

Einfaktorielle Varianzanalyse mit festen Effekten

1. WARUM?

Varianzanalysen werden durchgeführt, um Hypothesen zu testen, d.h. ob sich ein oder mehrere Faktoren signifikant auf einen Messwert auswirken.

Bisher: _____

Problem I: Faktor hat mehr als 2 Stufen

Bisher: _____

Folgeproblem: Inflation des α Fehlers

= je mehr Paarvergleiche umso höher wird die Wahrscheinlichkeit einen α Fehler zu begehen und zwar exponential mit der Anzahl der Vergleich m

$$p(\text{Fehler}) = 1 - (1 - \alpha)^m$$

z.B. für Faktor Konsonant aus der Klausur:

Anzahl der Paarvergleich: 15

R Befehl choose(6, 2)

$$p = 1 - (1 - 0.05)^{15} = 0.54$$

d.h. die Wahrscheinlich bei 15 Paarvergleichen einen α Fehler zu begehen ist 54%

Lösung 1: **Bonferroni**-Korrektur = das α -Niveau für jeden Einzeltest wird soweit herabgesetzt, dass das Gesamtniveau nur noch 0.05 beträgt (α /Anzahl der Tests).

Lösung 2: Mehrstufige Faktoren können getestet werden ohne Korrektur mittels der Varianzanalyse

Problem II: mehrere Faktoren könnten sich auf eine abhängige Variable auswirken (z.B. Geschlecht und Akzent auf Grundfrequenz).

2. VORAUSSETZUNGEN

- 1) Mindestens Intervallskalenniveau und Normalverteilung innerhalb der Stichprobe bei der abhängigen Variablen
- 2) Mindestens 20 Elemente pro Stichprobe (Gruppe, Zelle)
- 3) Ähnlich stark besetzte Gruppen (gleiches N)
- 4) Varianzhomogenität der abhängigen Variablen zwischen den einzelnen Stichproben (s. Bartlett-Test)

3. BERECHNUNG

Beispiel Kieferhöhe während der Konsonanten /s, ʃ, t, d, n, l/ von einem Sprecher (AW) mit k=9 Messungen pro Faktorstufe, p=6 Faktorstufen und insgesamt N = 9*6 = 54 Messungen .

		i Faktorstufen							
Zeilen	Spalten	JC	AW	S	\$	T	D	N	L
j Messwerte	1	1.259	1.318	1.665	1.081	0.283	-1.133		
	2	1.339	1.206	1.735	0.804	-0.351	-1.533		
	3	1.291	0.909	1.569	0.374	-0.498	-1.846		
	4	1.174	1.040	1.342	0.298	-0.066	-1.287		
	5	1.178	1.004	1.127	0.274	-0.840	-1.284		
	6	1.128	1.052	1.381	0.261	-0.335	-1.730		
	7	1.298	1.129	1.469	0.963	0.154	-1.206		
	8	1.325	0.827	1.495	0.404	0.444	-1.900		
	9	1.260	1.041	1.530	0.428	-1.500	-1.375		

→ Messwert x_{ij}

= Vergleich der Varianzen der einzelnen Faktorstufen mit der Gesamtvarianz. Ist die Varianz der einzelnen Faktorstufen wesentlich größer als die zufällige Gesamtvarianz in den Daten, dann hat der Faktor einen signifikanten Einfluss.

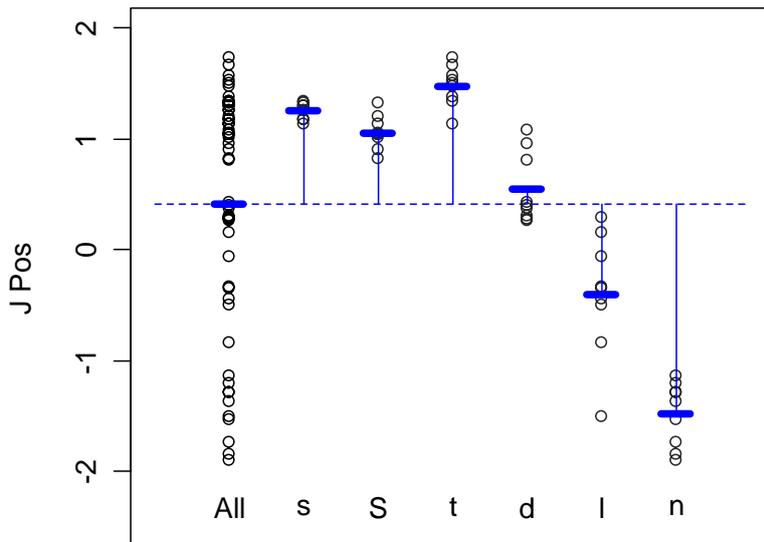
Die Gesamtvarianz lässt sich demnach zerlegen in folgende Quadratsummen (SS)

$$SS_{total} = SS_{treatment} - SS_{error}$$

$SS_{treatment}$ = Varianz, die sich aus den Faktorstufen ergibt (auch $SS_{between}$)

SS_{error} = Varianz, die sich aus mehreren Messungen ergeben (auch SS_{within})

Wichtig: Zusammenhang Quadratsummen – Varianz: $SS = var * df$



$SS_{treatment}$ = Summe der blauen senkrechten Linien
 SS_{error} = Abweichungen pro Faktorstufen
 SS_{total} = Abweichung aller Daten (vgl. All)

 Modellgleichung:
 $x_{ij} = \mu + \tau_i + \epsilon_{ij}$

rep(0, nrow(pos_aw))

Schritte:

1. Berechnung Faktorstufenvarianzen $SS_{treatment}$

Summe der Abweichungsquadrate innerhalb der Faktorstufen = $SS_{treatment}$

(fettgedrucktes x bedeutet im Folgenden Mittelwert, i bezieht sich auf die Faktorstufen und j auf die Messungen).

	S	\$	T	D	N	L	$\bar{x}_{..}$
\bar{x}_i	1.25	1.06	1.48	0.54	-0.40	-1.48	0.41
$\bar{x}_i - \bar{x}_{..}$	0.84	0.65	1.07	0.13	-0.81	-1.89	
$(\bar{x}_i - \bar{x}_{..})^2$	0.71	0.42	1.14	0.02	0.65	3.6	Sum 6.5

$$SS_{treatment} = r \sum (\bar{x}_i - \bar{x}_{..})^2 \quad \text{Sum of squares - treatment}$$

$$MS_{treatment} = \frac{SS_{treatment}}{df_{treatment}} \quad \text{Mean Square (variance) - treatment}$$

$$SS_{treatment} = \text{Sum} * \text{Anz.Messwerte} = 6.5 * 9 = 58.5$$

$$MS_{treatment} = SS_{treatment} / df_{treatment} = 58.5 / 5$$

2. Berechnung Fehlervarianz SS_{error}

= Varianz, die durch die Abweichungen vom Faktormittelwert bei z.B. mehrfachen Wiederholungen entstehen („weil die Versuchsperson nicht exakt immer das Gleiche gemacht hat“).

$$SS_{error} = \sum (x_{ij} - \bar{x}_i.)^2$$

$$SS_{error} = \text{sum}(\text{tapply}(\text{pos_aw}\$JC, \text{pos_aw}\$cons, \text{var})) * 8 = 4.25$$

$$MS_{error} = SS_{error} / df = 4.25 / 48$$

3. Berechnung Gesamtvarianz SS_{tot}

$$SS_{tot} = \sum (x_{ij} - \bar{x}_{..})^2$$

$$SS_{tot} = \text{var}(\text{pos_aw}\$JC) * (9 * 6 - 1) = 62.79$$

4. Berechnung F Wert

Zugrundeliegende Modellgleichung

$$x_{ij} = \mu + \tau_i + \epsilon_{ij}$$

Jeder Messwert x_{ij} setzt sich zusammen aus dem Gesamtmittelwert, dem Einfluss des Faktors τ_i und zufälliger Variation ϵ_j , die nicht auf den Faktor zurückzuführen ist.

Ob der Faktor nun wichtiger ist als die Fehlervarianz, läßt sich durch den F-Wert schätzen

$$F = MS_{\text{treatment}} / MS_{\text{error}}$$

mit $df_{\text{treatment}} = \text{Faktorstufen} - 1 (p - 1)$ und $df_{\text{error}} = \text{Gesamt} - \text{Faktorstufen} (N - p)$

Nullhypothese:

$$H_0: \tau_s = \tau_t = \tau_d = \tau_l = \tau_n = 0$$

4. INTERPRETATION

Befehle in R:

```
anova(lm(pos_aw$JC ~ pos_aw$cons))
oder
summary(aov(pos_aw$JC ~ pos_aw$cons))
```

Ergebnis aus R mit



- `df.treatment` entspricht Werten für *treatment*
- `df.residual` entspricht den Werten für *error*
- SS sind in Spalte `SS` und MS in Spalte `MS`
- Da $MS_{\text{treatment}}$ wesentlich größer ist als MS_{error} , wird der F-Wert ziemlich groß (132.18).
- Ein großer F-Wert ist meistens auch signifikant (siehe Tabellen in Statistikbüchern).
- Ergebnis (wie es in wissenschaftlichen Artikeln, Masterarbeiten und Statistikklausuren berichtet werden sollte): der Konsonant hat einen signifikanten Einfluss (**$F(5,48)=132.18, p<0.001$**) auf die Kieferposition während des Konsonanten.

Wiederholung ANOVA

1. Warum heißt dieses Verfahren Varianzanalyse?
2. Erläutere die folgenden Modellgleichungen
 - a) $x_{ij} = \mu + \tau_i$
 - b) $x_{ij} = \mu + \tau_i + \epsilon_{ij}$
3. Was bedeutet: $SS_{total} = SS_{treatment} + SS_{error}$
4. Was bedeutet folgende Tabelle

```

#####  ## #####  #####

#####  #####

                ## ## ##  ## ##  #  #####  #####
#####  ##  #####  #####  #####  #####  ##
#####  ##  #####  #####
###
#####  #####  #  #####  #####  #####  #####  ##  ##  ##  #  #  #
    
```

5. Wie sollten die Ergebnisse dokumentiert werden?

Exkurs: Hypothesen und Prüfstatistik

Nullhypothese: es existiert kein Unterschied zwischen zwei Mittelwerten (z.B. Stichprobenmittelwert und Populationsmittelwert, oder Mittelwert und einem angenommenen Mittelwert, oder zwischen 2 Stichprobenmittelwerten) $H_0: \mu_1 = \mu_2$

Alternativhypothese: Mittelwerte unterscheiden sich.

ungerichtete Alternativhypothese: es gibt einen Unterschied

$$H_1: \mu_1 \neq \mu_2$$

gerichtete Alternativhypothese gibt eine Richtung an (< oder >)

$$H_1: \mu_1 < \mu_2$$

α -Niveau

- Die Nullhypothese wird verworfen, wenn der empirisch ermittelte Kennwert außerhalb des Konfidenzintervalls liegt.
- Abhängig von $t_{\alpha,df}$
- Je kleiner α ist, desto größer muss der Mittelwertunterschied sein, um *signifikant* zu sein.
- Signifikant \approx statistisch relevant
- α -Niveau legt die Wahrscheinlichkeit fest, mit der die Nullhypothese abgelehnt wurde.
- Irrtumswahrscheinlichkeit bzw. Restrisiko für eine Fehlentscheidung gegen eine gültige Nullhypothese
- Umgangssprachlich ausgedrückt: wir haben blöderweise eine Stichprobe gezogen, die an den seitlichen Rändern der theoretischen Verteilungskurve aller Stichprobenmittelwerte liegt.
- α -Fehler, Fehler erster Art, *Type I error*

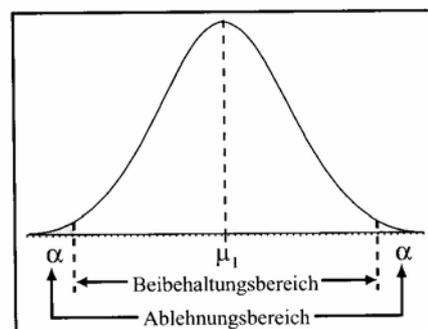


Abbildung 7.5: Das α -Niveau bei zweiseitiger Testung

Prüfung der Signifikanz hängt vom α -Niveau ab:

$\alpha=0.1$	marginal signifikant	.
$\alpha=0.05$	signifikant	*
$\alpha=0.01$	hoch signifikant	**
$\alpha=0.001$	höchst signifikant	***

Sind die Konsequenzen einer fälschlichen Ablehnung der Nullhypothese sehr gravierend, so setzt man das α -Niveau auf einen kleineren Wert (1% oder 1 Promille).

Testen von Hypothesen: zwei Mittelwerte, x_1 und x_2 , sollen miteinander verglichen werden. Wir wollen feststellen, ob sie aus der gleichen Population stammen (= -Hypothese) oder aus verschiedenen (= -Hypothese). Bei einem α -Niveau von 5 % ist die Wahrscheinlichkeit, dass x_1 und x_2 , wenn sie außerhalb des Beibehaltungsbereichs liegen, trotzdem aus der gleichen Population stammen, gleich 5%.

Bei einem **beidseitigen Test** entsprechen die beiden Ränder jeweils $\alpha/2$. Der Beibehaltungsbereich ist $1-\alpha$.

FRAGE: Wie groß sind die α -Bereiche bei einem beidseitigen Test mit einem Beibehaltungsbereich von

- 95%
- 99%
- 99.9%

Bei einem **einseitigen Test** wissen wir aus der Literatur, dass einer der beiden Mittelwerte größer (kleiner) sein sollte als der andere, d.h. wir nehmen eine Richtung an.

Vorteil: der t-Test wird schon bei einem geringeren Mittelwertsunterschied signifikant.

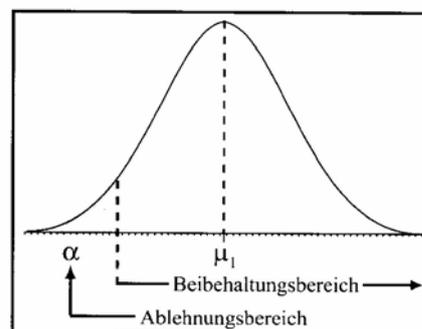


Abbildung 7.4: Das α -Niveau bei einseitiger Testung

β -Fehler

= Beibehaltung der falschen Nullhypothese bei gültiger Alternativhypothese

= Fehler zweiter Art, Type II error

Fehler 1. Art: Ablehnung einer gültigen Nullhypothese
 Fehler 2. Art: Beibehaltung der falschen Nullhypothese

		Realität	
		H0 ist wahr	H0 ist falsch
Entscheidung	akzeptiere H0	korrekt (es brennt nicht, kein Alarm)	Fehler 2. Art (es brennt, aber kein Alarm)
	lehne H0 ab	Fehler 1. Art (es brennt nicht, aber Alarm)	korrekt (es brennt und Alarm)

$1-\beta$: **Teststärke** (*test power*) ist die Wahrscheinlichkeit, dass ein in der Population vorhandener Unterschied bei statistischer Testung aufgedeckt wird.

β -Fehler ist abhängig von

- α -Niveau: je höher das vorher festgelegte α -Niveau, desto kleiner wird die Wahrscheinlichkeit für einen β -Fehler
- Einseitige vs. zweiseitige Testung: höhere Wahrscheinlichkeit für einen Fehler 2. Art bei zweiseitiger Testung
- Streuung des Merkmals: je einheitlicher sich die Stichprobenteilnehmer bezüglich eines Merkmals verhalten, umso geringer die Streuung. Je kleiner die Streuung umso kleiner ist auch der

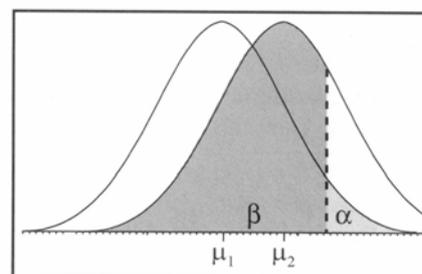


Abbildung 7.8: α - und β -Fehler, Teil 3

Standardfehler. Je kleiner der Standardfehler umso eher erhält man ein signifikantes Ergebnis.

- Stichprobenumfang: je größer die Stichprobe, umso kleiner der Standardfehler
- Mittelwertsunterschied: je größer der Unterschied zwischen zwei Stichproben (oder Faktorstufen) umso eher ein signifikantes Ergebnis
- β ist kleiner für abhängige als für unabhängige Stichproben
- Skalenniveau: je höher das Skalenniveau, desto kleiner β

R Befehle

Formelschreibweise in R: *AbhängigeVar ~ Faktor*

(entspricht sprachlich: Variable wird durch Faktor beschrieben bzw. hängt von dem Faktor ab)

t.test mit paired=T (t Test für abhängige Stichproben)

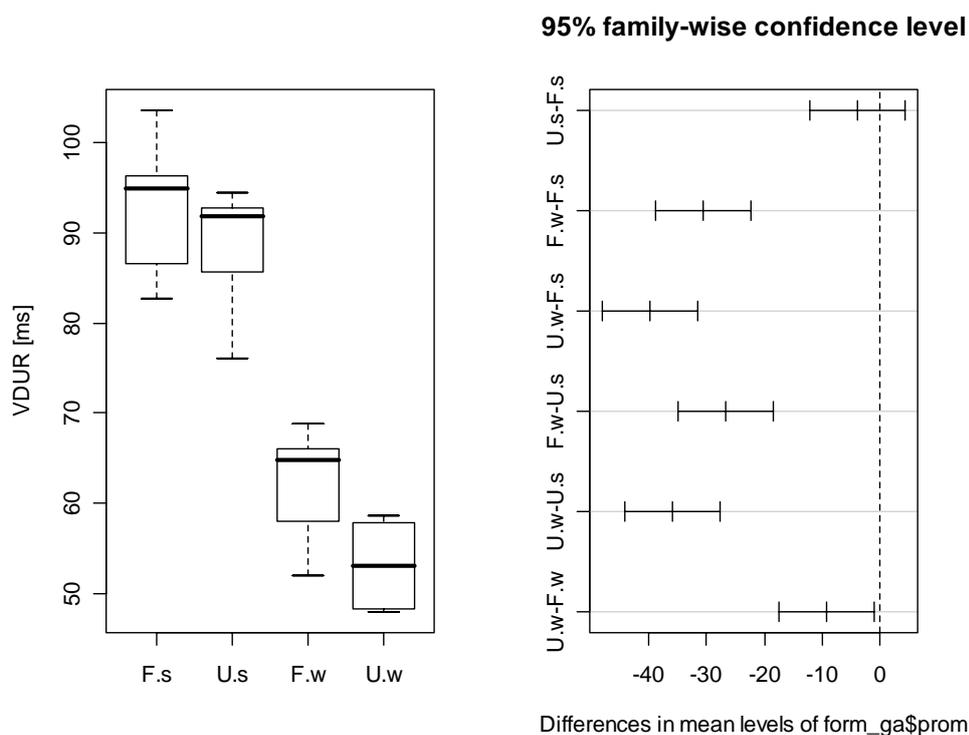
4. POST HOC TESTS

- Ziel: Welche Mittelwerte unterscheiden sich signifikant bei mehrstufigen Faktoren?
- **Nachdem** mittels einer ANOVA ein signifikanter Effekt festgestellt wurde, können so genannte *Post hoc Tests* durchgeführt werden.
- Es wird keine Unabhängigkeit der Stichproben gefordert.
- Automatische Anpassung des α -Niveaus

Tests:

- Sehr gebräuchlich: *Scheffé* Test (sehr konservativ)
- Pairwise.t.test mit Bonferroni Anpassung
- Auch in R implementiert *Tukey HSD* („honestly significant difference“)

Beispiel:




```
anova(lm(vdur ~ accent+stress, data=form_ga))
```

```

#####  ## #####  #####
#####  #####
#####  ##  ##  ##  #####  ##  # #####  #####
#####  # #####  #####  #####  #####  #####  ##
#####  # #####  #####  #####  #####  #####  ##
#####  ##  #####  #####
###
#####  #####  # #####  #####  #####  #####  ##  ##  ##  ##  #  #  #

```

Interpretation:

- höchst signifikanter Effekt von Wortakzent (F(1,29)= 241.24, p<0.001) auf die Vokaldauer,
- hoch signifikanter Effekt von Satzакzent (F(1,29)= 9.45, p<0.01) auf die Vokaldauer
- **beide Haupteffekte wirken sich signifikant auf die Vokaldauer aus.**

Interaktionen:

$$x_{ijk} = \mu + \alpha_i + \beta_j + \alpha_i\beta_j + \epsilon_k$$

Interaktionen treten auf, wenn die Unterschiede zwischen den Faktorstufen eines Faktors nicht für alle Faktorstufen des zweiten Faktors gleich sind.

```

anova(lm(vdur ~ accent+stress+accent:stress, data=form_ga))
anova(lm(vdur ~ accent*stress, data=form_ga))      (Kurzform)

```

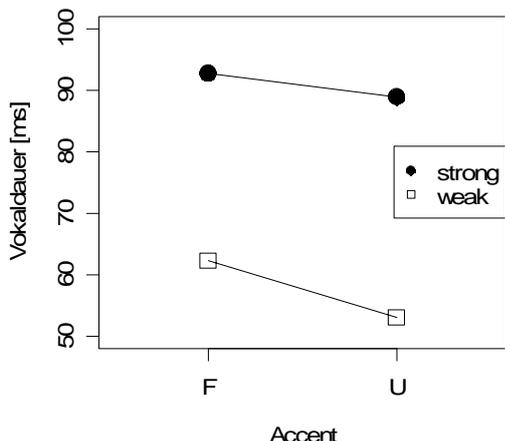
```

#####  ##  #####  #####
#####  #####
#####  ##  ##  ##  #####  ##  # #####  #####
#####  # #####  #####  #####  #####  #####  ##
#####  # #####  #####  #####  #####  #####  ##
#####  #####  # #####  #####  #####  #####
#####  ##  #####  #####
###
#####  #####  # #####  #####  #####  #####  ##  ##  ##  ##  #  #  #

```

Zum Ausprobieren

```
#####
```



Berechnung der Freiheitsgrade:

- Haupteffekte: p - 1=1, q-1=1
- Interaktion: (p-1)*(q-1)=1
- Fehler: pq(n-1) = 2*2*7=28
- Deakzentuierung hat immer eine reduzierende Wirkung auf die Vokaldauer, unabhängig vom Wortakzent.
- Wortakzentuierte Vokale (strong) sind immer länger als wortunbetonte Vokale, unabhängig vom Satzакzent.
- ➔ Linien verlaufen ungefähr parallel
- ➔ Keine Interaktionen

Datenbasis bei einfaktoriellem Design

	Stress	Strong	Weak
Sprecher		F0	F0
BD		s	w
	Messung 1	126.507	106.072
	Messung 2	132.109	106.348
	Messung 3	147.076	112.089
	Messung 4	125.079	107.023

	xbar	137	108
BP		s	w
	Messung 1	125.687	111.952
	Messung 2	113.411	103.334
	Messung 3	128.160	105.855
	Messung 4	119.850	107.437

	xbar	129	102

...

Weitere Sprecher

...

- Errechnen der **Zellenmittelwerte**, da sonst jede Messung wie eine neue Versuchsperson behandelt wird
- Zellenmittelwert = Mittelwerte für jeden Sprecher und jede Bedingung über die Wiederholungen

Zellenmittelwerte in R:

```
lab=paste(formNF$vp, substring(formNF$lab,5,5), "")
```

```
f0=as.vector(tapply(formNF$f0, lab, mean))
```

```
labnew=names(tapply(formNF$f0, lab, mean))
```

Erzeugen einer Matrize mit den Faktoren Sprecher und Stress sowie der Variablen f0:

Erstellen des Modells in R

Falsch:

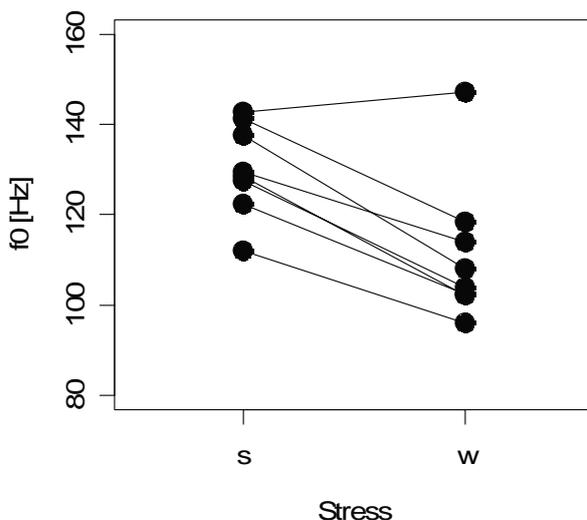
```
summary(aov(f0~stress), data=mat)
```

```

      Df Sum Sq Mean Sq F value Pr(>F)
stress  1  10000    10000     1.00  0.321
Residuals 14  10000     714.3    0.71  0.407
---
1. Total Sum of Squares: 20000
2. Error Sum of Squares: 10000
3. Error Degrees of Freedom: 14
4. Error Mean Square: 714.3
5. F value for stress: 1.00
6. Pr(>F) for stress: 0.321

```

Warum falsch????



Richtig:

```
summary(aov(f0~stress + Error(sp/stress), data=mat))
```

```

      Df Sum Sq Mean Sq F value Pr(>F)
stress  1  10000    10000     1.00  0.321
Error:sp 14  10000     714.3    0.71  0.407
---
1. Total Sum of Squares: 20000
2. Error Sum of Squares: 10000
3. Error Degrees of Freedom: 14
4. Error Mean Square: 714.3
5. F value for stress: 1.00
6. Pr(>F) for stress: 0.321

```

Error:sp bedeutet, dass Änderungen in der Grundfrequenz aufgrund des Faktors *stress* immer innerhalb des Subjekts betrachtet werden sollte.

Aufgabe ANOVA mit Messwiederholungen

Untersuche anhand der Datenbasis *formants.Rdata* für die Teilmenge der akzentuierten (*accent=F*) und wortbetonten Daten (*stress =s*), ob die Lautstärke einen signifikanten Einfluss auf die Variable *f0* hat. Erzeuge hierfür eine Matrix mit den Zellenmittelwerten. Wie können die Ergebnisse interpretiert werden? Nimm hierzu auch Abbildungen und Post hoc Tests zu Hilfe.

Mehrfaktorielles Design

```
summary(aov( JC ~ cons * loudness + Error(subj/(cons*loudness)), data=pos))
```

```

#####  #####
          ##  ###  ##  #####  ##  #  #####  #####
#####  #  #####  #####
#####  #####
          ##  ###  ##  #####  ##  #  #####  #####
#####  #  #####  #####  #####  #####  #####  ##
#####  ##  #####  #####
###
#####  #####  #  #####  #####  #####  #####  ##  #####  ##  ##  #  #  #
#####  #####
          ##  ###  ##  #####  ##  #  #####  #####
#####  #  #####  #####  #####  #####  #####  #
#####  #  #####  #####
###
#####  #####  #  #####  #####  #####  #####  ##  #####  ##  ##  #  #  #
#####  #####
          ##  ###  ##  #####  ##  #  #####  #####
#####  #  #####  #####  #####  #####  #####  #
#####  #  #####  #####
###
#####  #####  #  #####  #####  #####  #####  ##  #####  ##  ##  #  #  #
#####  #####

```

