

Metodi statistici per l'analisi dei dati

Introduzione al Factorial Design

1

Factorial designs – Definizione

Factorial designs


- Per "factorial design" si intende una campagna sperimentale in cui le misure sono eseguite **per tutte le possibili combinazioni** dei livelli dei fattori.
- Esempio:
 - 2 fattori A e B
 - a livelli (trattamenti) del fattore A
 - b livelli (trattamenti) del fattore B
 - Si eseguono $a \cdot b$ combinazioni dei trattamenti
- Quando i fattori sono combinati in questo modo, sono spesso definiti come **incrociati**.

2

Factorial designs – Definizione

Factorial designs

- **Esempio:** Si consideri il factorial design in figura
- Esperimento fattoriale con **due** fattori entrambi a **due** livelli



Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

3

3

Factorial designs – Definizioni di base

Factorial designs

- Il disegno sperimentale preso in considerazione è il più semplice possibile.
 - i due distinti livelli sono definiti "**low**" e "**high**" e definiti anche con i simboli "-" e "+", rispettivamente.
- Si definisce **effetto principale del livello** la variazione nella risposta prodotta da una variazione del livello del fattore.
- Nel caso in esame si può calcolare come la differenza tra la risposta media al livello A e la risposta media al livello B.

$$A = \frac{52 + 40}{2} - \frac{30 + 20}{2} = 21 \quad B = \frac{52 + 30}{2} - \frac{20 + 40}{2} = 11$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020


4

4

Factorial designs – Definizioni preliminari: presenza di interazioni

Factorial designs

- In alcuni casi la determinazione dell'effetto principale non è sufficiente. Si consideri ad esempio il seguente esperimento



Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

5

5

Factorial designs – Definizioni preliminari: presenza di interazioni

Factorial designs

- È possibile calcolare, ancora gli effetti principali:

$$A = \frac{50+12}{2} - \frac{40+20}{2} = 1 \quad B = \frac{40+12}{2} - \frac{20+50}{2} = -9$$

- ma, si può notare come:
 - a livello più basso di B (B^-), l'effetto di A sia

$$A(B^-) = 50 - 20 = 30 > 0$$

- al livello più alto (B^+) si ha invece

$$A(B^+) = 12 - 40 = -28 < 0$$

- È chiara la presenza di **interazioni** tra i due fattori.

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

6

6

Factorial designs – Definizioni preliminari: presenza di interazioni

Factorial designs

- L'interazione presente può essere quantificata come la differenza **media** dei due effetti di A in corrispondenza di B⁺ e B⁻

$$AB = \frac{A(B^+) - A(B^-)}{2} = \frac{-28 - 30}{2} = -29$$

- La presenza di interazioni può essere apprezzata anche per via grafica:



Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

7

7

Factorial designs – Definizioni preliminari: presenza di interazioni

Factorial designs

- Si può essere più dettagliati nel caso in cui i fattori siano **quantitativi** (es: temperatura, pressione, tempo etc.).
- In questo caso si può scrivere un modello di **regressione**:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \varepsilon$$

- dove:
 - y è la risposta misurata
 - x_1 e x_2 rappresentano i fattori
 - **N.B.** In genere, si suggerisce di lavorare con variabili **scalate**: $x_i \in [-1, 1]$
 - β sono i parametri da determinare
 - ε è l'errore sperimentale

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

8

8

Factorial designs – Definizioni preliminari: presenza di interazioni

Factorial designs

- Nel caso dell'esempio (estremamente **banale: due misure per due livelli**) la stima dei coefficienti è immediata:
 - I coefficienti β_i ($i \neq 0$) sono stimati come la metà dei valori dei corrispondenti effetti principali
 - Il coefficiente di interazione β_{12} corrisponde alla metà dell'effetto di interazione
 - L'intercetta β_0 è la media di tutte le risposte.

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

9

9



Factorial designs – Definizioni preliminari: presenza di interazioni

Factorial designs

- Caso 1: Stima modello di regressione

$$\hat{y} = 35.5 + 10.5x_1 + 5.5x_2 + 0.5x_1x_2$$

Il termine di interazione può essere trascurato



Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

10

10


Factorial designs – Definizioni preliminari: presenza di interazioni

Factorial designs


- Caso 2: Stima modello di regressione

$$\hat{y} = 30.5 + 0.5x_1 - 4.5x_2 - 14.5x_1x_2$$

Il termine di interazione **non** può essere trascurato



La presenza di interazioni nei fattori porta ad una **curvatura** nel modello



Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

11

11

Factorial design a due Fattori –Esempio

Factorial designs

- Un ricercatore sta studiando un nuovo enzima in grado di degradare un dato substrato. In particolare vuole investigare la resa al variare di
 - Temperatura di esercizio (tre diversi livelli: 15°C, 70°C, 125°C)
 - supporto specifico usato (tre diverse formulazioni)
- Per ogni combinazione delle condizioni sperimentali sono replicate 4 misure sperimentali

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

12

12

Factorial design a due Fattori –Esempio

Factorial designs

Tipo di supporto	Temperatura					
	15		70		125	
1	130	155	34	40	30	70
	74	180	80	75	82	58
2	150	188	136	122	25	70
	159	126	106	115	58	45
3	138	110	174	120	96	104
	168	160	150	139	82	60

- **Domande:**
- Quali sono gli effetti della temperatura e del supporto sulla resa?
- Esiste una scelta ottimale del supporto che garantisca una resa uniforme rispetto alla temperatura?

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

13

13

Factorial design a due Fattori – Definizioni

Factorial designs

- Sia
 Y_{ijk}
- la generica misura sperimentale in corrispondenza di:
 - livello i -esimo del fattore A con $i=1,2, \dots, a$
 - livello j -esimo del fattore B con $j=1,2, \dots, b$
 - replica k -esima della combinazione sperimentale con $k=1,2, \dots, n$
- Il numero di misure sperimentali totali è quindi $N=n \cdot a \cdot b$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

14

14


Factorial design a due Fattori – Definizioni

Factorial designs

- **Modello statistico a effetti** per il disegno fattoriale a due fattori:

$$y_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + \varepsilon_{ijk}$$

$$\begin{cases} i = 1, 2, \dots, a \\ j = 1, 2, \dots, b \\ k = 1, 2, \dots, n \end{cases}$$



Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

15

15

Factorial design a due Fattori – Definizioni

Factorial designs

- Per avere una soluzione univoca, è necessario porre dei vincoli.
- Come già visto nel caso del singolo fattore:

$$\sum_{i=1}^a \tau_i = 0 \quad \sum_{j=1}^b \beta_j = 0$$

- Anche le interazioni sono soggette a vincolo

$$\sum_{i=1}^a (\tau\beta)_{ij} = \sum_{j=1}^b (\tau\beta)_{ij} = 0$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

16

16

Factorial design a due Fattori – Definizioni

Factorial designs

- L'ipotesi nulla da verificare è ancora sulla eguaglianza degli effetti dei trattamenti:
- Rispetto al fattore A:

$$H_0: \tau_1 = \tau_2 = \dots = \tau_a = 0$$

$$H_1: \tau_i \neq 0 \text{ per almeno un } i$$

- e rispetto al fattore B:

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

$$H_1: \beta_j \neq 0 \text{ per almeno un } j$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

17

17

Factorial design a due Fattori – Definizioni

Factorial designs

- Inoltre, si può essere interessati ad una eventuale interazione tra fattori:

$$H_0: (\tau\beta)_{ij} = 0 \text{ per tutte le coppie } (i,j)$$

$$H_1: \tau_i \neq 0 \text{ per almeno un } (i,j)$$

- Tali ipotesi possono essere investigate con un **test analisi della varianza a due fattori**

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

18

18

Analisi della varianza a due fattori – Procedura

Factorial designs

- Definizioni grandezze utili per la statistica 1/2

$$y_{i\bullet\bullet} = \sum_{j=1}^b \sum_{k=1}^n y_{ijk} \quad \rightarrow \quad \text{Totale osservazioni per il trattamento i-esimo
Fattore A}$$

$$y_{\bullet j\bullet} = \sum_{i=1}^a \sum_{k=1}^n y_{ijk} \quad \rightarrow \quad \text{Totale osservazioni per il trattamento j-esimo
Fattore B}$$

$$y_{ij\bullet} = \sum_{k=1}^n y_{ijk} \quad \rightarrow \quad \text{Totale osservazioni nella cella (i,j)}$$

$$y_{\bullet\bullet\bullet} = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n y_{ijk} \quad \rightarrow \quad \text{Totale di tutte le
osservazioni}$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

19

19

Analisi della varianza a due fattori – Procedura

Factorial designs

- Definizioni grandezze utili per la statistica 2/2

$$\bar{y}_{i\bullet\bullet} = \frac{y_{i\bullet\bullet}}{bn} \quad \rightarrow \quad \text{Media osservazioni i-esimo Fattore A}$$

$$\bar{y}_{\bullet j\bullet} = \frac{y_{\bullet j\bullet}}{an} \quad \rightarrow \quad \text{Media osservazioni j-esimo Fattore B}$$

$$\bar{y}_{ij\bullet} = \frac{y_{ij\bullet}}{n} \quad \rightarrow \quad \text{Media osservazioni cella (i,j)}$$

$$\bar{y}_{\bullet\bullet\bullet} = \frac{y_{\bullet\bullet\bullet}}{abn} \quad \rightarrow \quad \text{"Grande" Media per tutte le osservazioni}$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

20

20

Analisi della varianza a due fattori – Procedura

Factorial designs

- La somma corretta dei quadrati può essere scritta come:

$$SST = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{...})^2$$

$$= \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n [(\bar{y}_{i..} - \bar{y}_{...}) + (\bar{y}_{.j.} - \bar{y}_{...}) + (\bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...}) + (y_{ijk} - \bar{y}_{ij.})]^2$$

- Espandendo il secondo membro e verificando che i prodotti misti si annullano

$$SST = bn \sum_{i=1}^a (\bar{y}_{i..} - \bar{y}_{...})^2 + an \sum_{j=1}^b (\bar{y}_{.j.} - \bar{y}_{...})^2 +$$

$$n \sum_{i=1}^a \sum_{j=1}^b (\bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...})^2 + \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{ij.})^2$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

21

21

Analisi della varianza a due fattori – Procedura

Factorial designs

- Interpretazione dei termini

Termine	Effetto	Gradi di libertà
$SSA = bn \sum_{i=1}^a (\bar{y}_{i..} - \bar{y}_{...})^2$	A	a-1
$SSB = an \sum_{j=1}^b (\bar{y}_{.j.} - \bar{y}_{...})^2$	B	b-1
$SSAB = n \sum_{i=1}^a \sum_{j=1}^b (\bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{...})^2$	Interazioni AB	(a-1)(b-1)
$SSE = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{ij.})^2$	Errore	ab(n-1)
$SST = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{...})^2$	Totale	abn-1

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

22

22

Analisi della varianza a due fattori – Procedura

Factorial designs

- Tabella ANOVA per il caso di due fattori

Sorgente di variazione	Somma dei quadrati	Gradi di libertà	Varianza	F ₀
Trattamento A	SSA	a-1	MSA=SSA/(a-1)	MSA/MSE
Trattamento B	SSB	b-1	MSB=SSB/(b-1)	MSB/MSE
Interazione	SSAB	(a-1)(b-1)	MSAB=SSAB/(a-1)(b-1)	MSAB/MSE
Errore	SSE	ab(n-1)	MSE=SSE/(ab(n-1))	
Totale	SST	abn-1		

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

23

23

ANOVA a 2 fattori– Formule per il calcolo manuale

Factorial designs

- La procedura ANOVA è in genere eseguita con software specifici
- Nel caso si debba procedere al calcolo manuale può essere conveniente ricorrere ad alcune formule semplificative per le somme dei quadrati:

$$SST = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n y_{ijk}^2 - \frac{y_{\dots}^2}{abn}$$

$$SSA = \frac{1}{bn} \sum_{i=1}^a y_{i\cdot\cdot}^2 - \frac{y_{\dots}^2}{abn}$$

$$SSB = \frac{1}{an} \sum_{j=1}^b y_{\cdot j\cdot}^2 - \frac{y_{\dots}^2}{abn}$$

$$SS_{Subtotal} = \frac{1}{n} \sum_{i=1}^a \sum_{j=1}^b y_{ij\cdot}^2 - \frac{y_{\dots}^2}{abn}$$

$$SSAB = SS_{Subtotal} - SSA - SSB$$

$$SSE = SST - SSAB - SSA - SSB = SST - SS_{Subtotal}$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

24

24

ANOVA a 2 fattori– Esercizio

Factorial designs

- Esempio di applicazione – sintesi enzimi

Tipo di supporto	Temperatura									$y_{i..}$
	15			70			125			
1	130	155	539	34	40	229	30	70	230	998
	74	180		80	75		82	58		
2	150	188	623	136	122	479	25	70	198	1300
	159	126		106	115		58	45		
3	138	110	576	174	120	583	96	104	342	1501
	168	160		150	139		82	60		
$y_{.j}$			1738			1291			770	$y_{...}=3799$

- I totali delle singole celle sono i numeri cerchiati

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

25

25

ANOVA a 2 fattori– Esercizio

Factorial designs

- Applicando le formule si perviene a

$$SST = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n y_{ijk}^2 - \frac{y_{...}^2}{abn} = (130)^2 + (155)^2 + \dots + (60)^2 - \frac{(3799)^2}{36} = 77,646.97$$

$$SSA = \frac{1}{bn} \sum_{i=1}^a y_{i..}^2 - \frac{y_{...}^2}{abn} = \frac{1}{(3)(4)} [(998)^2 + (1300)^2 + (1501)^2] - \frac{(3799)^2}{36} = 10,683.72$$

$$SSB = \frac{1}{an} \sum_{j=1}^b y_{.j.}^2 - \frac{y_{...}^2}{abn} = \frac{1}{(3)(4)} [(1738)^2 + (1291)^2 + (770)^2] - \frac{(3799)^2}{36} = 39,118.72$$

$$SSAB = \frac{1}{n} \sum_{i=1}^a \sum_{j=1}^b y_{ij.}^2 - \frac{y_{...}^2}{abn} - SSA - SSB = 9613.78$$

$$SSE = SST - SSA - SSB - SSAB = 18,230.75$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

26

26

ANOVA a 2 fattori– Esercizio

Factorial designs

- Tabella per l'esempio

Sorgente di variazione	Somma dei quadrati	Gradi di libertà	Varianza	F ₀	P-value
Supporto	10,683.72	2	5,341.86	7.91	0.0020
Temperatura	39,118.72	2	19,559.36)	28.97	0.0001
Interazione	9,613.78	4	2,403.44	3.56	0.0186
Errore	18,230.75	27	675.21		
Totale	77,646.97	35			

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020


27

27

ANOVA a 2 fattori– Esercizio

Factorial designs

- Rappresentazione delle rese (medie) al variare dei fattori



- La **perdita di parallelismo** tra le rette è un indizio di **presenza di interazione**
- Resa migliore a basse temperature
- Su questo aspetto il supporto 3 risulta il supporto che garantisce rese migliori

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

28

28

ANOVA a 2 fattori– Esercizio Confronti multipli

Factorial designs

- Una volta concluso che esistono differenze significative tra le colonne e le righe, ha senso confrontare le **single righe/colonne** per individuare le differenze specifiche.
- A tal proposito può essere usato il **test di Tukey**.
- **Da rimarcare che la presenza di interazioni non permette uno studio analogo al caso del singolo fattore.**
- Procedura possibile:
 - Si fissa uno specifico livello del fattore B e si applica il test alle medie del fattore A al dato livello.
 - Esempio: applicazione del test al solo livello 2 ($T=70^{\circ}\text{C}$)
 - Stima usata per la varianza: MSE (assunzione che la varianza dell'errore sia uniforme per tutte le combinazioni dei trattamenti)

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

29

29

ANOVA a 2 fattori– Esercizio Confronti multipli

Factorial designs

- Medie dei supporti a 70°C
 - $\bar{y}_{12\bullet} = 57.25$ (supporto 1)
 - $\bar{y}_{22\bullet} = 119.75$ (supporto 2)
 - $\bar{y}_{32\bullet} = 145.75$ (supporto 3)
- Inoltre, si può calcolare il valore critico:
$$T_{0.05} = q_{0.05}(3,27) \sqrt{\frac{MSE}{n}} = 3.50 \sqrt{\frac{675.21}{4}} = 45.47$$
- dove $q_{0.05}(3,27)=3.50$ è disponibile da tabelle.

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

30

30

ANOVA a 2 fattori– Esercizio Confronti multipli

Factorial designs

- Il confronto a coppie porta ai seguenti risultati:

$$3 \text{ vs. } 1 \quad 145.75 - 57.25 = 88.50 > T_{0.05} = 45.47$$

$$3 \text{ vs. } 2 \quad 145.75 - 119.75 = 26.00 < T_{0.05} = 45.47$$

$$2 \text{ vs. } 1 \quad 119.75 - 57.25 = 62.50 > T_{0.05} = 45.47$$

Si può concludere che il **supporto di tipo 1** differisce in maniera significativa dagli altri due ed ha una performance significativamente inferiore

31


ANOVA a 2 fattori– Esercizio Analisi dei residui

Factorial designs

- Per definizione:

$$e_{ijk} = y_{ijk} - \hat{y}_{ijk} = y_{ijk} - \bar{y}_{ij\bullet} \quad (\hat{y}_{ijk} \equiv \bar{y}_{ij\bullet})$$

- **Rappresentazione su carta probabilistica**





- Non si evidenziano particolari difetti nei dati
- Il residuo $e_{ijk} \sim -60$, (cui corrisponde un residuo standardizzato $d_{ijk} \sim -2.34$) nonostante sia molto grande in valore assoluto è comunque ancora ammissibile

32

ANOVA a 2 fattori– Esercizio Analisi dei residui

Factorial designs

- La combinazione **supporto 1** e **basse temperatura** presenta una maggiore varianza: tale combinazione *pare* produrre maggiore incertezza nella resa



Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

33

33

Factorial designs – Stima dei parametri del modello

Factorial designs

- I parametri nel modello a effetti per un disegno sperimentale a due fattori

$$y_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + \varepsilon_{ijk}$$

- possono essere stimati per mezzo del **metodo dei minimi quadrati**.

Modello a
(ab+b+a+1)
parametri



Richiede la scrittura di
(ab+b+a+1)
equazioni normali

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

34

34

Disegni fattoriali – Stima dei parametri del modello

Factorial designs

- Scrittura equazioni normali

1 equazione:

$$\mu: \quad abn\hat{\mu} + bn\sum_{i=1}^a \hat{\tau}_i + an\sum_{j=1}^b \hat{\beta}_j + n\sum_{i=1}^a \sum_{j=1}^b (\hat{i}_{\tau\beta})_{ij} = y_{\bullet\bullet}$$

a equazioni:

$$\tau_i: \quad bn\hat{\mu} + bn\hat{\tau}_i + n\sum_{j=1}^b \hat{\beta}_j + n\sum_{j=1}^b (\hat{i}_{\tau\beta})_{ij} = y_{i\bullet} \quad i=1, \dots, a$$

b equazioni:

$$\beta_j: \quad an\hat{\mu} + n\sum_{i=1}^a \hat{\tau}_i + an\hat{\beta}_j + n\sum_{i=1}^a (\hat{i}_{\tau\beta})_{ij} = y_{\bullet j}, \quad j=1, \dots, b$$

ab equazioni:

$$(\tau\beta)_{ij}: \quad n\hat{\mu} + n\hat{\tau}_i + n\hat{\beta}_j + n(\hat{i}_{\tau\beta})_{ij} = y_{ij\bullet}, \quad \begin{cases} i=1, 2, \dots, a \\ j=1, 2, \dots, b \end{cases}$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

35

35

Factoriali designs – Stima dei parametri del modello

Factorial designs

- Ci sono $(a+b+1)$ dipendenze lineari nel sistema di equazioni.
- Non esiste soluzione univoca a meno che non si fissano dei vincoli. Ad esempio:

$$\begin{array}{ll} \sum_{i=1}^a \hat{\tau}_i = 0 & \mathbf{1} \text{ vincolo} \\ \sum_{j=1}^b \hat{\beta}_j = 0 & \mathbf{1} \text{ vincolo} \\ \sum_{i=1}^a (\hat{i}_{\tau\beta})_{ij} = 0 \quad j=1, 2, \dots, b & \mathbf{a+b-1} \text{ vincoli} \\ \sum_{j=1}^b (\hat{i}_{\tau\beta})_{ij} = 0 \quad i=1, 2, \dots, a & \mathbf{a+b-1} \text{ vincoli} \end{array} \left. \vphantom{\begin{array}{l} \sum_{i=1}^a \hat{\tau}_i = 0 \\ \sum_{j=1}^b \hat{\beta}_j = 0 \\ \sum_{i=1}^a (\hat{i}_{\tau\beta})_{ij} = 0 \\ \sum_{j=1}^b (\hat{i}_{\tau\beta})_{ij} = 0 \end{array}} \right\} \mathbf{a+b+1} \text{ vincoli}$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

36

36

Factoriali designs – Stima dei parametri del modello

Factorial designs

- Applicando i vincoli le equazioni normali ammettono soluzione:

$$\hat{\mu} = \bar{y}_{\dots}$$

$$\hat{\tau}_i = \bar{y}_{i..} - \bar{y}_{\dots}, \quad i = 1, 2, \dots, a$$

$$\hat{\beta}_j = \bar{y}_{.j.} - \bar{y}_{\dots}, \quad j = 1, 2, \dots, b$$

$$\left(\hat{i}_{\tau\beta}\right)_{ij} = \bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{\dots} \quad \begin{cases} i = 1, 2, \dots, a \\ j = 1, 2, \dots, b \end{cases}$$

37

Factoriali designs – Stima dei parametri del modello

Factorial designs

- Usando le equazioni precedenti è possibile trovare i **valori predetti dal modello**

$$\begin{aligned} \hat{y}_{ijk} &= \mu + \hat{\tau}_i + \hat{\beta}_j + \left(\hat{i}_{\tau\beta}\right)_{ij} \\ &= \bar{y}_{\dots} + (\bar{y}_{i..} - \bar{y}_{\dots}) + (\bar{y}_{.j.} - \bar{y}_{\dots}) + (\bar{y}_{ij.} - \bar{y}_{i..} - \bar{y}_{.j.} + \bar{y}_{\dots}) \\ &= \bar{y}_{ij.} \end{aligned}$$

38

Assenza di interazioni in modelli a due fattori

Factorial designs

- In alcuni casi, è possibile descrivere i dati con un modello a due fattori senza interazioni.

$$y_{ijk} = \mu + \tau_i + \beta_j + \varepsilon_{ijk} \quad \begin{cases} i = 1, 2, \dots, a \\ j = 1, 2, \dots, b \\ k = 1, 2, \dots, n \end{cases}$$

- N.B. Tale modello richiede estrema cautela nella sua analisi, dato che come ampiamente discusso, le interazioni tra fattori possono essere importanti.
- Il modello senza interazioni ha una risoluzione immediata.

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

39

39

Assenza di interazioni in modelli a due fattori

Factorial designs

- Da notare che il vecchio termine di interazione è andato a sommarsi alla somma degli errori

Sorgente di variazione	Somma dei quadrati	Gradi di libertà	Varianza	F_0	P-value
Supporto	10,683.72	2	5,341.86	5.95	0.0065
Trattamento B	39,118.72	2	19,559.36)	21.78	$2.33 \cdot 10^{-6}$
Errore	27,844.52	31	898.21		
Totale	77,646.97	35			

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

40

40

Assenza di interazioni in modelli a due fattori

Factorial designs

- Come precedentemente discusso, si nota che i due effetti principali sono significativi.
- Anche in questo caso si possono calcolare i residui.
- I valori previsti dal modello in questo caso sono dati dalla espressione:

$$\begin{aligned}\hat{y}_{ijk} &= \mu + \hat{\tau}_i + \hat{\beta}_j \\ &= \bar{y}_{\dots} + (\bar{y}_{i\dots} - \bar{y}_{\dots}) + (\bar{y}_{\dots j} - \bar{y}_{\dots}) \\ &= \bar{y}_{i\dots} + \bar{y}_{\dots j} - \bar{y}_{\dots}\end{aligned}$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020


41

41

Assenza di interazioni in modelli a due fattori

Factorial designs

- Analisi dei residui



- La presenza di una struttura nei residui è plausibilmente dovuta alla necessità del termine di interazione nel modello.

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

42

42

Modelli a due fattori con una osservazione per cella

Factorial designs

- Caso in cui si effettua una osservazione per combinazione delle condizioni sperimentali.
- La **varianza non è più stimabile** come nel caso generale, dato che non si può ricorrere alla espressione:

$$MSE = \frac{SSE}{ab(n-1)} = \frac{1}{ab(n-1)} \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n (y_{ijk} - \bar{y}_{ij\bullet})^2$$

- È possibile comunque considerare un modello con la presenza dei soli effetti principali.

$$y_{ij} = \mu + \tau_i + \beta_j + \varepsilon_{ij} \quad \begin{cases} i = 1, 2, \dots, a \\ j = 1, 2, \dots, b \end{cases}$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

43

43

Modelli a due fattori con una osservazione per cella

Factorial designs

- In questo caso è possibile scrivere la tabella ANOVA

Sorgente di variazione	Somma dei quadrati	Gradi di libertà	Varianza	F ₀
Trattamento A	SSA	a-1	MSA=SSA/(a-1)	<i>MSA/MSE</i>
Trattamento B	SSB	b-1	MSB=SSB/(b-1)	<i>MSB/MSE</i>
Errore	SSE=SST-SSA-SSB	(a-1)(b-1)	MSE=SSE/((a-1)(b-1))	
Totale	SST	ab-1		

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

44

44

Modelli a due fattori con una osservazione per cella

Factorial designs

- Per stabilire se le interazioni sono presenti o meno, si può ricorrere ad un test sviluppato da Tukey (1949).
- La procedura assume che il termine di interazione sia di una forma particolarmente semplice:

$$(i_{\tau\beta})_{ij} = \gamma\tau_i\beta_j$$

- Si può considerare un test statistico che partiziona la somma dei quadrati dei residui in due termini
 - Una componente che descrive il contributo non additivo (termine di interazione) che viene formulato sulla base del tipo di interazione assunto (1 grado di libertà)
 - Il resto della somma dei residui

45

Modelli a due fattori con una osservazione per cella

Factorial designs

- Somma dei quadrati dovuta alla «non additività» (1 gdl):

$$SSN = \frac{1}{ab} \left[\sum_{i=1}^a \sum_{j=1}^b y_{ij} y_{i\bullet} y_{\bullet j} - y_{\bullet\bullet} \left(SSA + SSB + \frac{y_{\bullet\bullet}^2}{ab} \right) \right]^2$$

- Somma degli errori ad $(a-1)(b-1)-1$ gdl

$$SSE = SS_{\text{Residual}} - SSN \quad SS_{\text{Residual}} = SST - SSA - SSB$$

- Per testare l'interazione si deve valutare la statistica:

$$F_0 = \frac{SSN/1}{SSE / ((a-1)(b-1)-1)}$$

46

Modelli a due fattori con una osservazione per cella – Esempio

Factorial designs

- Le impurità presenti in un prodotto chimico possono essere dovute a due fattori:
 - temperatura
 - pressione
- I dati provenienti da una campagna sperimentale con una sola replicazione sono riportati in tabella:

Temperatura	Pressione					$y_{i\cdot}$
	25	30	35	40	45	
100	5	4	6	3	5	23
125	3	1	4	2	3	13
150	1	1	3	1	2	8
$y_{\cdot j}$	9	6	13	6	10	$y_{\cdot\cdot}=44$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

47

47

Modelli a due fattori con una osservazione per cella – Esempio

Factorial designs

- Le somme dei quadrati sono

$$SSA = \frac{1}{b} \sum_{i=1}^a y_{i\cdot}^2 - \frac{y_{\cdot\cdot}^2}{ab} = 23.33$$

$$SSB = \frac{1}{a} \sum_{j=1}^b y_{\cdot j}^2 - \frac{y_{\cdot\cdot}^2}{ab} = 11.60$$

$$SST = \sum_{i=1}^a \sum_{j=1}^b y_{ij}^2 - \frac{y_{\cdot\cdot}^2}{ab} = 36.93$$

$$SS_{\text{Residuals}} = SST - SSA - SSB = 2.00$$

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

48

48

Modelli a due fattori con una osservazione per cella – Esempio

Factorial designs

- La somma dei quadrati **SSN** per la **non additività** è calcolata come da equazione:

$$SSN = \frac{1}{ab} \left[\sum_{i=1}^a \sum_{j=1}^b y_{ij} y_{i\bullet} y_{\bullet j} - y_{\bullet\bullet} \left(SSA + SSB + \frac{y_{\bullet\bullet}^2}{ab} \right) \right]^2 = 0.0985$$

- Da cui è possibile ricavare la somma dei quadrati degli errori come:

$$SSE = SS_{Residuals} - SSN = 2.0 - 0.0985 = 1.9015$$

- Come si può vedere dalla tabella successiva, l'ipotesi di mancanza di interazioni sembra ragionevole.

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

49

49

Modelli a due fattori con una osservazione per cella – Esempio

Factorial designs

- I risultati possono essere sintetizzati nella tabella ANOVA

Sorgente di variazione	Somma dei quadrati	Gradi di libertà	Varianza	F ₀	P-value
(A) Temperatura	SSA=23.33	a-1=2	MSA=SSA/(a-1) =11.67	42.97	0.0001
B (Pressione)	SSB=11.60	b-1=4	MSB=SSB/(b-1) =2.90	10.68	0.0042
«Interazione»	SSN=0.0985	1	MSN=SSN/1 =0.0985	0.36	0.5674
Errore	SSE = SS _{Res} - SSN=1.90	(a-1)(b-1)-1 =7	MSE=SSE/((a-1)(b-1)-1)=0.2716		
Totale	SST	ab-1=14			

Metodi statistici per l'analisi dei dati
10-14 febbraio 2020

50

50