

## Grundlagen der Datenanalyse mit R, 2. Auflage – Errata

Stand: 25. September 2014

### Inhaltlich relevante Korrekturen

- Abschn. 2.7.1, S. 64, Fußnote 19:  
“Wegen  $0! = 1$  erzeugt `prod(numeric(0))` ebenso wie `factorial(numeric(0))` das Ergebnis 1.”
- Abschn. 2.12.2, S. 103:  
“Die Entsprechung zwischen variablen Feldern und Objekten wird über deren Reihenfolge hergestellt,”
- Abschn. 2.12.4, S. 107:  
“Das Ergebnis eignet sich besonders, um mit der `substr`ing() Funktion weiterverarbeitet zu werden,”
- Abschn. 2.12.5, S. 108:  
“indem dem Ergebnis von `substr`ing() ein passender Vektor von Zeichenketten zugewiesen wird”
- Abschn. 6.8.3, S. 206:  
“> `abline(h=0.5, v=-b0/n1b1, col="gray")`”
- Abschn. 7.1.2, S. 211:  
“> `absDiff <- abs(DV - ave(DV, IV, FUN=median))` # abs. Abweichungen
- Abschn. 7.4.1.2, S. 232:  
“> `SSEtot <- anRes["id", "Sum Sq"] + anRes["id:IV IV:id", "Sum Sq"]`”
- Abschn. 8.5.2, S. 315:  
“`(pLess <- 1-pbinom(N-obs-1, N, 0.5))` # linksseitig”  
“[1] 0.994091s 0.02069473”  
“> `(pTwoSided <- 2* (1-pbinom(max(obs,N-obs)-1,N,0.5))) min(pLess, pGreater)`”
- Abschn. 8.5.7, S. 320:  
“Der Rangsummentest nach Friedman dient der Analyse von Daten einer kategorialen stetigen ordinalen Variable, die in  $p$  abhängigen Stichproben erhoben wurde.”
- Abschn. 9.1.1, S. 332:  
“dessen Breite durch die  $\alpha/2$ - und  $1 - \alpha/2$ -Quantile der Werte von  $t^* = (\hat{\theta}^* - \hat{\theta})/S_{\hat{\theta}}^*$  multipliziert mit der Streuung von  $\hat{\theta}^*$  definiert ist.”
- Abschn. 9.1.3, S. 337:  
“> `(pValBS <- (sum(Fstar >= Fbase) + 1) / (length(Fstar) + 1))`”  
Der Vergleich der Bootstrap  $F^*$ -Werte mit dem  $F$ -Wert der Basisstichprobe über `>=` ist nicht tolerant gegenüber Problemen der numerischen Repräsentation von Gleitkommazahlen. Es ist daher besser, neben `>` nur auf ungefähre Gleichheit zu testen:  
`tol <- .Machine$double.eps^0.5`  
`FsIsGEQ <- (Fstar > Fbase) | (abs(Fstar-Fbase) < tol)`  
`(pValBS <- (sum(FsIsGEQ) + 1) / (length(Fstar) + 1))`

- Abschn. 9.2.1, S. 340:  
“> (pVal <- sum(resDM <= diffM) / length(resDM))”  
Vgl. Hinweis zu Abschn. 9.1.3, S. 337:  
tol <- .Machine\$double.eps^0.5  
DMsIsLEQ <- (resDM < diffM) | (abs(resDM-diffM) < tol)  
(pVal <- sum(DMsIsLEQ) / length(resDM))
- Abschn. 9.2.2, S. 342:  
“> (pVal <- sum(resMD <= mean(DVd)) / length(resMD))”  
Vgl. Hinweis zu Abschn. 9.1.3, S. 337:  
tol <- .Machine\$double.eps^0.5  
MDsIsLEQ <- (resMD < mean(DVd)) | (abs(resMD-mean(DVd)) < tol)  
(pVal <- sum(MDsIsLEQ) / length(resMD))
- Abschn. 10.1.1, S. 344, Fußnote 3:  
“Eine  $(1 \times 1)$ -Diagonalmatrix  $\mathbf{X}$  mit dem einzigen Element  $x \neq 1$  kann mit dem zweiten Argument `nrow` als `diag(x, nrow=1)` ~~müsste daher mit `matrix(x)`~~ erzeugt werden.”
- Abschn. 10.2, S. 361:  
“Die Hauptkomponenten selbst werden durch `prcomp()` ~~nicht berechnet~~ in der Komponente `x` der erzeugten Liste ausgegeben, und durch `princomp()` liefert sie aber in der Komponente `scores` ~~der erzeugten Liste.~~”
- Abschn. 10.2, S. 362:  
“Für die Datenmatrix  $\mathbf{X}$  gilt dann  $\mathbf{X} = \mathbf{BH}_s \mathbf{H}_s \mathbf{B}^t + \mathbf{c}$ .”
- Abschn. 10.6.2, S. 377:  
“Die Modellformel ist multivariat wie mit `lm()` (`<Modellformel>`) zu formulieren”  
“Außerdem ist  $T^2$  gleich dem  $(n_1 + n_2 - 1)$ -fachen der Hotelling-Lawley-Spur.”
- Abschn. 10.8, S. 383:  
“> Ydf1 <- data.frame(`IVman`, DV1=Ym1[ , 1], DV2=Ym1[ , 2])”

## Weitere Hinweise

- Abschn. 6.1, S. 171:  
Mit der Funktion `r.test()` aus dem Paket `psych` lassen sich auch Hypothesen darüber testen, ob zwei theoretische Korrelationskoeffizienten aus unabhängigen oder abhängigen Stichproben identisch sind.
- Abschn. 6.3.1, S. 180:  
Eine empfehlenswerte Alternative zu `scatterplot3d()` ist die Funktion `scatter3d()` aus dem Paket `car`, die als Argument dieselbe Modellformel wie `lm()` akzeptiert. Die hier mit `scatter3d(weight ~ height + age)` zu erstellende Grafik enthält bereits die Vorhersageebene und Residuen. Zudem lässt sich die dargestellte Perspektive durch Klicken und Ziehen mit der Maus interaktiv ändern, was den 3D-Eindruck fördert (vgl. Abschn. 11.8.2).
- Abschn. 6.3.4, S. 185:  
Die Funktion `sim.slopes()` aus dem Paket `QuantPsyc` eignet sich nur für den dargestellten Fall einer moderierten Regression mit einem Prädiktor und einem Moderator. In Modellen mit weiteren Prädiktoren ist das ausgegebene Ergebnis nicht korrekt.

- Abschn. 6.6.1, S. 191:  
Da Extremwerte die Streuungen mit beeinflussen, sollten für die Diagnose von Extremwerten evtl. robuste Schätzer für Varianzen und Kovarianzmatrizen in Betracht gezogen werden (vgl. `covMcd()` aus dem Paket `robustbase` und Abschn. 2.7.4). So geschätzte Kovarianzmatrizen können etwa an das Argument `cov` von `mahalanobis()` übergeben werden.
- Abschn. 8.5.9, S. 323:  
“Der Basisumfang von von R stellt für den [Bowker-] Test keine eigene Funktion bereit, weshalb eine manuelle Rechnung notwendig ist.”  
Die in Abschn. 8.5.10 vorgestellte Funktion `mcnemar.test()` berechnet automatisch den Bowker-Test, wenn Kontingenztafeln mit mehr als zwei Zeilen und Spalten als Argument übergeben werden (Dank an Andri Signorell für den Hinweis).
- Abschn. 9.1.3, S. 336:  
Eine Variante des model-based resampling ist der sog. *wild bootstrap* für Situationen, in denen Heteroskedastizität vorliegt. Hier wird  $E^*$  nicht aus den Residuen  $E$  gebildet, sondern aus dem Produkt  $E/\sqrt{1-h} \cdot U$ . Dabei ist  $h$  die Variable Hebelwert (vgl. Abschn. 6.6.1) und  $U$  eine unabhängige Zufallsvariable mit  $E(U) = 0$  und  $E(U^2) = 1$ .
  - Eine Wahl für  $U$  sind dichotome Variablen mit sog.  $F_1$ -Verteilung, die den Wert  $-(\sqrt{5}-1)/2$  mit Wahrscheinlichkeit  $p = (\sqrt{5}+1)/(2\sqrt{5})$  annehmen und den Wert  $(\sqrt{5}+1)/2$  mit Wahrscheinlichkeit  $1 - p = (\sqrt{5}-1)/(2\sqrt{5})$ . Bei  $n$  Residuen:  

```
sample(c(-(sqrt(5) - 1) / 2, (sqrt(5) + 1) / 2), size=n,  
       prob=c((sqrt(5) + 1) / (2*sqrt(5)), (sqrt(5) - 1) / (2*sqrt(5))))
```
  - Eine alternative Wahl für  $U$  sind ebenfalls dichotome Variablen mit sog.  $F_2$ - bzw. Rademacher-Verteilung: Sie nehmen die Werte  $-1$  und  $1$  jeweils mit Wahrscheinlichkeit  $1/2$  an, drehen also das ursprüngliche Vorzeichen jedes Residuums zufällig um. Bei  $n$  Residuen:  

```
sample(c(-1, 1), size=n, prob=c(0.5, 0.5))
```
- Abschn. 9.2.1, S. 340:  
Anstatt die Parameter der Normalverteilung aus der Permutationsverteilung zu schätzen, hätte auch die unter  $H_0$  gültige Verteilung der Mittelwertsdifferenz  $\mathcal{N}(0, \sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2})$  eingezeichnet werden können.
- Abschn. 10.2, S. 359:  
Zusätzlich erlaubt es `princomp()`, die Kovarianzmatrix der Daten über das Argument `covmat` separat zu spezifizieren. Dies könnte etwa für robuste Schätzungen der theoretischen Kovarianzmatrix genutzt werden (vgl. `covMcd()` aus dem Paket `robustbase`), die auch Grundlage der robusten Hauptkomponentenanalyse im Paket `pcaPP` sind.

## Tipp- und Druckfehler

- Abschn. 2.7.3, S. 66:  
“Für die Berechnung des Modalwertes, also des am häufigsten vorkommenden **n** Wertes eines Vektors,”
- Abschn. 3.3.3.2, S. 132:  
“> subset(myDf1, (myDf1\$sex == "m") & (myDf1\$rating > 2))”  
“> subset(myDf1, (myDf1\$IQ < 90) | (myDf1\$IQ > 110))”

- Abschn. 4.2.5.1, S. 159:  
“Für einen detaillierten Vergleich der Arbeit mit R, SAS und SPSS vgl. Muenchen (2011), der auch den Datenaustausch zwischen den Programmen behandelt.”
- Abschn. 7.4.1, S. 230:  
“> DV\_t4 <- round(rnorm(N, 0.4, 1), 2) # AV zu t34”
- Abschn. 7.5.1, S. 237:  
“> aov(<AV> ~ <UV1> + <UV2> + <UV1>:<UV2>), data=<Datensatz>”  
“> aov(<AV> ~ <UV1>\*<UV2>), data=<Datensatz>”
- Abschn. 8.1, S. 282:  
“auch wenn sich der  $\beta$ -Fehler so nicht exakt begrenzen lässt.”
- Abschn. 8.1.5, S. 290:  
“dass der von `chisq.test()` ausgegebene  $p$ -Wert nicht die Reduktion der Freiheitsgrade widerspiegelt und deshalb für diesen Test nicht der richtige ist.”
- Abschn. 8.2.6.1, S. 298:  
“Das  $F$ -Maß als harmonisches Mittel von Präzision und recall wird bisweilen als integriertes Gütemaß für eine Klassifikation herangezogen.”
- Abschn. 9.1, S. 330:  
“hat das erste Element des Vektors  $\hat{\theta}^*$  und das zweite Element der plug-in-Schätzer  $\hat{\sigma}_{\theta}^{2*}$  der theoretischen Varianz  $\sigma_{\theta}^2$  zu sein.”
- Abschn. 10.1.7, S. 355:  
“weshalb der Koordinatenvektor  $\mathbf{y}$  des orthogonal auf  $V$  projizierten Vektors  $\mathbf{x}$  bzgl. der Basis  $\mathbf{A}$  durch  $(\mathbf{A}^t \mathbf{A})^{-1} \mathbf{A}^t \mathbf{x}$  gegeben sind ist.”
- Abschn. 10.6.2, S. 377:  
“Lineare Strukturgleichungsmodelle werden durch die Pakete `sem` (Fox & Byrnes, 2011) ...”
- Abschn. 10.6.2, S. 377:  
“factIVht 1 0.6073 11.235 2 37 0.0001539 \*\*\*”
- Abschn. 10.8, S. 382:  
“Für weitere Klassifikationsverfahren wie Varianten der Clusteranalyse, CART-Modelle”
- Abschn. 11.2.1, S. 424:  
“Alternativ lässt sich mit der `hexbin()` Funktion aus dem gleichnamigen Paket ein Diagramm erstellen, das die Diagrammfläche in hexagonale Regionen einteilt”