} - \hat{\mu} - \hat{a}_i)^2 = \\ &= \sum_{i=1}^k \sum_{j=1}^p [Y_{ij} - Y_{..} - Y_{i.} + Y_{..}]^2 = \sum_{i=1}^k \sum_{j=1}^p [Y_{ij} - Y_{i.}]^2\end{aligned}$$

Μοντελοποίηση

- Το άθροισμα τετραγώνων που οφείλεται στην απόκλιση από την H_B θα είναι

$$\tilde{R}_1^2 - R_0^2 = \sum_{i=1}^k \sum_{j=1}^p (Y_{ij} - Y_{i.})^2 - \sum_{i=1}^k \sum_{j=1}^p [Y_{ij} - Y_{i.} - Y_{.j} + Y_{..}]^2 \Rightarrow$$

$$\Rightarrow \tilde{R}_1^2 - R_0^2 = k \sum_j^p \hat{\beta}_j^2 = k \sum_{j=1}^p [Y_{.j} - Y_{..}]^2$$

Μοντελοποίηση

- Η στατιστική συνάρτηση F για τον έλεγχο της H_B θα είναι

$$F_B = \frac{k \sum_{j=1}^p [Y_{.j} - Y_{..}]^2 / (p-1)}{R_0^2 / (k-1)(\rho-1)}$$

Μοντελοποίηση

Πηγή μεταβλητότητας	Άθροισμα τετραγώνων	Βαθμοί ελευθερίας	Μέσο άθροισμα τετραγώνων	F
Απόκλιση από την H_A (μεταξύ δειγμάτων)	$R_1^2 - R_0^2$	k-1	$\frac{\rho \sum_{i=1}^k [Y_{i.} - Y_{..}]^2}{(k-1)}$	$F_A = \frac{\frac{\rho \sum_{i=1}^k [Y_{i.} - Y_{..}]^2}{(k-1)}}{\frac{R_0^2}{(k-1)(\rho-1)}}$
Απόκλιση από την H_B (μεταξύ δειγμάτων)	$\tilde{R}_1^2 - R_0^2$	p-1	$\frac{k \sum_{j=1}^p [Y_{.j} - Y_{..}]^2}{(p-1)}$	$F_B = \frac{\frac{k \sum_{j=1}^p [Y_{.j} - Y_{..}]^2}{(p-1)}}{\frac{R_0^2}{(k-1)(\rho-1)}}$
Κατάλοιπα (εντός δειγμάτων)	R_0^2	(k-1)(p-1)	$\frac{R_0^2}{(k-1)(p-1)}$	
Σύνολο	$\sum_{i=1}^k \sum_{j=1}^p (Y_{ij} - Y_{..})^2$	n-1		

Απλοποιήσεις

- Το ολικό άθροισμα τετραγώνων υπολογίζεται από

$$\sum_{i=1}^k \sum_{j=1}^p (Y_{ij} - Y_{..})^2 = \sum_{i=1}^k \sum_{j=1}^p Y_{ij}^2 - \frac{1}{n} \left(\sum_{i=1}^k \sum_{j=1}^p Y_{ij} \right)^2$$

- Στην περίπτωση H_A έχουμε

$$\begin{aligned} R_1^2 - R_0^2 &= \rho \sum_i^k \hat{a}_i^2 = \rho \sum_{i=1}^k [Y_{i.} - Y_{..}]^2 = \rho \left[\sum_i^k Y_{i.}^2 - \frac{1}{k} \left(\sum_i^k Y_{i.} \right)^2 \right] = \\ &= \rho \sum_i^k Y_{i.}^2 - \rho \frac{1}{k} k^2 Y_{..}^2 = \rho \sum_i^k Y_{i.}^2 - \rho k Y_{..}^2 = \rho \sum_i^k Y_{i.}^2 - \frac{1}{n} \left(\sum_i^k \sum_j^p Y_{ij} \right)^2 \end{aligned}$$

$$R_1^2 - R_0^2 = \rho \sum_i^k Y_{i.}^2 - \frac{1}{n} \left(\sum_i^k \sum_j^p Y_{ij} \right)^2$$

Απλοποιήσεις

- Το ολικό άθροισμα τετραγώνων υπολογίζεται από

$$\sum_{i=1}^k \sum_{j=1}^p (Y_{ij} - Y_{..})^2 = \sum_{i=1}^k \sum_{j=1}^p Y_{ij}^2 - \frac{1}{n} \left(\sum_{i=1}^k \sum_{j=1}^p Y_{ij} \right)^2$$

- Στην περίπτωση H_B έχουμε

$$\tilde{R}_1^2 - R_0^2 = k \sum_j \hat{\beta}_j^2 = k \sum_j [Y_{.j} - Y_{..}]^2 = k \left[\sum_j Y_{.j}^2 - \frac{1}{p} \left(\sum_j Y_{.j} \right)^2 \right] =$$

$$= k \sum_j Y_{.j}^2 - k \frac{1}{p} p^2 Y_{..}^2 = k \sum_j Y_{.j}^2 - kp Y_{..}^2 = k \sum_j Y_{.j}^2 - \frac{1}{n} \left(\sum_i \sum_j Y_{ij} \right)^2$$

$$\tilde{R}_1^2 - R_0^2 = k \sum_j Y_{.j}^2 - \frac{1}{n} \left(\sum_i \sum_j Y_{ij} \right)^2$$

Απλοποιήσεις

ΠΙΝΑΚΑΣ ΥΠΟΛΟΓΙΣΜΟΥ ΑΝΟΝΑ ΜΕ 2 ΠΑΡΑΓΟΝΤΕΣ

A	B	B ₁	B ₂	B _p	Άθροισμα γραμμών	Μέσοι γραμμών	Τετρ. γραμμών	Άθροισμα Τετραγ. γραμμών
A ₁		Y ₁₁	Y ₁₂	Y _{1p}	$\sum_j^p Y_{1j}$	Y _{1.}	Y _{1.} ²	$\sum_j Y_{1j}^2$
A ₂		Y ₂₁	Y ₂₂	Y _{2p}	$\sum_j^p Y_{2j}$	Y _{2.}	Y _{2.} ²	$\sum_j Y_{2j}^2$
⋮		⋮	⋮	⋮	⋮	⋮	⋮	⋮
A _κ		Y _{κ1}	Y _{κ2}	Y _{κp}	$\sum_j^p Y_{kj}$	Y _{κ.}	Y _{κ.} ²	$\sum_j Y_{kj}^2$
Άθροισμα Στηλών		$\sum_i^k Y_{i1}$	$\sum_i^k Y_{i2}$	$\sum_i^k Y_{ip}$	$\sum_i^k \sum_j^p Y_{ij}$	$\sum_i Y_{i.}$	$\sum_i Y_{i.}^2$	↓
Μέσοι Στηλών		Y _{.1}	Y _{.2}	Y _{.p}	$\sum_j^p Y_{.j}$	Y _{..}		
Τετρ. Στηλών		Y _{.1} ²	Y _{.2} ²	Y _{.p} ²	$\sum_j^p Y_{.j}^2$			
Άθροισμα Τετραγ. Στηλών		$\sum_i^k Y_{i1}^2$	$\sum_i^k Y_{i2}^2$	$\sum_i^k Y_{ip}^2$				$\sum_i^k \sum_j^p Y_{ij}^2$

Παράδειγμα

ΠΙΝΑΚΑΣ ΥΠΟΛΟΓΙΣΜΟΥ ΑΝΟΝΑ ΜΕ 2 ΠΑΡΑΓΟΝΤΕΣ

Ειδος τροφης ομάδα	B ₁	B ₂	B ₃	Άθροισμα γραμμών	Μέσοι γραμμών	Τετρ. γραμμών	Άθροισμα Τετραγ. γραμμών
A ₁	7	14	8.5	29.5	9.83	96.62	317.25
A ₂	16	15	16.5	48	16	256	768.5
A ₃	10.5	15	9.5	35	11.67	136.18	425.5
A ₄	13.5	21	13.5	48	16	256	805.5
Άθροισμα Στηλών	47	65.5	48	160.5	53.5	744.81	
Μέσοι Στηλών	11.75	16.36	12	40.11	13.38		
Τετρ. Στηλών	138.06	267.64	144	549.71			
Άθροισμα Τετραγ. Στηλών	597.5	1102.25	617				2316.75

Παράδειγμα

$$\sum_{i=1}^4 \sum_{j=1}^3 (Y_{ij} - Y_{..})^2 = \sum_{i=1}^4 \sum_{j=1}^3 Y_{ij}^2 - \frac{1}{n} \left(\sum_{i=1}^4 \sum_{j=1}^3 Y_{ij} \right)^2 = 2316.75 - \frac{1}{12} (160.5)^2 = 170.06$$

$$R_1^2 - R_0^2 = \rho \sum_i^k Y_{i.}^2 - \frac{1}{n} \left(\sum_i^k \sum_j^p Y_{ij} \right)^2 = 3 \sum_i^4 Y_{i.}^2 - \frac{1}{12} \left(\sum_i^4 \sum_j^3 Y_{ij} \right)^2 = \dots = 87.76$$

$$\tilde{R}_1^2 - R_0^2 = k \sum_j^p Y_{.j}^2 - \frac{1}{n} \left(\sum_i^k \sum_j^p Y_{ij} \right)^2 = 4 \sum_j^3 Y_{.j}^2 - \frac{1}{12} \left(\sum_i^4 \sum_j^3 Y_{ij} \right)^2 = \dots = 30.13$$

Παράδειγμα

Πηγή μεταβλητότητας	Άθροισμα τετραγώνων	Βαθμοί ελευθερίας	Μέσο άθροισμα τετραγώνων	F
Απόκλιση από την H_A (μεταξύ δειγμάτων)	87.76	3	29.25	$F_A=5.82$
Απόκλιση από την H_B (μεταξύ δειγμάτων)	52.16	2	26.08	$F_B=5.19$
Κατάλοιπα (εντός δειγμάτων)	30.13	6	5.022	
Σύνολο	170.06	11		

$F_A=5.82 > 4.76$ άρα απορρίπτουμε την H_A

$F_B=5.19 > 5.14$ άρα απορρίπτουμε την H_B