


# Datenanalyse – Sitzung 7

## Varianzanalyse

---

Institut für Kommunikationswissenschaft und Medienforschung  
Ludwig-Maximilians-Universität München



# Ablauf der Sitzung

1. Wiederholung Varianzanalyse & Quadratsummenzerlegung
2. Übungsblatt: Aufgabe 1 (Hausaufgabe)
3. Quadratsummenzerlegung
4. Übungsblatt: Aufgabe 2
5. Berechnung der Effektstärke
6. Varianzanalyse in R
7. Übungsblatt: Aufgabe 3 (mit R)

# WIEDERHOLUNG: VARIANZANALYSE & QUADRATSUMMENZERLEGUNG

# Varianzanalyse

- Die Varianzanalyse untersucht den Einfluss einer oder mehrerer gestufter unabhängiger Variablen (UV) auf eine oder mehrere abhängige Variablen (AV)
- Terminologie:
  - Faktor = UV (manchmal auch: Treatment)
  - Faktorstufen = Ausprägungen der UV
- Eine Varianzanalyse wird nur bei **mehr als zwei Faktorstufen** durchgeführt
- Arten von Varianzanalysen:
 

■ Eine UV +	eine AV:	<b>Einfaktorielle ANOVA</b>	(= (Univariate) Analysis of Variance)
■ Mehrere UVs +	eine AV:	<b>Mehrfaktorielle ANOVA</b>	
■ Eine UV +	mehrere AVs:	<b>Einfaktorielle MANOVA</b>	(= Multivariate Analysis of Variance)
■ Mehrere UVs +	mehrere AVs:	<b>Mehrfaktorielle MANOVA</b>	

# Varianzanalyse

- Funktion: Signifikanztest, ob die (Teil-)Stichproben aus Grundgesamtheiten stammen, deren Parameter  $\mu_1, \mu_2, \dots, \mu_k$  identisch sind  
das heißt: ob sich die Mittelwerte mehrerer Gruppen systematisch voneinander unterscheiden.
- Hypothesen (zweiseitige Problem):
  - $H_0: \mu_1 = \mu_2 = \dots = \mu_k$
  - $H_1: \neg H_0$  (mindestens ein Unterschied bei den Mittelwerten)
- Gemeinsamkeit mit dem  $t$ -Test: Gruppen werden anhand ihrer Mittelwerte verglichen
- Unterschiede zum  $t$ -Test
  - Mehr als zwei Gruppen werden verglichen
  - Mehrfaktorielle Designs möglich (mehrere UVs)
  - $F$ -Test statt  $t$ -Test

# Voraussetzungen für die Varianzanalyse

- Die Fehlerkomponenten entstammen normalverteilten Grundgesamtheiten. Dafür ist nach dem zentralen Grenzwertsatz ein Stichprobenumfang größer 30 hinreichend.
- Die Messwerte sind in allen Bedingungen voneinander unabhängig.
- Die Abhängige Variable ist (quasi-)metrisch skaliert.
- Die Varianzen der Populationen der untersuchten Faktorstufen müssen gleich sein. Die Varianzhomogenität wird mit dem Levene-Test ermittelt (Details folgen).

# ÜBUNGSBLATT: AUFGABE 1 (HAUSAUFGABE)

# Aufgabe 1

Bestimmen Sie für folgende Fragestellungen jeweils die Freiheitsgrade und den kritischen  $F$ -Wert.

- a) Es wurde ein Experiment zur Werbewirkung durchgeführt. Die Versuchspersonen sahen unterschiedliche Versionen eines Werbespots. Insgesamt gab es vier Gruppen: Werbespot mit Humor, mit Erotik, mit Prominenten und mit Tieren. In jeder Gruppe waren 31 Versuchspersonen (Signifikanzniveau von 1%).
- b) Eine Studie hat die durchschnittliche Vor- und Nachbereitungszeit von Studierenden an der LMU untersucht. Untersucht wurden 50 Studierende der BWL, 40 der KW, 60 der Medizin, 40 der Soziologie und 40 der Rechtswissenschaften (Signifikanzniveau von 5%).

# Lösung: Aufgabe 1

$$df_X = k - 1$$

$$df_e = N - k$$

a.  $k = 4; N = 124$

$$\text{Zähler-df} = k - 1 = \mathbf{3}$$

$$\text{Nenner-df} = N - k = \mathbf{120}$$

$$F_{krit} = \mathbf{3,98} \quad (\alpha = 1\%)$$

b.  $k = 5; N = 230$

$$\text{Zähler-df} = k - 1 = \mathbf{4}$$

$$\text{Nenner-df} = N - k = \mathbf{225}$$

$$F_{krit} = \mathbf{2,42} \quad (\alpha = 5\%)$$

Tabelle: Kritische Werte der F-Verteilung

$\alpha = 1\%$

df2 (Nenner)	df1 (Zähler)						
	1	2	3	4	5	6	7
100	6,90	4,82	3,98	3,51	3,21	2,99	2,82
125	6,84	4,78	3,94	3,47	3,17	2,95	2,79

$df_e = 120$   
liegt dazwischen

Wir nehmen den  
konservativeren Wert

$\alpha = 5\%$

df2 (Nenner)	df1 (Zähler)						
	1	2	3	4	5	6	7
200	3,89	3,04	2,65	2,42	2,26	2,14	2,06
250	3,88	3,03	2,64	2,41	2,25	2,13	2,05

# QUADRATSUMMENZERLEGUNG

# Quadratsummenzerlegung

- **Totale Quadratsumme ( $QS_{tot}$ ):**  
Gesamte Variabilität der Messwerte  
(wie Varianz, nur ohne Division durch den Stichprobenumfang)
- **Treatmentquadratsumme ( $QS_X$ ):**  
Variabilität, die durch Treatment erklärt wird  
(wie oben, aber mit Gruppenmittelwerten statt allen Messwerten)
- **Fehlerquadratsumme ( $QS_e$ ):**  
Variabilität durch zufällige oder nicht untersuchte Einflüsse  
(Abweichungen der Gruppenmesswerte vom Gruppenmittelwert)
- **Additivitätsprinzip:**

$$QS_{tot} = \sum_j \sum_i (y_{ij} - \bar{y})^2$$

mit  $df_{tot} = N - 1$

$$QS_X = \sum_j n_j (\bar{y}_j - \bar{y})^2$$

mit  $df_x = k - 1$

$$QS_e = \sum_j \sum_i (y_{ij} - \bar{y}_j)^2$$

mit  $df_e = N - k$


$$QS_{tot} = QS_X + QS_e$$

mit  $df_{tot} = df_x + df_e$


# Quadratsummenzerlegung

$$QS_{tot} = \sum_j \sum_i (y_{ij} - \bar{y})^2$$

Totale Quadratsumme  $QS_{tot}$




Anteil an  $QS_{tot}$




$$\begin{aligned}
 QS_{tot} = & -5.5^2 + -4.5^2 + -3.5^2 + -2.5^2 + \\
 & -1.5^2 + -0.5^2 + 0.5^2 + 1.5^2 + \\
 & 2.5^2 + 3.5^2 + 4.5^2 + 5.5^2 \\
 = & 143
 \end{aligned}$$

# Quadratsummenzerlegung

## Treatmentquadratsumme $QS_X$



$$QS_X = \sum_j n_j (\bar{y}_j - \bar{y})^2$$





$$QS_X = 4 \times (-4^2 + 0^2 + 4^2) = 128$$

↑  
Gewichtung  
(Anzahl der  
Beobachtungen  
pro Faktorstufe)

# Quadratsummenzerlegung

## Fehlerquadratsumme $QS_e$



$$QS_e = \sum_j \sum_i (y_{ij} - \bar{y}_j)^2$$



$$QS_e = -1.5^2 + -0.5^2 + 0.5^2 + 1.5^2 + -1.5^2 + -0.5^2 + 0.5^2 + 1.5^2 + -1.5^2 + -0.5^2 + 0.5^2 + 1.5^2 = 15$$

# Quadratsummenzerlegung

Fehlerquadratsumme  $QS_e$



$$QS_{tot} = QS_X + QS_e$$

$$143 = 128 + 15$$

# ÜBUNGSBLATT: AUFGABE 2

## Aufgabe 2

Wir wollen herausfinden, wie sich verschiedene Substanzen auf die Note (Statistik-Klausur) auswirken. Wir teilen 18 Studierende zufällig in drei Gruppen, je nach Gruppenzuordnung erhalten sie vor der Klausur Placebo, Traubenzucker oder Kaffee.

Prüfen Sie die Hypothese, dass die eingenommene Substanz einen Einfluss auf die Klausurnote hat ( $\alpha = 0,05$ ).

# Aufgabe 2

	$j = 1$ Placebo	$j = 2$ Traubenzucker	$j = 3$ Kaffee		$N = 18$ $n = 6$
$i = 1$	1,0	1,7	2,3		
$i = 2$	1,7	2,7	3,3		
$i = 3$	1,3	2,3	5,0		
$i = 4$	4,0	1,7	1,0		
$i = 5$	3,3	2,0	1,7		
$i = 6$	3,7	2,7	1,3		
$SY_j$	15,0	13,1	14,6	$SY$	42,7
$\bar{y}_j$	2,50	2,18	2,43	$\bar{y}$	2,37

# Formeln (vereinfachte Berechnung)

- **Gleiche Stichprobengrößen (balanciertes Design)**

$$(1) = \frac{SY^2}{N} \quad (2) = \sum_j \sum_i y_{ij}^2 \quad (3) = \frac{\sum_j SY_j^2}{n}$$

- **Ungleiche Stichprobengrößen**

$$(1) = \frac{SY^2}{N} \quad (2) = \sum_j \sum_i y_{ij}^2 \quad (3) = \sum_j \left( \frac{SY_j^2}{n_j} \right)$$

- **Quadratsummen**

$$QS_X = (3) - (1) \quad \text{mit} \quad df_X = k - 1 \quad (\text{Zähler})$$

$$QS_e = (2) - (3) \quad \text{mit} \quad df_e = N - k \quad (\text{Nenner})$$

- **Mittlere Quadrate und Prüfgröße**

$$MQ_X = \frac{QS_X}{df_X} \quad MQ_e = \frac{QS_e}{df_e} \quad F = \frac{MQ_X}{MQ_e}$$

<b>Y</b>	Abhängige Variable
<b>X</b>	Unabhängige Variable bzw. Faktor
<b>k</b>	Anzahl der Faktorstufen
<b>j</b>	Kennzeichnung der Faktorstufe
<b>i</b>	Beobachtung (z.B. „Person“) innerhalb einer Faktorstufe
<b>N</b>	Gesamtzahl der Beobachtungen
<b>n<sub>j</sub></b>	Anzahl der Beobachtungen der j-ten Faktorstufe
<b>y<sub>ij</sub></b>	i-te Beobachtung von Y in der j-ten Faktorstufe
<b><math>\bar{y}_j</math></b>	arithmetisches Mittel aller Messwerte unter der j-ten Faktorstufe
<b>SY</b>	Gesamtsumme aller Messwerte für Y
<b>SY<sub>j</sub></b>	Summe der beobachteten Werte unter der j-ten Faktorstufe
<b>QS<sub>x</sub></b>	Treatmentquadratsumme
<b>QS<sub>e</sub></b>	Fehlerquadratsumme
<b>df<sub>x</sub></b>	Freiheitsgrade (Treatment) (Zähler)
<b>df<sub>e</sub></b>	Freiheitsgrade (Fehler) (Nenner)
<b>MQ<sub>x</sub></b>	Mittlere Quadrate (Treatment)
<b>MQ<sub>e</sub></b>	Mittlere Quadrate (Fehler)
<b>F</b>	Prüfgröße F

## Lösung: Aufgabe 2

Gleiche Stichprobengrößen

$$(1) = \frac{SY^2}{N} = \frac{42,7^2}{18} = 101,29$$

	<i>j</i> = 1 Placebo	<i>j</i> = 2 Traubenzucker	<i>j</i> = 3 Kaffee		<i>N</i> = 18 <i>n</i> = 6
<i>i</i> = 1	1,0	1,7	2,3		
<i>i</i> = 2	1,7	2,7	3,3		
<i>i</i> = 3	1,3	2,3	5,0		
<i>i</i> = 4	4,0	1,7	1,0		
<i>i</i> = 5	3,3	2,0	1,7		
<i>i</i> = 6	3,7	2,7	1,3		
<i>SY<sub>j</sub></i>	15,0	13,1	14,6	<i>SY</i>	42,7
<i>ȳ<sub>j</sub></i>	2,50	2,18	2,43	<i>ȳ</i>	2,37

## Lösung: Aufgabe 2

Gleiche Stichprobengrößen

$$(1) = \frac{SY^2}{N} = \frac{42,7^2}{18} = 101,29$$

$$(2) = \sum_j \sum_i y_{ij}^2 = 1,0^2 + 1,7^2 + 1,3^2 + \dots + 1,3^2 = 122,57$$

	<i>j</i> = 1 Placebo	<i>j</i> = 2 Traubenzucker	<i>j</i> = 3 Kaffee		<i>N</i> = 18 <i>n</i> = 6
<i>i</i> = 1	1,0	1,7	2,3		
<i>i</i> = 2	1,7	2,7	3,3		
<i>i</i> = 3	1,3	2,3	5,0		
<i>i</i> = 4	4,0	1,7	1,0		
<i>i</i> = 5	3,3	2,0	1,7		
<i>i</i> = 6	3,7	2,7	1,3		
<i>SY<sub>j</sub></i>	15,0	13,1	14,6	<i>SY</i>	42,7
$\bar{y}_j$	2,50	2,18	2,43	$\bar{y}$	2,37

## Lösung: Aufgabe 2

Gleiche Stichprobengrößen

$$(1) = \frac{SY^2}{N} = \frac{42,7^2}{18} = 101,29$$

$$(2) = \sum_j \sum_i y_{ij}^2 = 1,0^2 + 1,7^2 + 1,3^2 + \dots + 1,3^2 = 122,57$$

$$(3) = \frac{\sum_j SY_j^2}{n} = \frac{15^2 + 13,1^2 + 14,6^2}{6} = 101,63$$

## Lösung: Aufgabe 2

Gleiche Stichprobengrößen

$$(1) = \frac{SY^2}{N} = \frac{42,7^2}{18} = 101,29$$

$$(2) = \sum_j \sum_i y_{ij}^2 = 1,0^2 + 1,7^2 + 1,3^2 + \dots + 1,3^2 = 122,57$$

$$(3) = \frac{\sum_j SY_j^2}{n} = \frac{15^2 + 13,1^2 + 14,6^2}{6} = 101,63$$

Quadratsummen

$$QS_X = (3) - (1) = 101,63 - 101,29 = 0,34$$

$$df_X = k - 1 = \mathbf{2}$$

$$QS_e = (2) - (3) = 122,57 - 101,63 = 20,94$$

$$df_e = N - k = \mathbf{15}$$

## Lösung: Aufgabe 2

Gleiche Stichprobengrößen

$$(1) = \frac{SY^2}{N} = \frac{42,7^2}{18} = 101,29$$

$$(2) = \sum_j \sum_i y_{ij}^2 = 1,0^2 + 1,7^2 + 1,3^2 + \dots + 1,3^2 = 122,57$$

$$(3) = \frac{\sum_j SY_j^2}{n} = \frac{15^2 + 13,1^2 + 14,6^2}{6} = 101,63$$

Quadratsummen

$$QS_X = (3) - (1) = 101,63 - 101,29 = 0,34$$

$$QS_e = (2) - (3) = 122,57 - 101,63 = 20,94$$

$$df_X = k - 1 = \mathbf{2}$$

$$df_e = N - k = \mathbf{15}$$

Mittlere Quadrate und Prüfgröße

$$MQ_X = \frac{QS_X}{df_X} = \frac{0,34}{2} = 0,17$$

$$MQ_e = \frac{QS_e}{df_e} = \frac{20,94}{15} = 1,39$$

$$F = \frac{MQ_X}{MQ_e} = \frac{0,17}{1,39} = \mathbf{0,12}$$

**Zur Interpretation:**

$MQ_X$  viel kleiner als  $MQ_e$  → das Treatment erklärt nur einen geringen Anteil der Gesamtvariabilität, entsprechend gering ist auch der  $F$ -Wert

# Lösung: Aufgabe 2


Kritischer  $F$ -Wert bei  $\alpha = 0,05$   
für  $df_X = 2$  und  $df_e = 15$

$F_{krit} = 3,68$

**H1 wird abgelehnt,**

da  $F = 0,12 < F_{krit} = 3,68$

**Ergebnis:** Die Hypothese wird abgelehnt, die eingenommene Substanz hat keinen Einfluss auf die Klausurnote. Zwar schneidet die Traubenzucker-Gruppe im Mittel ( $M = 2,18$ ;  $SD = 0,46$ ) besser ab als die Koffein-Gruppe ( $M = 2,43$ ;  $SD = 1,50$ ) und die Placebo-Gruppe ( $M = 2,50$ ;  $SD = 1,32$ ), der Unterschied ist allerdings nicht signifikant und damit nicht auf die Grundgesamtheit übertragbar ( $F(2, 15) = 0,12$ ;  $p = n. s.$ ).



# BERECHNUNG DER EFFEKTSTÄRKE

# Effektstärke: $\eta^2$

- Maß der „**Varianzaufklärung**“ in den beobachteten Werten:
  - beziffert den Anteil der beobachteten Variation in der abhängigen Variable, die auf den Einfluss der unabhängigen Variable (d.h. dem Faktor) zurückzuführen ist
- Wertebereich: 0,0 bis 1,0 (bzw. 0% bis 100%)

$$\eta^2 = \frac{QS_X}{QS_{tot}} = \frac{QS_X}{QS_X + QS_e}$$

Beispiel aus Aufgabe 2:  $\eta^2 = \frac{QS_X}{QS_{tot}} = \frac{0,34}{21,28} = \mathbf{0,016}$

→ Die eingenommene Substanz erklärt 1,6 Prozent der Varianz der Klausurnote.

## Wichtige Take-Aways

- **Varianzanalyse/Anova:** Prüft, ob sich drei oder mehr Gruppen in einem (metrischen) Merkmal unterscheiden
- Effektstärke:  $\eta^2$  (Anteil der Varianzaufklärung)



# VARIANZANALYSE IN R

# Varianzanalyse berechnen mittels `tidycomm`

Sie können die Varianzanalyse mit dem `tidycomm` Package berechnen. Dafür können Sie die folgende Funktion nutzen:

`unianova()`

## Struktur:

```
data %>%  
  unianova(independent_variable,  
           dependent_variable,  
           post_hoc = TRUE)
```

# Varianzanalyse in R

**Beispielhypothese:** Journalist\*innen nehmen je nach Beschäftigungsverhältnis (Vollzeit, Teilzeit, selbstständig) ihre Autonomie unterschiedlich wahr

## Schritt 1:

- Mithilfe der Funktion `dplyr::group_by()` die zu vergleichenden Gruppen/unabhängige Variable definieren  
**Einsetzen:** unabhängige Variable/Gruppen (employment)
- Dann mit `tidycomm::describe` die Voraussetzungen prüfen  
**Einsetzen:** abhängige Variable (autonomy\_emphasis)

## Befehl:

```
woj %>%  
  dplyr::group_by(employment) %>%  
  describe(autonomy_emphasis)
```

# Varianzanalyse in R

## Ausgabe (Schritt 1):

```
# A tibble: 3 × 16
# Groups:   employment [3]
  employment Variable      N Missing    M    SD  Min  Q25  Mdn  Q75  Max Range CI_95_LL CI_95_UL Skewness Kurtosi
* <chr>      <chr>    <int> <int> <dbl> <dbl>
1 Freelancer autonomy_emphasis  171     1  3.90 0.852    1    4    4    4    5    4    3.77    4.03  -0.956    4.3
2 Full-time  autonomy_emphasis  898     4  4.12 0.781    1    4    4    5    5    4    4.07    4.17  -0.827    3.9
3 Part-time  autonomy_emphasis  126     0  4.02 0.759    1    4    4    4    5    4    3.88    4.15  -1.35    7.1
```

- ✓ Alle Teilstichproben > 30
- ✓ Drei (> 2) Faktorstufen, die voneinander unabhängig sind
- ✓ Abhängige Variable (autonomy\_emphasis) = quasimetrisch
- ? (Varianzhomogenität: siehe nächste Folie)

# Varianzanalyse in R

**Schritt 2:** Mithilfe der Funktion `tidycmm::unianova()` die Varianzanalyse berechnen  
**Einsetzen:** unabhängige Variable/Gruppen (employment), abhängige Variable (autonomy\_emphasis)

## Befehl:

```
WoJ %>% unianova(employment, autonomy_emphasis)
```

## Ausgabe:

```
# A tibble: 1 × 8
  Variable      F df_num df_denom      p eta_squared Levene_p var_equa
* <chr>      <num:.3!> <dbl> <dbl> <num:.3!> <num:.3!> <dbl> <chr>
1 autonomy_emphasis 5.861      2 1192 0.003 0.010 0.175 TRUE
```

Ist der Levene-Test signifikant (d.h. es liegt keine **Varianzhomogenität** vor) muss eine Korrektur der Freiheitsgrade vorgenommen werden. Die `unianova()`-Funktion rechnet dann automatisch den Welch-Test und gibt als Effektstärke das konservativere Omega-Quadrat aus.

**Ergebnis, Teil 1:** Das Beschäftigungsverhältnis hat einen signifikanten Effekt auf die Wahrnehmung der Autonomie durch Journalist\*innen. Es erklärt jedoch nur 1,0 Prozent der Varianz der abhängigen Variable ( $F(2,1192) = 5,86; p = ,003; \eta^2 = ,010$ )

# Varianzanalyse in R


Der F-Test ist ein globaler Test. Ein signifikantes Testergebnis belegt Unterschiede zwischen mindestens zwei Faktorstufen, aber nicht, *welche* Faktorstufen sich signifikant voneinander unterscheiden. Um das zu prüfen, wird bei einem signifikanten Ergebnis ein Post hoc-Test durchgeführt.

## Schritt 3 (wenn Ergebnis signifikant):

- Durch das zusätzliche Argument `post_hoc = TRUE` einen Post hoc-Tests durchführen  
(Es gibt verschiedene Post hoc-Tests. Standardmäßig wird **Tukey's HSD** gerechnet, sind die Varianzen zu verschieden (ablesbar am Levene-Test), wird automatisch **Games-Howell** angewendet)
- Die Analyse in einem separaten Modell (model2) speichern und dann mit `View()` anzeigen

```
model2 <- WoJ %>% unianova(employment, autonomy_emphasis, post_hoc = TRUE)
View(model2)
```


Für das Ergebnis muss mit der Maus die kleine Tabelle in der Zelle unter `post_hoc` ausgewählt werden



Variable	F	df_num	df_denom	p	eta_squared	post_hoc	Levene_p	var_equal
1 autonomy_emphasis	5.861	2	1192	0.003	0.010	1 variable 	0.175	TRUE

# Varianzanalyse in R

## Ausgabe:



	Group_Var	contrast	Delta_M	conf_lower	conf_upper	p	d
2	employment	Full-time-Part-time	-0.1021671	-0.2783892	0.07405504	0.362143840	-0.1326677
1	employment	Full-time-Freelancer	-0.2174553	-0.3720115	-0.06289907	0.002843092	-0.2660905
3	employment	Part-time-Freelancer	-0.1152882	-0.3327729	0.10219650	0.427505854	-0.1429371

→ Für jedes Faktorenpaar wird angegeben, ob ein signifikanter Unterschied vorliegt.

**Ergebnis, Teil 2:** Für den Post hoc\_Test wurde Tukey's HSD gerechnet, da Varianzhomogenität angenommen werden darf. Hier zeigt sich, dass die freiberuflichen Journalist\*innen signifikant weniger Autonomie wahrnehmen als ihre Kolleg\*innen in Vollzeit. Es gibt jedoch keinen signifikanten Unterschied zwischen den freiberuflich Beschäftigten und Teilzeitbeschäftigten, die sich wiederum auch nicht von den Vollzeitbeschäftigten unterscheiden ( $n_V = 898$ ;  $M_V = 4,12$ ;  $SD_V = 0,78$ ;  $n_T = 126$ ;  $M_T = 4,02$ ;  $SD_T = 0,76$ ;  $n_S = 171$ ;  $M_S = 3,90$ ;  $SD_S = 0,85$ )

# ÜBUNGSBLATT: AUFGABE 3 (MIT R)

# Aufgabe 3

Rufen Sie den Datensatz „WoJ“ in R auf.

Prüfen Sie die Hypothese, dass Journalist\*innen aus Dänemark, Deutschland und dem Vereinigten Königreich unterschiedlich stark der Aussage zustimmen, dass Ethik im Journalismus eine Frage der persönlichen Beurteilung ist (ethics\_3).

Vorbereitung: Filtern Sie vorher mit der Funktion `dplyr::filter()` den Datensatz nach den entsprechenden Ländern:

```
WoJ_filtered <- WoJ %>%  
  filter(country == "UK" | country == "Denmark" | country == "Germany")
```

# Aufgabe 3

## Schritt 1: Voraussetzungsprüfung

```
> WoJ_filtered %>%
+   dplyr::group_by(country) %>%
+   describe(ethics_3)
# A tibble: 3 × 16
# Groups:   country [3]
  country Variable      N Missing      M      SD   Min   Q25   Mdn   Q75   Max Range CI_95_LL CI_95_UL Skewness Kurtosis
* <fct>   <chr>      <int>  <int> <dbl> <dbl>
1 Denmark ethics_3    376     0  2.55  1.21     1     2     2     4     5     4     2.43     2.68     0.296     1.88
2 Germany ethics_3    173     0  2.01  0.961    1     1     2     3     5     4     1.86     2.15     0.579     2.47
3 UK      ethics_3    211     0  2.70  1.28     1     2     2     4     5     4     2.52     2.87     0.130     1.69
```

## Schritt 2: Varianzanalyse

```
> WoJ_filtered %>% unianova(country, ethics_3)
The significant result from Levene's test suggests unequal variances among the groups, violating standard ANOVA assumptions. This necessitates the use of Welch's ANOVA, which is robust against heteroscedasticity.
# A tibble: 1 × 8
  Variable      F df_num df_denom      p omega_squared Levene_p var_equal
* <chr>   <num:.3!> <dbl>   <dbl> <num:.3!> <num:.3!> <dbl> <chr>
1 ethics_3  23.187     2     422  0.000     0.044     0 FALSE
```

# Aufgabe 3

## Schritt 3: Post hoc-Test

```
posthoc <- WoJ_filtered %>%
  unianova(country, ethics_3, post_hoc = TRUE)
View(posthoc)
```

Group_Var	contrast	Delta_M	conf_lower	conf_upper	p	d	se	t	df
country	Denmark-Germany	-0.5474111	-0.7731265	-0.3216957	6.677094e-08	-0.5020697	0.06785301	5.704657	411
country	Denmark-UK	0.1434910	-0.1103003	0.3972823	3.793634e-01	0.1153654	0.07629398	1.329901	413
country	Germany-UK	0.6909021	0.4213886	0.9604156	1.154186e-08	0.6100483	0.08099387	6.031834	379

**Ergebnis:** Das Land hat einen signifikanten Effekt auf die Wahrnehmung journalistischer Ethik als Frage der persönlichen Beurteilung. Es erklärt aber nur 4,4 Prozent der Varianz der abhängigen Variable. Da keine Varianzhomogenität vorlag, wurde der Games-Howell Post hoc-Test gerechnet. Er zeigte, sich alle Länder signifikant voneinander unterscheiden. In Deutschland wird Ethik am wenigsten als persönliche Frage wahrgenommen, im Vereinigten Königreich am meisten ( $n_{Dä} = 376$ ;  $M_{Dä} = 2,55$ ;  $SD_{Dä} = 1,21$ ;  $n_{De} = 173$ ;  $M_{De} = 2,01$ ;  $SD_{De} = 0,96$ ;  $n_{VK} = 211$ ;  $M_{VK} = 2,70$ ;  $SD_{VK} = 1,28$ ;  $F(2,422) = 23,19$ ;  $p = < ,001$ ;  $\eta^2 = ,044$ )

# Wichtige Take-Aways

- **Varianzanalyse in R:** berechnen mit
  - `dplyr::group_by()` und `tidycomm::describe()` für die Voraussetzungsprüfung und
  - `tidycomm::unianova` mit dem Argument `posthoc = TRUE` für den Post hoc-Test (testet bei einem signifikanten Ergebnis, *welche* Faktorstufen sich signifikant voneinander unterscheiden)



**DANKE FÜR IHRE AUFMERKSAMKEIT!**