

Varianzanalyse und Tukey-Test in SAS, R und JMP - die Skalierung der Erklärungsvariablen ist von enormer Bedeutung

Eckard Moll

Grashüpfeweg 37
14532 Stahnsdorf
EckardMoll@web.de

Doreen Gabriel

Julius Kühn-Institut
Bundesallee 50
38116 Braunschweig
Doreen.Gabriel@julius-kuehn.de

Zusammenfassung

Mit den Daten eines Beispiels werden in SAS, R und JMP eine einfache Varianzanalyse und Tukey-Test durchgeführt. Es wird gezeigt, welche enorme Bedeutung die Skalierung der Erklärungsvariablen, d.h. des Faktors im Modell, hat.

In SAS wird im Allgemeinen mit der Wahl der Prozedur das Auswertungsverfahren festgelegt. Die Variable des Faktors im Varianzanalysemodell muss in der CLASS-Anweisung stehen. Sie kann sowohl vom Typ character als auch numerisch sein. Für die Auswertung mit R und unter Nutzung der Funktion aov muss die Erklärungsvariable als Faktor deklariert sein. Passiert das nicht und es soll eine Varianzanalyse durchgeführt werden, erfolgt bei der Durchführung des Tukey-Tests eine Fehlermitteilung. Für Varianzanalyse und Tukey-Test in JMP kann der Faktor numerisch sein, aber nur nominal oder ordinal. Ist er stetig, wird anstelle der Varianzanalyse die Regressionsanalyse gerechnet. Multiple Tests werden in diesem Fall ohne eine entsprechende Warn- oder Fehlermeldung auszugeben.

Schlüsselwörter: Skalierung, Varianzanalyse, Tukey-Test, SAS, R, JMP

1 Vorbemerkungen und Zielstellung

Es ist Basiswissen, dass die Eigenschaften der Variablen, besonders ihre Skalierung (character, numerisch: stetig, ordinal oder nominal), entscheidend für die Wahl der statistischen Analyse sind. Wird das bei der Nutzung von Software vergessen oder übersehen, kann es zu falschen Schlussfolgerungen oder Auswertungen kommen. Mit den Daten des Beispiels [1] sollen in SAS, R und JMP eine einfache Varianzanalyse und Tukey-Test durchgeführt werden. Besondere Bedeutung erhält dabei die Skalierung der Variablen *gruppe*. Die Daten sind:

gruppe	y			
1	15	17	19	
2	17	20	23	
3	22	25	27	30

2 Varianzanalyse und Tukey-Test in SAS, R und JMP

2.1 SAS 9.4

SAS stellt mehrere Prozeduren zur Verfügung, die in Abhängigkeit von den Modelleigenschaften und der Zielstellung Varianzanalyse und Tukey-Test genutzt werden. Grafiken werden mit Hilfe der ODS GRAPHICS Anweisung automatisch erzeugt.

Die Variable *gruppe*, der Faktor im Varianzanalysemodell, ist numerisch. Das nachfolgende Programm liefert die Ergebnisse für den Tukey-Test zum Signifikanz-niveau $\alpha = 5\%$.

```
DATA beispiel1;
  INPUT gruppe y @@;
CARDS;
  1 15    1 17    1 19
  2 17    2 20    2 23
  3 22    3 25    3 27    3 30
;
ODS GRAPHICS ON/ reset=all imagefmt=emf;
PROC GLM DATA = beispiel1;
  CLASS gruppe;
  MODEL y = gruppe / ss3 ;
  LSMEANS gruppe/ adjust=tukey cl;
RUN;
ODS GRAPHICS OFF;
```

Die Textausgabe der Ergebnisse wird hier nur auf die Varianztabelle, die Mittelwertvergleiche und die Konfidenzintervalle beschränkt. Zwei Grafiken werden angelegt.

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	148.5000000	74.2500000	8.66	0.0128
Error	7	60.0000000	8.5714286		
Corrected Total	9	208.5000000			

Least Squares Means
Adjustment for Multiple Comparisons: Tukey-Kramer

gruppe	y LSMEAN	LSMEAN Number
1	17.0000000	1
2	20.0000000	2
3	26.0000000	3

Least Squares Means for effect gruppe
 Pr > |t| for H0: LSMean(i)=LSMean(j)

Dependent Variable: y

i/j	1	2	3
1		0.4615	0.0122
2	0.4615		0.0716
3	0.0122	0.0716	

gruppe y LSMEAN 95% Confidence Limits

1	17.000000	13.003056	20.996944
2	20.000000	16.003056	23.996944
3	26.000000	22.538545	29.461455

Least Squares Means for Effect gruppe

i j	Difference Between Means	Simultaneous 95% Confidence Limits for LSMean(i)-LSMean(j)	
1 2	-3.000000	-10.039984	4.039984
1 3	-9.000000	-15.585302	-2.414698
2 3	-6.000000	-12.585302	0.585302

Die erste Grafik (Abb. 1) veranschaulicht die Lage der Mittelwerte für jede Gruppe,




Abbildung 1: Mittelwerte jeder Gruppe

die zweite (Abb. 2) die Signifikanzentscheidungen für die Differenzen.




Abbildung 2: Signifikanzentscheidungen für die Differenzen

In SAS ist im Allgemeinen mit der Wahl der Prozedur das Auswertungsverfahren festgelegt. Durch die MODEL-Anweisung wird aus einer Variablen – im Beispiel die Variable *gruppe* – in Verbindung mit der CLASS-Anweisung ein Faktor im Varianzanalysemodell. Aus diesem Grund kann die Variable *gruppe* sowohl vom Typ character als auch numerisch sein.

Steht eine (numerische) Variable auf der rechten Seite der MODEL-Anweisung und fehlt in der CLASS-Anweisung, so wird sie im linearen Modell zur Kovariablen. Ist sie die alleinige Variable im Modell, wird sie zum Regressor und anstelle der Varianzanalyse wird die Regressionsanalyse gerechnet:

Dependent Variable: y

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	143.8043478	143.8043478	17.78	0.0029
Error	8	64.6956522	8.0869565		
Corrected Total	9	208.5000000			

R-Square	Coeff Var	Root MSE	y Mean
0.689709	13.22678	2.843757	21.50000

Source	DF	Type III SS	Mean Square	F Value	Pr > F
gruppe	1	143.8043478	143.8043478	17.78	0.0029

Parameter	Estimate	Standard Error	t Value	Pr > t
Intercept	11.91304348	2.44485494	4.87	0.0012
gruppe	4.56521739	1.08259997	4.22	0.0029

Der in der LSMEANS-Anweisung formulierte Mittelwertvergleich wird nicht ausgeführt. In der Fehlermitteilung wird darauf hingewiesen, dass die Klassifizierungsvariable fehlt.

2.2 R

2.2.1 Die Variable *gruppe* als Faktor (Funktion `aov`)

Die Aufgaben der SAS-Prozeduren übernehmen in R die speziellen Funktionsaufrufe. Für multiple Mittelwertvergleiche stehen in R mehrere Packages bereit. Für die Nutzung der Funktion `aov` wird die Variable *gruppe* des Beispiels als Faktor eingelesen.

```
beispiel1<-data.frame(gruppe=factor(c(1,1,1,2,2,2,3,3,3,3)),
y=c(15,17,19,17,20,23,22,25,27,30))
```

```
mod<-aov(y~gruppe, data=beispiel1)
summary(mod)
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
gruppe	2	148.5	74.25	8.662	0.0128 *
Residuals	7	60.0	8.57		

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

TukeyHSD(mod)

```
Tukey multiple comparisons of means
95% family-wise confidence level
```

```
Fit: aov(formula = y ~ gruppe, data=beispiel1)
```

\$gruppe	diff	lwr	upr	p adj
2-1	3	-4.0400361	10.04004	0.4614676
3-1	9	2.4146493	15.58535	0.0121868
3-2	6	-0.5853507	12.58535	0.0715599

```
plot(TukeyHSD(mod))
```

Diese Plot-Anweisung erzeugt eine Veranschaulichung (Abb. 3) der Signifikanzentscheidungen.




Abbildung 3: Signifikanzentscheidungen für die Differenzen

Zusätzlich kann man aus dem Package Agricolae den Tukey-Test mit der Funktion `HSD.test` durchführen.

```
library(agricolae)
out<-HSD.test(mod, "gruppe")
out
```

```
$statistics
  Mean      CV  MSerror      HSD r.harmonic
 21.5 13.61721 8.571429 6.740321 3.272727
```

```
$parameters
  Df ntr StudentizedRange alpha test name.t
  7  3      4.164941 0.05 Tukey gruppe
```

```
$means
  y      std r Min Max
1 17 2.000000 3 15 19
2 20 3.000000 3 17 23
3 26 3.366502 4 22 30
```

```
$comparison
NULL
```

```
$groups
  trt means M
1   3    26 a
2   2    20 ab
3   1    17 b
```

```
bar.group(out$groups, ylim=c(0,45), density=4, border="blue")
```

Diese Anweisung liefert ein Balkendiagramm der Mittelwerte mit der Signifikanzentscheidung mittels Buchstaben (Abb. 4).




Abbildung 4: Signifikanzentscheidungen durch Buchstaben

2.2.2 Die Variable *gruppe* als numerische Variable (Funktion *aov*)

Wird der Faktor *gruppe* als *gruppe2* numerisch vereinbart und ebenfalls die Funktion *aov* verwendet, dann wird eine andere Varianzanalysetabelle ausgegeben und bei Wahl des Tukey-Tests erfolgt eine Fehlermitteilung.

```
beispiel1$gruppe2<-c(1,1,1,2,2,2,3,3,3,3)
mod2<-aov(y~gruppe2, data = beispiel1)
summary(mod2)
```

```
          Df Sum Sq Mean Sq F value Pr(>F)
gruppe2   1  143.8   143.80   17.78 0.00293 **
Residuals  8    64.7     8.09
```

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
TukeyHSD(mod2)
```

```
Error in TukeyHSD.aov(mod2) : keine Faktoren im angepassten Modell
In addition: Warning message:
In replications(paste("~", xx), data = mf) :
nicht-Faktoren ignoriert: gruppe2
```

Die Fehlerauschrift besagt, dass *gruppe2*, die numerisch vereinbarte Variable *gruppe*, nicht als Faktor für den Tukey-Test erkannt wird.

Zu klären bleibt noch, was das für eine Varianzanalyse ist, die nun gerechnet wurde. Dazu wird die Funktion `lm` verwendet:

```
mod2<-lm(y~gruppe2, data=beispiel1)
summary(mod2)
```

Residuals:

Min	1Q	Median	3Q	Max
-4.0435	-1.3696	-0.0435	1.8152	4.3913

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	11.913	2.445	4.873	0.00124	**
gruppe2	4.565	1.083	4.217	0.00293	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.844 on 8 degrees of freedom
Multiple R-squared: 0.6897, Adjusted R-squared: 0.6509
F-statistic: 17.78 on 1 and 8 DF, p-value: 0.002928

```
anova(mod2)
```

Analysis of Variance Table

Response: y

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
gruppe2	1	143.804	143.804	17.782	0.002928	**
Residuals	8	64.696	8.087			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Diese Varianztabelle stimmt mit obiger für *gruppe2* überein. Es ist die Anpassung an ein lineares Regressionsmodell. Das Verfahren ist folglich ebenso wie mit der SAS-GLM-Prozedur ohne die CLASS-Anweisung die Regressionsanalyse. Dem entsprechend werden wie auch in SAS die Schätzwerte für die Regressionskoeffizienten der linearen Funktion $y = f(\text{gruppe2})$ berechnet.

Für die Aufgabenstellung, die Berechnung der einfachen Varianzanalyse und des Tukey-Tests, bedeutet das, dass die Erklärungsvariable *gruppe* als Faktor deklariert sein muss.

2.3 JMP 12

2.3.1 Die Variable gruppe als nominale oder ordinale Variable

Mit dem Öffnen der Datei des Beispiels oder der direkten Dateneingabe werden die Eigenschaften der Variablen automatisch festgelegt: *y*: stetig, *gruppe*: stetig. Für die Analysen Varianzanalyse und Tukey-Tests muss die numerische Variable *gruppe* nominal oder ordinal sein. D.h. die Eigenschaft der Variablen *gruppe* muss geändert werden!

Varianzanalyse und multiple Mittelwertvergleiche erreicht man über das Pull-Down-Menü *Analyse* → *Fit Model*. Die auszuwertende Variable und die Effekte im Modell sind zuzuweisen: *Y*: *y* und *Add*: *gruppe*.

Die Standardausgabe ist umfangreich und enthält mehrere Grafiken. Die Angabe hier wird nur auf die Varianztabelle begrenzt.

```
Analysis of Variance
Source          DF      Sum of Squares      Mean Square      F Ratio
Model           2          148,50000          74,2500          8,6625
Error           7           60,00000           8,5714          Prob > F
C. Total        9          208,50000
                                0,0128*
```

Das zu den multiplen Mittelwertvergleichen führende rote Dreieck steht vor der Überschrift *Response y*. Die Wahl von *Estimates* führt zur Entscheidung *Multiple Comparisons*. In einem separaten Fenster sind zu wählen der Typ der Schätzer (Least Square Means Estimates), der Effekt (voreingestellt: *gruppe*) und das Testverfahren *All Pairwise Comparisons - Tukey HSD*.

```
Multiple Comparisons
Estimates
gruppe Estimate Std Error DF t Ratio Prob>|t| Lower 95% Upper 95%
1      17,000000 1,6903085 7 10,06 <,0001* 13,003056 20,996944
2      20,000000 1,6903085 7 11,83 <,0001* 16,003056 23,996944
3      26,000000 1,4638501 7 17,76 <,0001* 22,538545 29,461455
```

```
Tukey HSD All Pairwise Comparisons
Quantile = 2,94498
, Adjusted DF = 7,0
, Adjustment = Tukey-Kramer
```

```
All Pairwise Differences
gruppe -gruppe Difference Std Error t Ratio Prob>|t| Lower 95% Upper 95%
1      2      -3,00000 2,390457 -1,25 0,4615 -10,0398 4,03984
1      3      -9,00000 2,236068 -4,02 0,0122* -15,5852 -2,41483
2      3      -6,00000 2,236068 -2,68 0,0716 -12,5852 0,58517
```

Die grafische Darstellung der Signifikanzentscheidungen (Abb. 5) wird mitgeliefert.




Abbildung 5: Signifikanzentscheidungen für die Paarvergleiche

2.3.2 Die Variable gruppe als stetige Variable

Wird es „vergessen“, die numerische Variable *gruppe*, den Faktor im Modell, von stetig auf nominal oder ordinal umzustellen, dann führt das zur Regressionsanalyse. Multiple Mittelwertvergleiche können durchgeführt werden; es kommt kein Warn- oder Fehlerhinweis. Diese Mittelwertvergleiche entsprechen aber nicht der Zielstellung, denn sie basieren auf dem Regressionsmodell. Um das zu veranschaulichen wird mit der stetigen Variablen *gruppe* die gleiche Analyse wie oben wiederholt. Die Varianztabelle stimmt mit der Varianztabelle der Ausgaben in SAS, wenn die Variable *gruppe* nicht in der CLASS-Anweisung steht, und in R für die numerische Variable *gruppe2* überein.

Analysis of Variance

Source	DF	Sum of Squares	Mean Square	F Ratio
Model	1	143,80435	143,804	17,7823
Error	8	64,69565	8,087	Prob > F
C. Total	9	208,50000		0,0029*

Unter anderem werden auch die berechneten Regressionskoeffizienten ausgegeben:

Parameter Estimates

Term	Estimate	Std Error	t Ratio	Prob> t
Intercept	11,913043	2,444855	4,87	0,0012
Gruppe	4,5652174	1,0826	4,22	0,0029

Wenn jetzt ebenfalls über das rote Dreieck vor der Überschrift Response y 'Estimates ▶' und 'Multiple Comparisons' gewählt, dann kann man auch hier zu einem Tukey-Test kommen. Diese Ergebnisse unterscheiden sich vom Tukey-Test der Varianzanalyse:

Multiple Comparisons

Estimates

Gruppe	Estimate	Std Error	DF	t Ratio	Prob> t	Lower 95%	Upper 95%
1	16,478261	1,4922611	8	11,04	<,0001	13,037101	19,919421
2	21,043478	0,9057681	8	23,23	<,0001	18,954773	23,132183
3	25,608696	1,3259088	8	19,31	<,0001	22,551145	28,666247

Tukey HSD All Pairwise Comparisons

Quantile = 2,85742

, Adjusted DF = 8,0

, Adjustment = Tukey-Kramer

All Pairwise Differences

gruppe	-gruppe	Difference	Std Error	t Ratio	Prob> t	Lower 95%	Upper 95%
1	2	-4,56522	1,082600	-4,22	0,0073	-7,6587	-1,47177
1	3	-9,13043	2,165200	-4,22	0,0073	-15,3173	-2,94354
2	3	-4,56522	1,082600	-4,22	0,0073	-7,6587	-1,47177

Auch die grafische Darstellung der Signifikanzentscheidungen (Abb. 6) ist eine andere als oben. Sie scheinen zur Abb. 5 parallel verschoben zu sein. Die Ursache ist schnell gefunden. Sie liegt in den Varianzen und Freiheitsgraden.




Abbildung 6: Signifikanzentscheidungen für die Paarvergleiche bei der Regressionsanalyse

Wird in JMP der Skalierung der Variablen, die Faktoren im Modell werden sollen, keine Beachtung geschenkt, dann kommt man ohne einen Hinweis bei stetiger Variable *gruppe* auch zu einem Tukey-Test. Diese Ergebnisse basieren auf der Regressionsanalyse und entsprechen nicht dem eigentlichen Ziel der Varianzanalyse mit dem Faktor *gruppe*.

3 Schlussfolgerungen

Die Skalierung der Variablen ist wesentlich für die Berechnung von Maßzahlen und der Durchführung von statistischen Analysen. Beispielhaft sollen die einfache Varianzanalyse und der Tukey-Test gerechnet werden. In SAS legt man sich dafür im Allgemeinen mit der Wahl der Prozedur, die Auflistung der Variablen in der CLASS- und MODEL-Anweisung fest, dass z.B. die Variable *gruppe* ein Faktor ist. Es macht dabei keinen Unterschied, ob dieser Faktor vom Typ character oder numerisch ist.

Für die Varianzanalyse mit R muss bei Nutzung der Funktion aov mit anschließendem Tukey-Test die Variable *gruppe* als Faktor vereinbart sein. Damit ist die Stellung dieser Variablen im Varianzanalysemodell klar.

In JMP muss der automatischen Wahl der Eigenschaften der Variablen unbedingt Beachtung geschenkt werden. Am einfachsten ist es, wenn die Variable, die Faktor werden soll, vom Typ character ist. Ist sie numerisch und wird automatisch als stetige Variable erkannt, dann muss diese Eigenschaft auf nominal oder ordinal geändert werden, wenn mit dieser Variablen als Faktor Varianzanalyse und Tukey-Test gerechnet werden sollen. Bleibt die Variable, die für die Varianzanalyse und Tukey-Test Faktor werden soll, stetig skaliert, dann wird eine Regressionsanalyse durchgeführt und die darauf basierenden Mittelwertvergleiche verfehlen die eigentliche Zielstellung der Analyse.

Literatur

- [1] Schumacher, E. (2004): Vergleich von mehr als zwei Parametern
In: Moll, E., J. Gröger, M. Liesebach, P.E. Rudolph, T. Stauber und M. Ziller (Hrsg.): Einführung in die Biometrie, Heft 3,
2. Aufl., ISBN 3-930037-17-3