Allgemeines Lineares Modell

BSc Psychologie SoSe 2023

Prof. Dr. Dirk Ostwald

(10) Einfaktorielle Varianzanalyse

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Selbstkontrollfragen

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Selbstkontrollfragen

Zwei oder mehr Gruppen (Stichproben) randomisierter experimenteller Einheiten.

Annahme der unabhängigen und identischen Normalverteilung $N(\mu_i, \sigma^2)$ der Daten.

μ_i und σ^2 unbekannt.

Absicht des inferentiellen Testens der Nullhypothese identischer Gruppenerwartungswerte.

$$\Downarrow$$

Generalisierung des Zweistichproben-T-Tests bei unabhängigen Stichproben mit einfacher Nullhypothese für mehr als zwei Stichproben

Anwendungsbeispiel

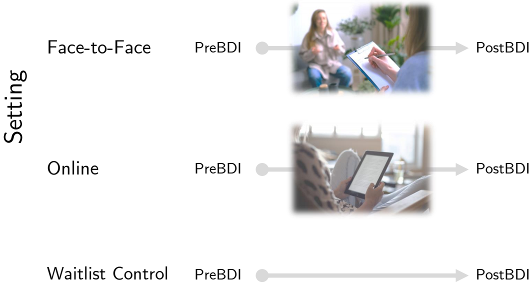

PrePost-BDI Differenzwertanalyse für drei Gruppen von Patient:innen (F2F, ONL, WLC)

- Inferentielle Evidenz für Gruppenerwartungswertunterschiede?
- Evidenz für unterschiedliche Therapiewirksamkeit?

Anwendungsszenario

Dateneinlesen

```
fname        = file.path(getwd(), "10_Daten", "10_Einfaktorielle_Varianzanalyse_Daten.csv")
D            = read.table(fname, sep = ",", header = TRUE)
```

	ID	Setting	PreBDI	PostBDI	dBDI
1	1	F2F	29	25	4
2	2	F2F	32	31	1
3	3	F2F	28	26	2
4	4	F2F	36	26	10
5	5	F2F	32	27	5
6	6	F2F	28	29	-1
7	7	F2F	33	27	6
8	8	F2F	33	27	6
9	9	F2F	33	25	8
10	10	F2F	30	26	4
41	41	ONL	31	27	4
42	42	ONL	31	25	6
43	43	ONL	34	29	5
44	44	ONL	34	29	5
45	45	ONL	30	24	6
46	46	ONL	30	33	-3
47	47	ONL	33	25	8
48	48	ONL	34	21	13
49	49	ONL	32	26	6
50	50	ONL	35	27	8
81	81	WLC	27	31	-4
82	82	WLC	29	35	-6
83	83	WLC	33	35	-2
84	84	WLC	24	29	-5
85	85	WLC	31	23	8
86	86	WLC	30	38	-8
87	87	WLC	32	32	0
88	88	WLC	28	32	-4
89	89	WLC	30	30	0
90	90	WLC	30	32	-2

Boxplot

```
# Dateneinlesen
fname       = file.path(getwd(), "10_Daten", "10_Einfaktorielle_Varianzanalyse_Daten.csv")
D           = read.table(fname, sep = ",", header = TRUE)

# Abbildungsparameter
par(                                        # für Details siehe ?par
family      = "sans",                       # Serif-freier Fonttyp
pty         = "m",                          # Maximale Abbildungsregion
bty         = "l",                          # L förmige Box
lwd         = 1,                            # Liniendicke
las         = 1,                            # Horizontale Achsenbeschriftung
font.main   = 1,                            # Non-Bold Titel
cex         = 1,                            # Textvergrößerungsfaktor
cex.main    = 1.2)                          # Titeltextvergrößerungsfaktor

# Boxplot
boxplot(dBDI ~ Setting, data = D)           # BDI ~ Setting enkodiert die Datengruppierung

# PDF Speicherung
dev.copy2pdf(
file        = file.path(getwd(), "10_Abbildungen", "alm_10_aov_1_boxplot.pdf"),
width       = 7,
height      = 4)
```

Boxplot

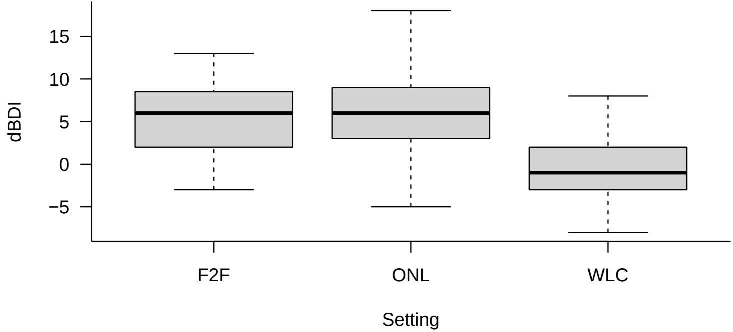

Balkendiagramm

```
# Datenselektion
fname       = file.path(getwd(), "10_Daten", "10_Einfaktorielle_Varianzanalyse_Daten.csv")
D           = read.table(fname, sep = ",", header = TRUE)

# Datenselektion
A           = data.frame(                           # neuer Dataframe
              F2F = D$dBDI[D$Setting == "F2F"],     # F2F BDI Daten
              ONL = D$dBDI[D$Setting == "ONL"],     # ONL BDI Daten
              WLC = D$dBDI[D$Setting == "WLC"])     # WLC BDI Daten

# Deskriptive Statistiken
groupmeans  = colMeans(A)                           # Gruppenmittelwerte
groupstds   = apply(A,2,sd)                         # Gruppenstandardabweichungen

# Balkendiagramm
par(                                                # für Details siehe ?par
family      = "sans",                               # Serif-freier Fonttyp
pty         = "m",                                  # Maximale Abbildungsregion
bty         = "l",                                  # L förmige Box
lwd         = 1,                                    # Liniendicke
las         = 1)                                    # Horizontale Achsenbeschriftung
x = barplot(                                        # Ausgabe der x-Ordinaten (?barplot für Details)
groupmeans,
ylim        = c(-5,15),
col         = "gray90",
ylab        = "dBDI",
xlab        = "Condition")
arrows(                                             # für Details siehe ?arrows
x0          = x,                                    # arrow start x-ordinate
y0          = groupmeans - groupstds,               # arrow start y-ordinate
x1          = x,                                    # arrow end   x-ordinate
y1          = groupmeans + groupstds,               # arrow end   y-ordinate
code        = 3,                                    # Pfeilspitzen beiderseits
angle       = 90,                                   # Pfeilspitzenwinkel -> Linie
length      = 0.05)                                 # Linielänge

# PDF Speicherung
dev.copy2pdf(
file        = file.path(getwd(), "10_Abbildungen", "alm_10_aov_1_barplot.pdf"),
width       = 7,
height      = 4)
```

Balkendiagramm

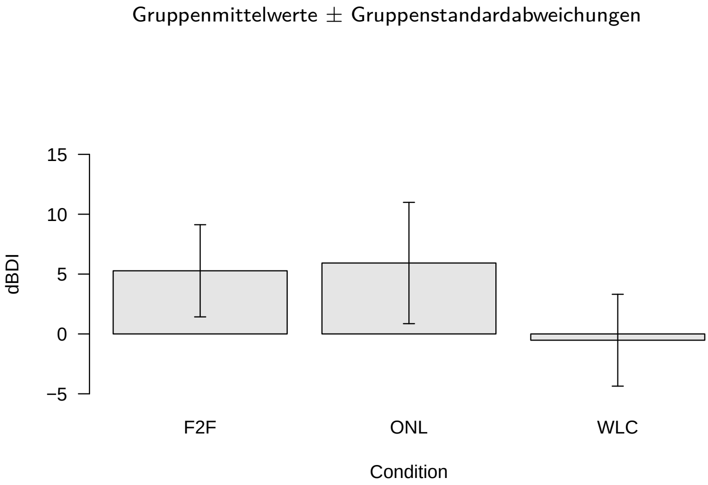

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Selbstkontrollfragen

Modellformulierung

Definition (EVA Modell in Erwartungswertparameterdarstellung)

υ_{ij} mit $i = 1, ..., p$, welche die Gruppen indizieren, und $j = 1, ..., n_i$, welche die experimentellen Einheiten innerhalb der Gruppen indizieren, seien Zufallsvariablen, die die Datenpunkte eines Einfaktoriellen Varianzanalyse (EVA) Szenarios modellieren. Dann hat das *EVA Modell in Erwartungswertparameterdarstellung* die strukturelle Form

$$\upsilon_{ij} = \mu_i + \varepsilon_{ij} \text{ mit } \varepsilon_{ij} \sim N(0, \sigma^2) \text{ u.i.v. für } i = 1, ..., p, j = 1, ..., n_i \text{ mit } \mu_i \in \mathbb{R}, \sigma^2 > 0. \tag{1}$$

und die Datenverteilungsform

$$\upsilon_{ij} \sim N(\mu_i, \sigma^2) \text{ u.v. für } i = 1, ..., p, j = 1, ..., n_i \text{ mit } \mu_i \in \mathbb{R}, \sigma^2 > 0. \tag{2}$$

Wenn $n_i := m$ für alle $i = 1, ..., p$ heißt das EVA Szenario *balanciert*.

Bemerkungen

- Die Äquivalenz der beiden Modellformulierungen folgt aus den Ergebnissen in Einheit (5) Modellformulierung
- Es handelt sich um die Generalisierung des Zweistichproben-T-Test Modells für unabhängige Stichproben unter Annahme identischer Varianzparameter von $p = 2$ auf ein beliebiges $p \in \mathbb{N}$.
- Bei balancierten Varianzanalyseszenarien besteht jede Datengruppe aus der gleichen Anzahl von Datenpunkten.

Motivation der Effektdarstellung

Die Erwartungswertparameterdarstellung des EVA Modells ist ein valides ALM, das sich in dieser Form auch in der Literatur findet (z.B. Georgii (2009), Kapitel 12.4). Im Sinne der Konsistenz mit mehrfaktoriellen Varianzanalysemodellen bietet sich jedoch eine Reparameterisierung der Erwartungswertparameter an. Kern dieser Reparameterisierung ist es, den Erwartungswertparameter der $i$ten Gruppe als Summe eines *gruppenübergreifenden Erwartungswertparameters* $\mu_0 \in \mathbb{R}$ und eines *gruppenspezifischen Effektparameters* $\alpha_i \in \mathbb{R}$ zu modellieren,

$$\mu_i := \mu_0 + \alpha_i \text{ für } i = 1, ..., p. \tag{3}$$

Dabei modelliert α_i den Unterschied (die Differenz) zwischen dem $i$ten Erwartungswertparameter μ_i und dem gruppenübergreifenden Erwartungswertparameter μ_0,

$$\alpha_i = \mu_i - \mu_0 \text{ für } i = 1, ..., p. \tag{4}$$

Allerdings hat die in dieser Form vorgenommene Reparameterisierung einen entscheidenden Nachteil: es werden p Erwartungswertparameter $\mu_i, i = 1, ..., p$ durch die $p + 1$ Parameter μ_0 und $\alpha_i, i = 1, ..., p$ dargestellt. Diese Darstellung ist im Allgemeinen nicht eindeutig. Zum Beispiel können die Erwartungswertparameter $\mu_1 = 3, \mu_2 = 5, \mu_3 = 6$ sowohl durch den gruppenspezifischen Erwartungswertparameter $\mu_0 = 0$ und die gruppenunspezifischen Effektparameter $\alpha_1 = 3, \alpha_2 = 5, \alpha_3 = 6$ als auch durch den gruppenunspezifischen Erwartungswertparameter $\mu_0 = 1$ und die gruppenspezifischen Effektparameter $\alpha_1 = 2, \alpha_2 = 4, \alpha_3 = 5$ dargestellt werden. Man sagt in diesem Kontext auch, dass das EVA Modell mit (3) *überparameterisiert* ist.

Motivation der Effektdarstellung

Datenanalytisch hat die Überparameterisierung eines Varianzanalysemodells den Nachteil, dass aus p geschätzten Erwartungswertparametern $p+1$ Betaparameterschätzer bestimmt werden müssten, was wie oben gesehen nicht eindeutig erfolgen kann. Um diese Probleme in der Effektparameterdarstellung des EVA Modells zu umgehen und diese konsistent auf mehrfaktorielle Varianzanalysemodelle zu übertragen, bietet sich die Einführung der Nebenbedingung

$$\alpha_1 := 0 \tag{5}$$

an. Es wird also ein Effektparameter von vornherein als "gleich Null" angenommen. Für die gruppenspezifischen Erwartungswertparameter ergibt sich damit

$$\begin{aligned} \mu_1 &:= \mu_0 \\ \mu_i &:= \mu_0 + \alpha_i \text{ für } i = 2, ..., p. \end{aligned} \tag{6}$$

Hierbei wird die erste Gruppe nun als *Referenzgruppe* bezeichnet und die α_i modellieren die Differenz zwischen dem Erwartungswertparameter der $i$ten Gruppe und dem Erwartungswertparameter der ersten Gruppe:

$$\alpha_i = \mu_i - \mu_0 = \mu_i - \mu_1 \text{ für } i = 1, ..., p. \tag{7}$$

μ_0 ist also kein gruppenübergreifender Erwartungswertparameter mehr, sondern identisch mit dem Erwartungswertparameter der ersten Gruppe. Welche tatsächliche experimentelle Gruppe dabei als "erste Gruppe" definiert wird, ist unerheblich. Entscheidend ist, dass die entsprechenden Erwartungswertparameterschätzer $\hat{\mu}_0$,$\hat{\alpha}_2, ..., \hat{\alpha}_p$ korrekt als (1) Erwartungswertparameterschätzer der Referenzgruppe ($\hat{\mu}_0$) und (2) geschätzte Erwartungswertparameterdifferenz zwischen dem Erwartungswertparameter der Referenzgruppe und der dem Erwartungswertparameter der $i$ten Gruppe ($\hat{\alpha}_2, ..., \hat{\alpha}_p$) verstanden werden. Wir formalisieren das oben Gesagte in folgendem Theorem.

Theorem (EVA Modell in Effektdarstellung mit Referenzgruppe I)

Gegeben sei das EVA Modell in Erwartungswertparameterdarstellung. Dann können die Zufallsvariablen, die die Datenpunkte des EVA Szenarios modellieren, äquivalent in der strukturellen Form

$$\begin{aligned} \upsilon_{1j} &= \mu_0 + \varepsilon_{1j} && \text{mit } \varepsilon_{1j} \sim N(0,\sigma^2) \text{ u.i.v. für } j = 1,...,n_1 \\ \upsilon_{ij} &= \mu_0 + \alpha_i + \varepsilon_{ij} && \text{mit } \varepsilon_{ij} \sim N(0,\sigma^2) \text{ u.i.v. für } i = 2,...,p, j = 1,...,n_i \end{aligned} \tag{8}$$

mit

$$\alpha_i := \mu_i - \mu_1 \text{ für } i = 2,...,p \tag{9}$$

und in der entsprechenden Datenverteilungsform

$$\begin{aligned} \upsilon_{1j} &\sim N(\mu_0,\sigma^2) && \text{u.i.v. für } j = 1,...,n_i \text{ mit } \mu_0 \in \mathbb{R}, \sigma^2 > 0 \\ \upsilon_{ij} &\sim N(\mu_0 + \alpha_i,\sigma^2) && \text{u.v. für } i = 2,...,p, j = 1,...,n_i \text{ mit } \alpha_i \in \mathbb{R}, \sigma^2 > 0 \end{aligned} \tag{10}$$

geschrieben werden. Wir nennen (8) und (10) strukturelle und Datenverteilungsform des *EVA Modells in Effektdarstellung mit Referenzgruppe*.

Beweis

Es gilt

$$\mu_i = \mu_0 + \mu_i - \mu_0. \tag{11}$$

Die Parameterisierungen mit μ_i und mit $\mu_0 + \mu_i - \mu_0$ sind also gleich und damit äquivalent. Dann folgt aber auch

$$\mu_i = \mu_0 + (\mu_i - \mu_0) =: \mu_0 + \alpha_i \text{ für } i = 1,...,p \tag{12}$$

Mit $\alpha_1 := 0$ gilt dann $\mu_1 = \mu_0$ und $\mu_i = \mu_0 + \alpha_i$ für $i = 2,...,p$, wie im Theorem behauptet.

Theorem (EVA Modell in Effektdarstellung mit Referenzgruppe II)

Gegeben sei die strukturelle Form des EVA Modells in Effektdarstellung mit Referenzgruppe. Dann hat dieses Modell die Designmatrixform

$$\upsilon = X\beta + \varepsilon \text{ mit } \varepsilon \sim N(0_n, \sigma^2 I_n), n := \sum_{i=1}^{p} n_i \tag{13}$$

$$\upsilon := \begin{pmatrix} \upsilon_{11} \\ \vdots \\ \upsilon_{1n_1} \\ \upsilon_{21} \\ \vdots \\ \upsilon_{2n_2} \\ \\ \vdots \\ \\ \upsilon_{p1} \\ \vdots \\ \upsilon_{pn_p} \end{pmatrix} \in \mathbb{R}^n,\ X := \begin{pmatrix} 1 & 0 & & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & & 0 \\ 1 & 1 & & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 1 & & 0 \\ \\ \vdots & \vdots & \cdots & \vdots \\ \\ 1 & 0 & & 1 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & & 1 \end{pmatrix} \in \mathbb{R}^{n \times p},\ \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \vdots \\ \alpha_p \end{pmatrix} \in \mathbb{R}^p \text{ und } \sigma^2 > 0.$$

<u>Beweis</u>

Das Theorem ergibt sich direkt mit den Regeln der Matrixmultiplikation.

Modellformulierung

Beispiel

Es seien

$$p = 4 \text{ und } n_i := 3 \text{ für } i = 1, ..., p, \text{ also } n = 12. \tag{14}$$

Dann gilt

$$\upsilon = X\beta + \varepsilon \text{ mit } \varepsilon \sim N(0_{12}, \sigma^2 I_{12}) \tag{15}$$

mit

$$\upsilon := \begin{pmatrix} \upsilon_{11} \\ \upsilon_{12} \\ \upsilon_{13} \\ \upsilon_{21} \\ \upsilon_{22} \\ \upsilon_{23} \\ \upsilon_{31} \\ \upsilon_{32} \\ \upsilon_{33} \\ \upsilon_{41} \\ \upsilon_{42} \\ \upsilon_{43} \end{pmatrix}, X := \begin{pmatrix} 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{pmatrix} \in \mathbb{R}^{12 \times 4}, \ \beta := \begin{pmatrix} \mu_0 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \end{pmatrix} \in \mathbb{R}^4 \text{ und } \sigma^2 > 0. \tag{16}$$

Modellformulierung

Beispiel

```
# Modellformulierung
library(MASS)                                           # Multivariate Normalverteilung
m      = 3                                              # Anzahl von Datenpunkten der iten Gruppe
p      = 4                                              # Anzahl Gruppen
n      = p*m                                            # Gesamtanzahl Datenpunkte
Xt     = cbind(                                         # Designmatrix
           matrix(1,nrow = n, ncol = 1),
           kronecker(diag(p), matrix(1,nrow = m,ncol = 1)))
X      = Xt[,-2]
I_n    = diag(n)                                        # n x n Einheitsmatrix
beta   = matrix(c(1,2), nrow = p)                       # \beta = (\mu_0,\alpha_2,\alpha_3,\alpha_4)
sigsqr = 14                                             # \sigma^2

# Datenrealisierung
y      = mvrnorm(1, X %*% beta, sigsqr*I_n)             # eine Realisierung eines n-dimensionalen ZVs
```

```
>       [,1] [,2] [,3] [,4]
>  [1,]    1    0    0    0
>  [2,]    1    0    0    0
>  [3,]    1    0    0    0
>  [4,]    1    1    0    0
>  [5,]    1    1    0    0
>  [6,]    1    1    0    0
>  [7,]    1    0    1    0
>  [8,]    1    0    1    0
>  [9,]    1    0    1    0
> [10,]    1    0    0    1
> [11,]    1    0    0    1
> [12,]    1    0    0    1
```

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Selbstkontrollfragen

Theorem (Betaparameterschätzung im EVA Modell)

Gegeben sei die Designmatrixform des EVA in Effektdarstellung mit Referenzgruppe. Dann ergibt sich für den Betaparameterschätzer

$$\hat{\beta} := \begin{pmatrix} \hat{\mu}_0 \\ \hat{\alpha}_2 \\ \vdots \\ \hat{\alpha}_p \end{pmatrix} = \begin{pmatrix} \bar{\upsilon}_1 \\ \bar{\upsilon}_2 - \bar{\upsilon}_1 \\ \vdots \\ \bar{\upsilon}_p - \bar{\upsilon}_1 \end{pmatrix} \quad (17)$$

wobei

$$\bar{\upsilon}_i := \frac{1}{n_i} \sum_{j=1}^{n_i} \upsilon_{ij} \quad (18)$$

das Stichprobenmittel der $i$ten Gruppe bezeichent.

Bemerkungen

- Der Erwartungswertparameter der ersten Gruppe wird durch das Stichprobenmittel der ersten Gruppe geschätzt; der Effektparameter der $i$ten Gruppe wird durch die Differenz des Stichprobenmittels der $i$ten und der ersten Gruppe geschätzt. Die Beziehung zwischen dem Varianzparameterschätzer $\hat{\sigma}^2$ und dem Konzept der gepoolten Stichprobenvarianz betrachten wir an dieser Stelle nicht genauer.

Modellschätzung

Beweis

Wir halten zunächst fest, dass

$$
X^T X = \begin{pmatrix}
1 & \cdots & 1 & 1 & \cdots & 1 & \cdots & 1 & \cdots & 1 \\
0 & \cdots & 0 & 1 & \cdots & 1 & \cdots & 0 & \cdots & 0 \\
 & \vdots & & & \vdots & & \vdots & & \vdots & \\
0 & \cdots & 0 & 0 & \cdots & 0 & \cdots & 1 & \cdots & 1
\end{pmatrix}
\begin{pmatrix}
1 & 0 & & 0 \\
\vdots & \vdots & \cdots & \vdots \\
1 & 0 & & 0 \\
1 & 1 & & 0 \\
\vdots & \vdots & \cdots & \vdots \\
1 & 1 & & 0 \\
 & & & \\
\vdots & \vdots & \cdots & \vdots \\
 & & & \\
1 & 0 & & 1 \\
\vdots & \vdots & \cdots & \vdots \\
1 & 0 & & 1
\end{pmatrix}
$$

$$
= \begin{pmatrix}
n & n_2 & n_3 & \cdots & n_p \\
n_2 & n_2 & 0 & \cdots & 0 \\
n_3 & 0 & n_3 & \cdots & 0 \\
\vdots & \vdots & \vdots & \ddots & \vdots \\
n_p & 0 & 0 & \cdots & n_p
\end{pmatrix} .
$$

Beweis (fortgeführt)

Die Inverse von X^TX ist

$$
(X^TX)^{-1} = \begin{pmatrix} \frac{1}{n_1} & -\frac{1}{n_1} & \cdots & -\frac{1}{n_1} \\ -\frac{1}{n_1} & \frac{n_1+n_2}{n_1n_2} & \cdots & \frac{1}{n_1} \\ \vdots & \vdots & \ddots & \vdots \\ -\frac{1}{n_1} & \frac{1}{n_1} & \cdots & \frac{n_1+n_p}{n_1n_p} \end{pmatrix}. \qquad (19)
$$

So gilt zum Beispiel für $p = 3$, dass

$$
X^TX = \begin{pmatrix} n & n_2 & n_3 \\ n_2 & n_2 & 0 \\ n_3 & 0 & n_3 \end{pmatrix} \text{ und } (X^TX)^{-1} = \begin{pmatrix} \frac{1}{n_1} & -\frac{1}{n_1} & -\frac{1}{n_1} \\ -\frac{1}{n_1} & \frac{n_1+n_2}{n_1n_2} & \frac{1}{n_1} \\ -\frac{1}{n_1} & \frac{1}{n_1} & \frac{n_1+n_3}{n_1n_3} \end{pmatrix}. \qquad (20)
$$

Beweis (fortgeführt)

Wir halten weiterhin fest, dass

$$
\begin{aligned}
X^T \upsilon &= \begin{pmatrix}
1 & \cdots & 1 & 1 & \cdots & 1 & & \cdots & & 1 & \cdots & 1 \\
0 & \cdots & 0 & 1 & \cdots & 1 & & \cdots & & 0 & \cdots & 0 \\
 & \vdots & & & \vdots & & & \vdots & & & \vdots & \\
0 & \cdots & 0 & 0 & \cdots & 0 & & \cdots & & 1 & \cdots & 1
\end{pmatrix}
\begin{pmatrix}
\upsilon_{11} \\ \vdots \\ \upsilon_{1n_1} \\ \upsilon_{21} \\ \vdots \\ \upsilon_{2n_2} \\ \\ \vdots \\ \\ \upsilon_{p1} \\ \vdots \\ \upsilon_{pn_p}
\end{pmatrix} \\
&= \begin{pmatrix}
\sum_{i=1}^{p} \sum_{j=1}^{n_i} \upsilon_{ij} \\
\sum_{j=1}^{n_2} \upsilon_{2j} \\
\vdots \\
\sum_{j=1}^{n_p} \upsilon_{pj}
\end{pmatrix}.
\end{aligned}
\tag{21}
$$

Modellschätzung

Beweis (fortgeführt)

Es ergibt sich also

$$\hat{\beta} = (X^T X)^{-1} X^T \upsilon = \begin{pmatrix} \frac{1}{n_1} & -\frac{1}{n_1} & \cdots & -\frac{1}{n_1} \\ -\frac{1}{n_1} & \frac{n_1+n_2}{n_1 n_2} & \cdots & \frac{1}{n_1} \\ \vdots & \vdots & \ddots & \vdots \\ -\frac{1}{n_1} & \frac{1}{n_1} & \cdots & \frac{n_1+n_p}{n_1 n_p} \end{pmatrix} \begin{pmatrix} \sum_{i=1}^{p} \sum_{j=1}^{n_i} \upsilon_{ij} \\ \sum_{j=1}^{n_2} \upsilon_{2j} \\ \vdots \\ \sum_{j=1}^{n_p} \upsilon_{pj} \end{pmatrix}. \qquad (22)$$

Für die erste Komponente von $\hat{\beta}$ ergibt sich damit

$$\begin{aligned} \hat{\beta}_0 &= \frac{1}{n_1} \sum_{i=1}^{p} \sum_{j=1}^{n_i} \upsilon_{ij} - \frac{1}{n_1} \sum_{j=1}^{n_2} \upsilon_{2j} - \cdots - \frac{1}{n_1} \sum_{j=1}^{n_p} \upsilon_{pj} \\ &= \frac{1}{n_1} \left(\left(\sum_{j=1}^{n_1} \upsilon_{1j} + \sum_{j=1}^{n_2} \upsilon_{2j} + \cdots + \sum_{j=1}^{n_p} \upsilon_{pj} \right) - \sum_{j=1}^{n_2} \upsilon_{2j} - \cdots - \sum_{j=1}^{n_p} \upsilon_{pj} \right) \qquad (23) \\ &= \frac{1}{n_1} \sum_{j=1}^{n_1} \upsilon_{1j} \\ &= \bar{\upsilon}_1. \end{aligned}$$

Modellschätzung

Beweis (fortgeführt)

Für die zweite Komponente von $\hat{\beta}$ und analog für alle weiteren ergibt sich

$$
\begin{aligned}
\hat{\beta}_2 &= -\frac{1}{n_1}\sum_{i=1}^{p}\sum_{j=1}^{n_i} \upsilon_{ij} + \frac{n_1+n_2}{n_1 n_2}\sum_{j=1}^{n_2}\upsilon_{2j} + \frac{1}{n_1}\sum_{j=1}^{n_3}\upsilon_{3j} + \cdots + \frac{1}{n_1}\sum_{j=1}^{n_p}\upsilon_{pj} \\
&= \frac{n_1+n_2}{n_1 n_2}\sum_{j=1}^{n_2}\upsilon_{2j} - \frac{1}{n_1}\left(\left(\sum_{j=1}^{n_1}\upsilon_{1j} + \sum_{j=1}^{n_2}\upsilon_{2j} + \cdots + \sum_{j=1}^{n_p}\upsilon_{pj}\right) - \sum_{j=1}^{n_3}\upsilon_{3j} - \cdots - \sum_{j=1}^{n_p}\upsilon_{pj}\right) \\
&= \frac{n_1+n_2}{n_1 n_2}\sum_{j=1}^{n_2}\upsilon_{2j} - \frac{1}{n_1}\sum_{j=1}^{n_1}\upsilon_{1j} - \frac{1}{n_1}\sum_{j=1}^{n_2}\upsilon_{2j} \\
&= \frac{n_1+n_2}{n_1 n_2}\sum_{j=1}^{n_2}\upsilon_{2j} - \frac{n_2}{n_1 n_2}\sum_{j=1}^{n_2}\upsilon_{2j} - \frac{1}{n_1}\sum_{j=1}^{n_1}\upsilon_{1j} \\
&= \frac{n_1}{n_1 n_2}\sum_{j=1}^{n_2}\upsilon_{2j} - \frac{1}{n_1}\sum_{j=1}^{n_1}\upsilon_{1j} \\
&= \frac{1}{n_2}\sum_{j=1}^{n_2}\upsilon_{2j} - \frac{1}{n_1}\sum_{j=1}^{n_1}\upsilon_{1j} = \bar{\upsilon}_2 - \bar{\upsilon}_1 .
\end{aligned}
$$

Modellschätzung

```r
# Dateneinlesen
fname       = file.path(getwd(), "10_Daten", "10_Einfaktorielle_Varianzanalyse_Daten.csv")
D           = read.table(fname, sep = ",", header = TRUE)

# Datengruppen
y_1         = D$dBDI[D$Setting == "F2F"]                          # BDI Differenzwerte in der F2F Gruppe
y_2         = D$dBDI[D$Setting == "ONL"]                          # BDI Differenzwerte in der ONL Gruppe
y_3         = D$dBDI[D$Setting == "WLC"]                          # BDI Differenzwerte in der ONL Gruppe

# Modellformulierung
p           = 3                                                   # drei Gruppen
m           = length(y_1)                                         # balancierters Design mit n_i = 40
n           = p*m                                                 # Datenvektordimension
y           = matrix(c(y_1, y_2, y_3), nrow = n)                  # Datenvektor
Xt          = cbind(                                              # Designmatrix
                matrix(1, nrow = n, ncol = 1),
                kronecker(diag(p), matrix(1, nrow = m, ncol = 1)))
X           = Xt[,-2]

# Modellschätzung
beta_hat    = solve(t(X) %*% X) %*% t(X) %*% y                    # Betaparameterschätzer
eps_hat     = y - X %*% beta_hat                                  # Residuenvektor
sigsqr_hat = (t(eps_hat) %*% eps_hat) /(n-p)                     # Varianzparameterschätzer
s_sqr_123 = ((m-1)*var(y_1) +                                    # gepoolte Stichprobenvarianz
             (m-1)*var(y_2) +
             (m-1)*var(y_3))/(m+m+m-p)

# Ausgabe
cat("hat{beta}                                   : "  , beta_hat,
    "\nbar{y}_1,bar{y}_2,bar{y}_3                 : ", c(mean(y_1),mean(y_2),mean(y_3)),
    "\nbar{y}_1,bar{y}_2-bar{y}_1,bar{y}_3-bar{y}_1 : ", c(mean(y_1),mean(y_2)-mean(y_1),mean(y_3)-mean(y_1)),
    "\nhat{sigsqr}                                : ", sigsqr_hat,
    "\ns_123^2                                    : ", s_sqr_123,
    "\ns_y^2                                      : ", var(y))
```

```
> hat{beta}                                    :  5.28 0.65 -5.8
> bar{y}_1,bar{y}_2,bar{y}_3                   :  5.28 5.92 -0.525
> bar{y}_1,bar{y}_2-bar{y}_1,bar{y}_3-bar{y}_1 :  5.28 0.65 -5.8
> hat{sigsqr}                                  :  18.4
> s_123^2                                      :  18.4
> s_y^2                                        :  26.6
```

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Selbstkontrollfragen

Vorbemerkungen und Überblick

Prinzipiell sind alle Parameterschätzwerte in einem EVA Modell von Interesse; mit der T-Teststatistik können einzelne oder lineare Kombinationen der Betaparameterschätzwerte im Sinne von Hypothesentests evaluiert werden.

Nichtsdestotrotz steht im EVA Szenario häufig die Evaluation der Nullhypothese, dass alle Effektparameter gleich Null sind im Vordergrund. Intuitiv besagt diese Nullhypothese, dass die wahren, aber unbekannten, Erwartungswertparameter aller Gruppen identisch sind, formal haben wir

$$H_0 : \alpha_i = 0 \text{ für alle } i = 2, ..., p \Leftrightarrow \Theta_0 := \mathbb{R} \times \{0_{p-1}\} \tag{25}$$

und

$$H_1 : \alpha_i \neq 0 \text{ für mindestens ein } i = 2, ..., p \Leftrightarrow \Theta_1 := \mathbb{R}^p \setminus \mathbb{R} \times \{0_{p-1}\} \tag{26}$$

Zur Überprüfung von H_0 wird im Allgemeinen eine F-Teststatistik eingesetzt.

Im Folgenden entwickeln wir zunächst diese F-Teststatistik anhand einer *Quadratsummenzerlegung* der Datenvariabilität in einem EVA Szenario und betrachten in diesem Zusammenhang auch das dem R^2 analoge Maß η^2 der Effektstärke im EVA Szenario. Ausgestattet mit der speziellen Form der F-Teststatistik in dem hier betrachteten Szenario diskutieren wir dann den traditionellen EVA Hypothesentest. Wir verzichten auf eine Analyse der Testgütefunktion und eine Diskussion der Powerfunktion.

Theorem (Quadratsummenzerlegung bei einfaktorieller Varianzanalyse)

Für $i = 1, ..., p$ und $j = 1, ..., n_i$ sei υ_{ij} die $j$te Datenvariable in der $i$ten Gruppe eines EVA Szenarios. Weiterhin seien mit $n := \sum_{i=1}^{p} n_i$

$$\bar{\upsilon} := \frac{1}{n} \sum_{i=1}^{p} \sum_{j=1}^{n_i} \upsilon_{ij} \qquad \text{das } \textit{Gesamtstichprobenmittel}$$

$$\bar{\upsilon}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \upsilon_{ij} \qquad \text{das } i\textit{te Stichprobenmittel}$$

sowie

$$\mathsf{SQT} := \sum_{i=1}^{p} \sum_{j=1}^{n_i} (\upsilon_{ij} - \bar{\upsilon})^2 \qquad \text{die } \textit{Total Sum of Squares}$$

$$\mathsf{SQB} := \sum_{i=1}^{p} n_i (\bar{\upsilon}_i - \bar{\upsilon})^2 \qquad \text{die } \textit{Between Sum of Squares}$$

$$\mathsf{SQW} := \sum_{i=1}^{p} \sum_{j=1}^{n_i} (\upsilon_{ij} - \bar{\upsilon}_i)^2 \qquad \text{die } \textit{Within Sum of Squares}$$

Dann gilt

$$\mathsf{SQT} = \mathsf{SQB} + \mathsf{SQW}. \tag{27}$$

Bemerkung

- In Analogie zur Quadratsummenzerlegung bei einer Ausgleichsgerade (vgl. Einheit (3) Korrelation) wird die *Within Sum of Squares* auch als *Residual Sum of Squares* bezeichnet.

Modellevaluation

Beweis

Es gilt

$$
\begin{aligned}
\mathsf{SQT} &= \sum_{i=1}^{p}\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon})^2 \\
&= \sum_{i=1}^{p}\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i+\bar{\upsilon}_i-\bar{\upsilon})^2 \\
&= \sum_{i=1}^{p}\sum_{j=1}^{n_i}\Big((\upsilon_{ij}-\bar{\upsilon}_i)+(\bar{\upsilon}_i-\bar{\upsilon})\Big)^2 \\
&= \sum_{i=1}^{p}\sum_{j=1}^{n_i}\Big((\upsilon_{ij}-\bar{\upsilon}_i)^2+2(\upsilon_{ij}-\bar{\upsilon}_i)(\bar{\upsilon}_i-\bar{\upsilon})+(\bar{\upsilon}_i-\bar{\upsilon})^2\Big) \\
&= \sum_{i=1}^{p}\left(\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2+\sum_{j=1}^{n_i}2(\upsilon_{ij}-\bar{\upsilon}_i)(\bar{\upsilon}_i-\bar{\upsilon})+\sum_{j=1}^{n_i}(\bar{\upsilon}_i-\bar{\upsilon})^2\right)
\end{aligned}
\tag{28}
$$

Beweis (fortgeführt)

und weiter

$$
\begin{aligned}
\mathsf{SQT} &= \sum_{i=1}^{p}\left(\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2 + 2(\bar{\upsilon}_i-\bar{\upsilon})\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i) + n_i(\bar{\upsilon}_i-\bar{\upsilon})^2\right) \\
&= \sum_{i=1}^{p}\left(\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2 + 2(\bar{\upsilon}_i-\bar{\upsilon})\sum_{j=1}^{n_i}\left(\upsilon_{ij}-\frac{1}{n_i}\sum_{j=1}^{n_i}\upsilon_{ij}\right) + n_i(\bar{\upsilon}_i-\bar{\upsilon})^2\right) \\
&= \sum_{i=1}^{p}\left(\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2 + 2(\bar{\upsilon}_i-\bar{\upsilon})\left(\sum_{j=1}^{n_i}\upsilon_{ij}-\sum_{j=1}^{n_i}\left(\frac{1}{n_i}\sum_{j=1}^{n_i}\upsilon_{ij}\right)\right) + n_i(\bar{\upsilon}_i-\bar{\upsilon})^2\right) \\
&= \sum_{i=1}^{p}\left(\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2 + 2(\bar{\upsilon}_i-\bar{\upsilon})\left(\sum_{j=1}^{n_i}\upsilon_{ij}-\frac{n_i}{n_i}\sum_{j=1}^{n_i}\upsilon_{ij}\right) + n_i(\bar{\upsilon}_i-\bar{\upsilon})^2\right)
\end{aligned}
$$

Beweis (fortgeführt)

und weiter

$$
\begin{aligned}
\mathsf{SQT} & = \sum_{i=1}^{p}\left(\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2 + 2(\bar{\upsilon}_i-\bar{\upsilon})\left(\sum_{j=1}^{n_i}\upsilon_{ij}-\sum_{j=1}^{n_i}\upsilon_{ij}\right)+n_i(\bar{\upsilon}_i-\bar{\upsilon})^2\right) \\
& = \sum_{i=1}^{p}\left(\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2 + n_i(\bar{\upsilon}_i-\bar{\upsilon})^2\right) \\
& = \sum_{i=1}^{p}\sum_{j=1}^{n_i}(\upsilon_{ij}-\bar{\upsilon}_i)^2 + \sum_{i=1}^{p} n_i(\bar{\upsilon}_i-\bar{\upsilon})^2 \\
& = \mathsf{SQW} + \mathsf{SQB}
\end{aligned}
\tag{29}
$$

und damit direkt

$$
\mathsf{SQT} = \mathsf{SQB} + \mathsf{SQW}. \tag{30}
$$

Definition (Effektstärkenmaß η^2)

Für ein EVA Szenario seien die Between Sum of Squares SQB und die Total Sum of Squares SQT definiert wie oben. Dann ist das *Effektstärkenmaß* η^2 definiert als

$$\eta^2 := \frac{\text{SQB}}{\text{SQT}} \tag{31}$$

Bemerkungen

- η^2 ist analog zum Bestimmtheitsmaß R^2 der Regression definiert.
- η^2 gibt den Anteil der Varianz zwischen den Gruppen an der Gesamtvarianz der Daten an.
- Mit dem Theorem zur Quadratsummenzerlegung bei EVA folgt sofort $0 \le \eta^2 \le 1$, da

$$\begin{aligned} \text{SQB} = 0 &\Rightarrow \text{SQT} = \text{SQW und } \eta^2 = 0 \\ \text{SQW} = 0 &\Rightarrow \text{SQT} = \text{SQB und } \eta^2 = 1 \end{aligned} \tag{32}$$

Theorem (F-Teststatistik)

Es sei

$$\upsilon = X\beta + \varepsilon \text{ mit } \varepsilon \sim N(0_n, \sigma^2 I_n) \tag{33}$$

die Designmatrixform der Effektdarstellung mit Referenzgruppe des EVA Modells und im Sinne der Definition der F-Statistik (vgl. Einheit (8) F-Statistiken) sei dieses Modell partioniert mit $p_0 := 1$ und $p_1 := p - 1$. Weiterhin seien

$$\text{MSB} := \frac{\text{SQB}}{p-1} \qquad \text{die } \textit{Mean Between Sum of Squares}$$

$$\text{MSW} := \frac{\text{SQW}}{n-p} \qquad \text{die } \textit{Mean Within Sum of Squares}$$

respektive. Dann gilt

$$F = \frac{\text{MSB}}{\text{MSW}}. \tag{34}$$

Bemerkungen

- $p_0 := 1$ impliziert, dass das reduzierte Modell die Designmatrix $X_0 := 1_n$ hat.
- $p_0 := 1$ impliziert zudem, dass das reduzierte Modell den Betaparameter $\beta_0 := \mu_0$ hat.
- $p_0 := 1$ impliziert damit auch, dass das reduzierte Modell keine Effektparameter hat.
- Die Zahl $p - 1$ wird auch als “Between Freiheitsgrade” bezeichnet.
- Die Zahl $n - p$ wird auch als “Within Freiheitsgrade” bezeichnet.

Modellevaluation

Beweis

Wir halten zunächst fest, dass für den Betaparameterschätzer des reduzierten Modells gilt, dass

$$\hat{\beta}_0 = (X_0^T X_0)^{-1} X_0^T \upsilon = (1_n^T 1_n)^{-1} 1_n^T \upsilon = \frac{1}{n} \sum_{i=1}^{p} \sum_{j=1}^{n_i} \upsilon_{ij} = \bar{\upsilon}. \tag{35}$$

Weiterhin ergibt sich

$$\hat{\varepsilon}_0^T \hat{\varepsilon}_0 = (\upsilon - X_0\hat{\beta}_0)^T (\upsilon - X_0\hat{\beta}_0) = (\upsilon - 1_n\bar{\upsilon})^T (\upsilon - 1_n\bar{\upsilon}) = \sum_{i=1}^{p} \sum_{j=1}^{n_i} (\upsilon_{ij} - \bar{\upsilon})^2 = \mathsf{SQT}. \tag{36}$$

Der Betaparameterschätzer des vollständigen Modells ergibt sich wie oben gesehen zu

$$\hat{\beta} = \begin{pmatrix} \hat{\mu}_0 \\ \hat{\alpha}_2 \\ \vdots \\ \hat{\alpha}_m \end{pmatrix} = \begin{pmatrix} \frac{1}{n_1} \sum_{j=1}^{n_1} \upsilon_{1j} \\ \frac{1}{n_2} \sum_{j=1}^{n_2} \upsilon_{2j} - \frac{1}{n_1} \sum_{j=1}^{n_1} \upsilon_{1j} \\ \vdots \\ \frac{1}{n_m} \sum_{j=1}^{n_m} \upsilon_{mj} - \frac{1}{n_1} \sum_{j=1}^{n_1} \upsilon_{1j} \end{pmatrix} = \begin{pmatrix} \bar{\upsilon}_1 \\ \bar{\upsilon}_2 - \bar{\upsilon}_1 \\ \vdots \\ \bar{\upsilon}_p - \bar{\upsilon}_1 \end{pmatrix}, \tag{37}$$

so dass

Beweis (fortgeführt)

$$
\begin{aligned}
\hat{\varepsilon}^T\hat{\varepsilon} =& (\upsilon - X\hat{\beta})^T(\upsilon - X\hat{\beta}) \\
=& \left(\begin{pmatrix} \upsilon_{11} \\ \vdots \\ \upsilon_{1n_1} \\ \upsilon_{21} \\ \vdots \\ \upsilon_{2n_2} \\ \vdots \\ \upsilon_{p1} \\ \vdots \\ \upsilon_{pn_p} \end{pmatrix} - \begin{pmatrix} 1 & 0 & & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & & 0 \\ 1 & 1 & & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 1 & & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & & 1 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & & 1 \end{pmatrix} \begin{pmatrix} \bar{\upsilon}_1 \\ \bar{\upsilon}_2 - \bar{\upsilon}_1 \\ \vdots \\ \bar{\upsilon}_p - \bar{\upsilon}_1 \end{pmatrix}\right)^T (\upsilon - X\hat{\beta})
\end{aligned}
$$

Modellevaluation

Beweis (fortgeführt)

und weiter

$$
\hat{\varepsilon}^T\hat{\varepsilon} =
\begin{pmatrix}
\upsilon_{11} - \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{1n_1} - \bar{\upsilon}_1 \\
\upsilon_{21} - \bar{\upsilon}_1 - \bar{\upsilon}_2 + \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{2n_2} - \bar{\upsilon}_1 - \bar{\upsilon}_2 + \bar{\upsilon}_1 \\
\\
\vdots \\
\\
\upsilon_{p1} - \bar{\upsilon}_1 - \bar{\upsilon}_p + \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{pn_p} - \bar{\upsilon}_1 - \bar{\upsilon}_p + \bar{\upsilon}_1
\end{pmatrix}^T
\begin{pmatrix}
\upsilon_{11} - \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{1n_1} - \bar{\upsilon}_1 \\
\upsilon_{21} - \bar{\upsilon}_1 - \bar{\upsilon}_2 + \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{2n_2} - \bar{\upsilon}_1 - \bar{\upsilon}_2 + \bar{\upsilon}_1 \\
\\
\vdots \\
\\
\upsilon_{p1} - \bar{\upsilon}_1 - \bar{\upsilon}_p + \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{pn_p} - \bar{\upsilon}_1 - \bar{\upsilon}_p + \bar{\upsilon}_1
\end{pmatrix}
=
\begin{pmatrix}
\upsilon_{11} - \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{1n_1} - \bar{\upsilon}_1 \\
\upsilon_{21} - \bar{\upsilon}_2 \\
\vdots \\
\upsilon_{2n_2} - \bar{\upsilon}_2 \\
\\
\vdots \\
\\
\upsilon_{p1} - \bar{\upsilon}_p \\
\vdots \\
\upsilon_{pn_p} - \bar{\upsilon}_p
\end{pmatrix}^T
\begin{pmatrix}
\upsilon_{11} - \bar{\upsilon}_1 \\
\vdots \\
\upsilon_{1n_1} - \bar{\upsilon}_1 \\
\upsilon_{21} - \bar{\upsilon}_2 \\
\vdots \\
\upsilon_{2n_2} - \bar{\upsilon}_2 \\
\\
\vdots \\
\\
\upsilon_{p1} - \bar{\upsilon}_p \\
\vdots \\
\upsilon_{pn_p} - \bar{\upsilon}_p
\end{pmatrix}
$$

$$
= \sum_{i=1}^{p}\sum_{j=1}^{n_i}(\upsilon_{ij} - \bar{\upsilon}_i)^2
$$

$$
= \mathrm{SQW}.
$$

Beweis (fortgeführt)

Mit dem Theorem zur Quadratsummenzerlegung bei einfaktorieller Varianzanalyse

$$\mathsf{SQT} = \mathsf{SQB} + \mathsf{SQW} \Leftrightarrow \mathsf{SQB} = \mathsf{SQT} - \mathsf{SQW} \tag{38}$$

folgt sofort, dass

$$\begin{aligned}\mathsf{SQB} &= \mathsf{SQT} - \mathsf{SQW} \\ &= \hat{\varepsilon}_0^T\hat{\varepsilon}_0 - \hat{\varepsilon}^T\hat{\varepsilon}.\end{aligned} \tag{39}$$

Dann aber folgt auch direkt, dass

$$\begin{aligned}\frac{\mathsf{MSB}}{\mathsf{MSW}} &= \frac{\frac{\mathsf{SQB}}{p-1}}{\frac{\mathsf{SQW}}{n-p}} \\ &= \frac{\frac{\hat{\varepsilon}_0^T\hat{\varepsilon}_0 - \hat{\varepsilon}^T\hat{\varepsilon}}{p-1}}{\frac{\hat{\varepsilon}^T\hat{\varepsilon}}{n-p}} \\ &= F\end{aligned} \tag{40}$$

Theorem (Effektstärkenmaß η^2 und F-Teststatistik)

Für ein EVA Szenario mit p Gruppen und Gesamtdatenpunktanzahl n seien das Effektstärkenmaß η^2 und die F-Teststatistik wie oben definiert. Dann gilt

$$\eta^2 = \frac{F(p-1)}{F(p-1)+(n-p)} \tag{41}$$

Bemerkungen

- Das Verhältnis von F und η^2 ist Analog zum Verhältnis von T und Cohen's d.
- Die gleichzeitige Angabe von F und η^2 ist redundant.

Modellevaluation

Beweis

Wir halten zunächst fest, dass

$$F = \frac{\mathsf{SQB}}{\mathsf{SQW}} \cdot \frac{n-p}{p-1} \Leftrightarrow \mathsf{SQB} = \frac{p-1}{n-p} \cdot \mathsf{SQW} \cdot F \tag{42}$$

Damit folgt dann

$$\begin{aligned}
\eta^2 = \frac{\mathsf{SQB}}{\mathsf{SQT}} = \frac{\mathsf{SQB}}{\mathsf{SQB} + \mathsf{SQW}} = \frac{\frac{p-1}{n-p} \cdot \mathsf{SQW} \cdot F}{\frac{p-1}{n-p} \cdot \mathsf{SQW} \cdot F + \mathsf{SQW}} & = \frac{\frac{F(p-1)}{n-p} \cdot \mathsf{SQW}}{\frac{F(p-1)}{n-p} \cdot \mathsf{SQW} + \mathsf{SQW}} \\
& = \frac{\frac{F(p-1)}{n-p} \cdot \mathsf{SQW}}{\left(\frac{F(p-1)}{n-p} + 1\right) \cdot \mathsf{SQW}} \\
& = \frac{\frac{F(p-1)}{n-p}}{\frac{F(p-1)}{n-p} + \frac{n-p}{n-p}} \\
& = \frac{\frac{F(p-1)}{n-p}}{\frac{F(p-1)+(n-p)}{n-p}} \\
& = \frac{F(p-1)}{F(p-1) + (n-p)}
\end{aligned} \tag{43}$$

Gliederung (vgl. WTFI Einheiten (12) - (14))

(1) Statistisches Modell ✓

(2) Testhypothesen ✓

(3) Teststatistik ✓

(4) Test

(5) Testumfangkontrolle

(6) p-Werte

(4) Test

Definition (Einfaktorielle Varianzanalyse F-Test)

Gegeben sie das Modell der einfaktoriellen Varianzanalyse sowie die zusammengesetzten Null- und Alternativhypothesen

$$H_0 : \alpha_i = 0 \text{ für alle } i = 2, ..., p \Leftrightarrow \Theta_0 := \mathbb{R} \times \{0_{p-1}\} \tag{44}$$

und

$$H_1 : \alpha_i \neq 0 \text{ für mindestens ein } i = 2, ..., p \Leftrightarrow \Theta_1 := \mathbb{R}^p \setminus \mathbb{R} \times \{0_{p-1}\} \tag{45}$$

respektive. Weiterhin sei die F-Teststatistik definiert durch

$$F = \frac{\text{MSB}}{\text{MSW}} \tag{46}$$

mit der Mean Sum of Squares Between MSB und der Mean Sum of Square Within MSW definiert wie oben. Dann ist der *einfaktoriellen Varianzanalyse F-Test (EVA F-Test)* definiert als der kritische Wert-basierte Test

$$\phi(\upsilon) := 1_{\{F \geq k\}} := \begin{cases} 1 & F \geq k \\ 0 & F < k \end{cases}. \tag{47}$$

(5) Testumfangkontrolle

Theorem (Testumfangkontrolle)

ϕ sei der F-Test zur einfaktoriellen Varianzanalyse. Dann ist ϕ ein Level-α_0-Test mit Testumfang α_0, wenn der kritische Wert definiert ist durch

$$k_{\alpha_0} := \varphi^{-1}(1 - \alpha_0; p - 1, n - p), \tag{48}$$

wobei $\varphi^{-1}(\cdot; p - 1, n - p)$ die inverse KVF der f-Verteilung mit Freiheitsgradparametern $p - 1$ und $n - p$ ist.

Wahl von $k_{\alpha_0} := \varphi^{-1}(1 - \alpha_0; p - 1, n - p)$ mit $p = 3, n = 12$ $\alpha_0 := 0.05$ und Ablehnungsbereich

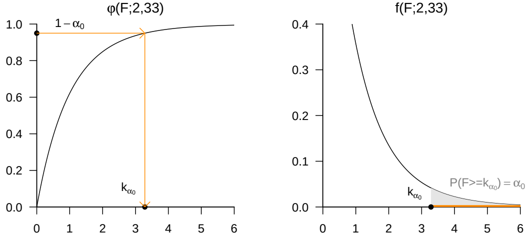

Modellevaluation

Beweis

Die Testgütefunktion des betrachteten Tests im vorliegenden Testszenario ist definiert als

$$q : \mathbb{R} \to [0,1], \beta \mapsto q_\phi(\beta) := \mathbb{P}_\beta(\phi = 1). \tag{49}$$

Wir haben in Einheit (7) Modellevaluation gesehen, dass die F-Teststatistik für $p_1 = p - 1$ nach einer nichtzentralen f-Verteilung verteilt ist,

$$F \sim f(\delta, p-1, n-p). \tag{50}$$

Weiterhin ist der Ablehnungsbereich des hier betrachteten Tests gegeben als $[k, \infty[$ Für die funktionale Form der Testgütefunktion ergibt sich also

$$\begin{aligned}
\mathbb{P}_\beta(\phi = 1) &= \mathbb{P}_\beta(F \in [k, \infty[) \\
&= \mathbb{P}_\beta(F \ge k) \\
&= 1 - \mathbb{P}_\beta(F \le k) \\
&= 1 - \varphi(k; \delta, p-1, n-p),
\end{aligned} \tag{51}$$

wobei $\varphi(k; \delta, p-1, n-p)$ den Wert der KVF der nichtzentralen f-Verteilung an der Stelle k und mit Nichtzentralitätsparameter δ sowie Freiheitsgradparametern $p-1$ und $n-p$ bezeichnet (vgl. Einheit (7) Modellevaluation).

Damit der betrachtete Test ein Level-α_0-Test ist, muss bekanntlich gelten, dass

$$q_\phi(\beta) \le \alpha_0 \text{ für alle } \beta \in \Theta_0 \text{ mit } \Theta_0 = \mathbb{R} \times \{0_{p-1}\}. \tag{52}$$

Modellevaluation

Beweis

Mit der Form des Nichtzentralitätsparameters (vgl. Einheit (7) Modellevaluation) gegeben durch

$$\delta = \frac{1}{\sigma^2} K^T \beta \left(K^T (X^T X)^{-1} K \right)^{-1} K^T \beta \tag{53}$$

folgt mit $\beta \in \Theta_0$ aus

$$K = \begin{pmatrix} 0 \\ 1_{p-1} \end{pmatrix} \in \mathbb{R}^p \text{ und } \beta = \begin{pmatrix} \mu_0 \\ 0_{p-1} \end{pmatrix} \in \mathbb{R}^p \tag{54}$$

dann aber $\delta = 0$ und somit

$$q_\phi(\beta) = 1 - \varphi(k; p-1, n-p) \text{ für alle } \beta \in \Theta_0. \tag{55}$$

wobei $\varphi(k; p-1, n-p)$ den Wert der KVF der f-Verteilung an der Stelle k mit Freiheitsgradparametern $p-1$ und $n-p$ bezeichnet (vgl. Einheit (7) Modellevaluation). Der Testumfang des betrachteten Tests ergibt sich nach Definition (vgl. WTFI Einheit (12) Hypothesentests) als

$$\alpha = \max_{\beta \in \Theta_0} q_\phi(\beta) = 1 - \varphi(k; p-1, n-p), \tag{56}$$

da $q_\phi(\beta)$ für $\beta \in \Theta_0$ nicht von μ_0 abhängt. Wir müssen also lediglich zeigen, dass die Wahl von k_{α_0} wie im Theorem garantiert, dass ϕ den Testumfang α_0 hat. Sei also $k := k_{\alpha_0}$. Dann gilt für alle $\beta \in \Theta_0$

$$q_\phi(\beta) = 1 - \varphi(\varphi^{-1}(1-\alpha_0; p-1, n-p); p-1, n-p) = 1 - (1-\alpha_0) = \alpha_0 \tag{57}$$

und damit ist alles gezeigt.

(7) p-Wert

Nach Definition ist der p-Wert das kleinste Signifikanzlevel α_0, bei welchem man die Nullhypothese basierend auf einem vorliegenden Wert der Teststatistik ablehnen würde. Wir wollen einen vorliegenden Wert der F-Teststatistik hier mit f bezeichnen.

Bei $F = f$ würde H_0 für jedes α_0 mit $f \geq \psi^{-1}(1-\alpha_0; p-1, n-p)$ abgelehnt werden. Für ein solches α_0 gilt aber

$$\alpha_0 \geq \mathbb{P}(F \geq f), \tag{58}$$

denn

$$\begin{aligned}
f &\geq \psi^{-1}(1-\alpha_0; p-1, n-p) \\
\Leftrightarrow \psi(f; p-1, n-p) &\geq \psi(\psi^{-1}(1-\alpha_0; p-1, n-p), p-1, n-p) \\
\Leftrightarrow \psi(f; p-1, n-p) &\geq 1-\alpha_0 \\
\Leftrightarrow \mathbb{P}(F \leq f) &\geq 1-\alpha_0 \\
\Leftrightarrow \alpha_0 &\geq 1-\mathbb{P}(F \leq f) \\
\Leftrightarrow \alpha_0 &\geq \mathbb{P}(F \geq f)
\end{aligned} \tag{59}$$

Das kleinste $\alpha_0 \in [0,1]$ mit $\alpha_0 \geq \mathbb{P}(F \geq f)$ ist dann $\alpha_0 = \mathbb{P}(F \geq f)$, also folgt

$$\text{p-Wert} = \mathbb{P}(F \geq f) = 1 - \varphi(f; p-1, n-p). \tag{60}$$

Praktisches Vorgehen

- Man nimmt an, dass ein vorliegender Datensatz von p Gruppendatensätzen $\upsilon_{11}, ..., \upsilon_{1n_1}, \upsilon_{21}, ..., \upsilon_{2n_2}, \dots, \upsilon_{p1}, ..., \upsilon_{pn_p}$ Realisationen von $\upsilon_{1j} \sim N(\mu_0, \sigma^2)$ und $\upsilon_{ij} \sim N(\mu_0 + \alpha_i, \sigma^2)$ für $i = 2, ..., p$ mit wahre, aber unbekannten, Parametern $\mu_0, \alpha_i, i = 2, ..., p$ und $\sigma^2 > 0$ sind.
- Man möchte entscheiden ob $H_0 : \alpha_i = 0$ für alle $i = 2, ..., p$ eher zutrifft oder eher nicht.
- Man wählt ein Signifikanzniveau α_0 und bestimmt den zugehörigen Freiheitsgradparameter-abhängigen kritischen Wert k_{α_0}. Zum Beispiel gilt bei Wahl von $\alpha_0 := 0.05, p = 3, m = 12, i = 1, 2, 3$ und somit $n = 36$, dass $k_{\alpha_0} = \varphi^{-1}(1 - 0.05; 2, 33) \approx 3.28$ ist.
- Anhand der MSB und MSW berechnet man den realisierten Wert der F-Teststatistik, den wir hier mit f bezeichnen.
- Wenn f größer gleich k_{α_0} ist, lehnt man die Nullhypothese ab, andernfalls nicht.
- Die oben entwickelte Theorie garantiert dann, dass man im Mittel in höchstens $\alpha_0 \cdot 100$ von 100 Fällen die Nullhypothese fälschlicherweise ablehnt.
- Schließlich ergibt sich der assoziierte p-Wert der realisiertern F-Teststatistik $\tilde{F}$ zu

$$\text{p-Wert} = \mathbb{P}(F \geq f) = 1 - \varphi(f; p - 1, n - p) \tag{61}$$

Modellevaluation

Anwendungsbeispiel

```
# Dateneinlesen
fname       = file.path(getwd(), "10_Daten", "10_Einfaktorielle_Varianzanalyse_Daten.csv")
D           = read.table(fname, sep = ",", header = TRUE)

# Datengruppen
y_1         = D$dBDI[D$Setting == "F2F"]              # BDI Differenzwerte in der F2F Gruppe
y_2         = D$dBDI[D$Setting == "ONL"]              # BDI Differenzwerte in der ONL Gruppe
y_3         = D$dBDI[D$Setting == "WLC"]              # BDI Differenzwerte in der ONL Gruppe

# Modellformulierung
p           = 3                                        # drei Gruppen
m           = length(y_1)                              # balancierters Design mit n_i = 40
n           = p*m                                      # Datenvektordimension
y           = matrix(c(y_1, y_2, y_3), nrow = n)       # Datenvektor
Xt          = cbind(                                   # Designmatrix vollständiges Modell
              matrix(1, nrow = n, ncol = 1),
              kronecker(diag(p),
                        matrix(1, nrow = m, ncol = 1)))
X           = Xt[,-2]
X_0         = X[,1]                                    # Designmatrix reduziertes Modell

# F-Teststatistikevaluation
beta_hat    = solve(t(X) %*% X) %*% t(X) %*% y         # Betaparameterschätzer vollständiges Modell
beta_hat_0  = solve(t(X_0) %*% X_0) %*% t(X_0) %*% y   # Betaparameterschätzer reduziertes Modell
eps_hat     = y - X %*% beta_hat                       # Residuenvektor vollständiges Modell
eps_hat_0   = y - X_0 %*% beta_hat_0                   # Residuenvektor reduziertes Modell
SQT         = t(eps_hat_0) %*% eps_hat_0               # Sum of Squares Total
SQW         = t(eps_hat)   %*% eps_hat                 # Sum of Squares Within
SQB         = SQT - SQW                                # Sum of Squares Between
DFB         = p - 1                                    # Between Degrees of Freedom
DFW         = n - p                                    # Within  Degrees of Freedom
DFB         = p - 1                                    # Between Degrees of Freedom
MSB         = SQB/DFB                                  # Mean Sum of Squares Between
MSW         = SQW/DFW                                  # Mean Sum of Squares Within
Eff         = MSB/MSW                                  # F-Teststatistik
p           = 1 - pf(Eff, p-1, n-p)                    # p-Wert
```

Anwendungsbeispiel

```r
# Ausgabe
cat( "DFB :" , DFB,
    "\nDFW :", DFW,
    "\nSQB :", SQB,
    "\nSQW :", SQW,
    "\nMSB :", MSB,
    "\nMSW :", MSW,
    "\nF   :", Eff,
    "\np   :", paste(p))
```

```
> DFB : 2
> DFW : 117
> SQB : 1009
> SQW : 2153
> MSB : 504
> MSW : 18.4
> F   : 27.4
> p   : 1.7192636203589e-10
```

Anwendungsbeispiel

```r
# Dateneinlesen
fname      = file.path(getwd(), "10_Daten", "10_Einfaktorielle_Varianzanalyse_Daten.csv")
D          = read.table(fname, sep = ",", header = TRUE)

# Benutzung von R's aov Funktion und Ausgabe
res.aov = aov(D$dBDI ~ D$Setting, data = D)
summary(res.aov)
```

```
>              Df Sum Sq Mean Sq F value  Pr(>F)
> D$Setting     2   1009     504    27.4 1.7e-10 ***
> Residuals   117   2153      18
> ---
> Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Anwendungsszenario

Modellformulierung

Modellschätzung

Modellevaluation

Selbstkontrollfragen

Selbstkontrollfragen

1. Erläutern Sie das Anwendungsszenario einer einfaktoriellen Varianzanalyse (EVA).
2. Geben Sie die Definition des EVA Modells in Erwartungswertparameterdarstellung wieder.
3. Geben Sie die strukturelle Form des EVA Modells in Effektdarstellung wieder.
4. Erläutern Sie die Motivation für die Reparameterisierung des EVA Modells
5. Welche Bedeutung haben die Parameter $\mu_0, \alpha_2, ..., \alpha_p$ in der Effektparameterdarstellung des EVA Modells?
6. Warum gibt es bei p Gruppen eines EVA Szenarios nur die $p-1$ Effektparameter $\alpha_2, ..., \alpha_p$?
7. Geben Sie die Designmatrixform des EVA Modells in Effektdarstellung wieder.
8. Formulieren Sie die Designmatrix eines EVA Modells mit $n_i = 3$ und $p = 2$.
9. Formulieren Sie die Designmatrix eines EVA Modells mit $n_i = 2$ und $p = 5$.
10. Geben Sie das Theorem zur Betaparameterschätzung im EVA Modell wieder.
11. Mit welchen deskriptiven Statistiken werden die Parameter $\mu_0, \alpha_2, ..., \alpha_p$ eines EVA Modells geschätzt?
12. Geben Sie das Theorem zur Quadratsummenzerlegung bei einfaktorieller Varianzanalyse wieder.
13. Erläutern Sie die Begriffe Total Sum of Squares, Between Sum of Squares, Within Sum of Squares der EVA.
14. Geben Sie die Definition des Effektstärkenmaßes η^2 an.
15. Wann nimmt das Effektstärkenmaß η^2 der EVA seinen Minimalwert an und wie lautet dieser?
16. Wann nimmt das Effektstärkenmaß η^2 der EVA seinen Maximalwert an und wie lautet dieser?
17. Geben Sie das Theorem zur F-Teststatistik der EVA wieder.
18. Erläutern Sie die Begriffe Mean Between Sum of Squares und Mean Within Sum of Squares der EVA.
19. Geben Sie das Theorem zum Zusammenhang von Effektstärkenmaß η^2 und F-Teststatistik der EVA wieder.
20. Geben Sie die Definition des EVA F-Test wieder.
21. Erläutern sie die Null- und Alternativhypothesen des EVA F-Tests.
22. Geben Sie das Theorem zur Testumfangkontrolle der EVA wieder.
23. Skizzieren Sie den Beweis zur Testumfangkontrolle der EVA.
24. Geben Sie den p-Wert zum F-Test der EVA wieder.

References

Georgii, Hans-Otto. 2009. *Stochastik: Einführung in die Wahrscheinlichkeitstheorie und Statistik*. 4., überarb. und erw. Aufl. De-Gruyter-Lehrbuch. Berlin: de Gruyter.