

# Eine Einführung in R: Varianzanalyse

Bernd Klaus, Verena Zuber

Institut für Medizinische Informatik, Statistik und Epidemiologie (IMISE),  
Universität Leipzig

6. Januar 2011


## I. Varianzanalyse: Theorie

## II. Varianzanalyse: Praxis

## I. Varianzanalyse: Theorie

## Beispiel: "toycar"

Fragestellung: Fahren die drei Autotypen unterschiedlich weit?



Oder wie untersucht man die Nullhypothese:  $H_0 : \mu_1 = \mu_2 = \mu_3$ ?

## Varianzanalyse

Daten: Gegeben ist eine metrische (normalverteilte) Zielgröße  $Y$  und mindestens ( $p \leq 1$ ) Faktorstufen, die jeweils mehrere Gruppen ( $k \leq 2$ ) umfassen.

Insgesamt sind  $n_1 + \dots + n_k = n$  Beobachtungen gegeben

- ▶  $p = 1$ : Einfaktorielle Varianzanalyse
- ▶  $p = 1$  und  $k = 2$ :  $t$ -Test
- ▶  $p > 1$ : Mehrfaktorielle Varianzanalyse

Frage: Unterscheiden sich die Erwartungswert der metrischen Zufallsvariable in den Gruppen?

Oder: Ist die Varianz zwischen den Gruppen größer als in den Gruppen?

## Das Modell der einfaktoriellen Varianzanalyse $p = 1$

- ▶ Spezialfall  $k = 2$ :  $t$ -Test
- ▶ Das Modell für  $j = 1, \dots, k$  Gruppen und  $i = 1, \dots, n_j$  Beobachtungen in Gruppe  $j$ :

$$Y_{ji} = \mu_j + \epsilon_{ji}$$

- ▶ Voraussetzungen:
  1.  $\epsilon_{ji} \sim N(0, \sigma)$
  2.  $\epsilon_{ji}$  ist normalverteilt mit Erwartungswert 0
  3. identischer Varianz  $\sigma^2$
- ▶  $H_0: \mu_1 = \dots = \mu_k$

# Streuungszerlegung

ANOVA: *AN*alysis Of *VA*riances

$$\text{SQT} = \sum_{i=1}^n (y_i - \bar{y})^2 = \underbrace{\sum_{j=1}^k \sum_{i=1}^{n_j} (y_{ij} - \bar{y}_j)^2}_{\text{SQR}} + \underbrace{\sum_{j=1}^k n_j (\bar{y}_j - \bar{y})^2}_{\text{SQE}}$$

Für die Streuungszerlegung werden folgende Größen berechnet:

- ▶ **SQT**: Sum of Squares Total, die Gesamtstreuung ( $\text{Var}(Y)$ )
- ▶ **SQR**: Sum of Squares Residuals, Streuung in den Gruppen
- ▶ **SQE**: Sum of Squares Explained, Streuung zwischen den Gruppen

## Der $F$ -Test

- ▶  $H_0: \mu_1 = \dots = \mu_k$
- ▶ Aus der Streuungszersetzung wird verwendet:

Streuung	df	Mittlerer Quadr. Fehler
zwischen den Gruppen	$k-1$	$SQE/(k-1)$
in den Gruppen	$n-k$	$SQR/(n-k)$

- ▶ Die Prüfgröße  $F$  berechnet sich aus:

$$F = MQE/MQR = \frac{SQE}{k-1} / \frac{SQR}{n-k}$$

- ▶  $F$  ist  $F$ -verteilt mit  $(k-1, n-k)$  Freiheitsgraden



## Mehrfaktorielle Varianzanalyse $p > 1$

- ▶ Natürlich können mehrere Faktoren und Wechselwirkungen zwischen Faktoren berücksichtigt werden
- ▶ Die Formeldarstellung kann dabei sehr schnell sehr kompliziert werden
- ▶ Wichtig in der Praxis ist dabei, dass jede der einzelnen Unterkategorien eine ausreichende Stichprobengröße besitzt
- ▶ Es gibt  $F$ -Tests für alle Faktoren und deren Wechselwirkungen

## II. Varianzanalyse: Praxis

## Beispiel: *toy*car-Daten

- ▶ Berechnung des linearen Modells `lm.car`:

```
lm.car <- lm(distance ~ car)
```

- ▶ Output des `summary`-Befehl :

```
Call: lm(formula = distance ~ car)
```

```
Coefficients:
```

	Estimate	Std. Error	t value	Pr(>  t )	
Intercept	0.5911	0.0902	6.555	8.86 e-07	***
car2	0.1111	0.1275	0.871	0.392	
car3	-0.0822	0.1275	-0.645	0.525	

```
Multiple R-squared: 0.08797,
```

```
Adjusted R-squared: 0.01197
```

```
F-statistic: 1.158 on 2 and 24 DF, p-value: 0.3312
```

## Beispiel: *toycar*-Daten

- ▶ R-Befehl zur Varianzanalyse: `anova(lm.car)`
- ▶ Output des anova-Befehl :

Analysis of Variance Table

Response: distance

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
car	2	0.16945	0.084726	1.1575	0.3312
Residuals	24	1.75673	0.073197		

## Beispieldaten: "Taste"

Untersuchung von zwei verschiedenen Einflussfaktoren auf den Geschmack eines Nahrungsmittels:

- ▶ SCORE: *Geschmackspunktzahl*
- ▶ LIQ: *Flüssigkeitskomponente: hohe (1) oder niedrige (0) Konzentration*
- ▶ SCR: *Textur des Nahrungsmittels: rauh (0) oder fein (1)*

## Beispiel für 2-faktorielle Varianzanalyse: *Taste*-Daten

- ▶ Berechnung des linearen Modells *taste*:  
`taste <- lm(SCORE ~ LIQ * SCR)`
- ▶ R-Befehl zur Varianzanalyse: `anova(taste)`
- ▶ Output:

Analysis of Variance Table  
Response: SCORE

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
LIQ	1	1024.0	1024.0	2.6321	0.1306	
SCR	1	10609.0	10609.0	27.2696	0.0002	***
LIQ:SCR	1	420.2	420.2	1.0802	0.3191	
Residuals	12	4668.5	389.0			

⇒ Nur der Effekt von **SCR** ist signifikant von 0 verschieden

## Beispiel - Schätzung der Effektgrößen / Koeffizienten

- ▶ Schätzer der Effektgrößen des Modells taste:

```
summary(taste)
```

- ▶ Output wie im linearen Modell:

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
Intercept	41.75	9.862	4.233	0.0011	**
LIQ1	-5.75	13.947	-0.412	0.6874	
SCR1	61.75	13.947	4.427	0.0008	***
LIQ1:SCR1	-20.50	19.724	-1.039	0.3191	