

Die Übung am Tag der Arbeit (1.5.) entfällt. Ab 2.5. steht die Musterlösung im Netz. Wer Fragen zur Musterlösung hat kann eine E-mail an Fabian Scheipl schreiben oder einen Termin ausmachen.

### Aufgabe 1:


In dieser Aufgabe sollen Sie erste Erfahrungen mit dem Schätzen gemischter Modelle in R machen. Benutzen Sie den folgenden Code um den Ratten-Datensatz nach R einzulesen und für die Analyse vorzubereiten:

```
R>library("nlme")
R>url <- "http://www.statistik.lmu.de/institut/lehrstuhl/semwiso/longitudinal_ss08"
R>rats <- read.table(paste(url, "/download/rats.txt", sep = ""),
+   header = T, na.strings = ".")
R>rats$GROUP <- factor(rats$GROUP, labels = c("low", "high", "control"))
R>rats$SUBJECT <- factor(rats$SUBJECT)
R>rats$logT = log(1 + (rats$TIME - 45)/10)
R>rats <- rats[complete.cases(rats), ]
R>obs <- table(rats$SUBJECT)
R>zuvieleNAs <- levels(rats$SUBJECT)[obs < 3]
R>rats <- rats[!(rats$SUBJECT %in% zuvieleNAs), ]
```

- (a) Legen Sie für rats ein groupedData-Objekt an. Berechnen Sie separate lineare Modelle mit linearem Trend in logT für die einzelnen Ratten. Visualisieren Sie die geschätzten subjektspezifischen Regressionskoeffizienten mit Konfidenzintervallen.

### Lösung:

```
R>rats <- groupedData(RESPONSE ~ logT | SUBJECT, data = rats, labels = list(x = "log(Age)",
+   y = "Distance"), units = list(x = " ", y = "[Pixels]"))
R>lm1list.lin <- lmList(RESPONSE ~ logT, rats)
R>print(plot(intervals(lm1list.lin)))
```



⇒ teilweise große Unterschiede im Ausgangsniveau, sehr große Überlappung der Intervalle für Trend.

- (b) Berechnen Sie mit der Funktion `lme` ein gemischtes lineares Modell mit linearem Trend in `logT` und subjektsspezifischen zufälligen Intercepts.
- Wie groß ist die geschätzte Korrelation zwischen 2 Messungen an der selben Ratte?
  - Wie groß ist die Korrelation zwischen 2 Messungen zum gleichen Zeitpunkt bei verschiedenen Ratten?

**Lösung:**

```
R>lmm.lin1 <- lme(RESPONSE ~ logT, random = ~1 | SUBJECT, data = rats)
R>summary(lmm.lin1)
```

```
Linear mixed-effects model fit by REML
Data: rats
      AIC      BIC    logLik
901.1729 915.0954 -446.5864
```

Random effects:

```
Formula: ~1 | SUBJECT
      (Intercept) Residual
StdDev:   2.006254  1.19497
```

Fixed effects: RESPONSE ~ logT

	Value	Std.Error	DF	t-value	p-value
(Intercept)	68.63524	0.3683028	198	186.35547	0
logT	7.20782	0.1549328	198	46.52223	0

```
Correlation:
  (Intr)
logT -0.512
```

Standardized Within-Group Residuals:

	Min	Q1	Med	Q3	Max
	-2.37783156	-0.69658660	-0.03501172	0.54495942	2.84167218

Number of Observations: 242

Number of Groups: 43

(i) Das verwendete Modell für den Responsevektor  $\mathbf{y}_i$  der  $i$ -ten Ratte ist

$$\mathbf{y}_i = \beta_0 \mathbf{1}_{n_i} + \beta_1 \mathbf{x}_i + b_{0i} \mathbf{1}_{n_i} + \boldsymbol{\varepsilon}_i; \quad i = 1, \dots, 43$$

$$\text{mit } \mathbf{b}_0 \sim N_{43}(\mathbf{0}, d^2 * \mathbf{I}_{43}); \quad \boldsymbol{\varepsilon} \sim N_{242}(\mathbf{0}, \sigma^2 \mathbf{I}_{242})$$

$$\begin{aligned} \Rightarrow \text{Cov } \mathbf{y}_i &= \text{Cov}(b_{0i} \mathbf{1}_{n_i} + \boldsymbol{\varepsilon}_i) \\ &= \text{Cov}(b_{0i} \mathbf{1}_{n_i}) + \text{Cov}(\boldsymbol{\varepsilon}_i) \quad (\mathbf{b}, \boldsymbol{\varepsilon} \text{ unabhängig}) \\ &= \mathbf{1}_{n_i} d^2 \mathbf{1}'_{n_i} + \sigma^2 \mathbf{I}_{n_i} \\ &= \begin{pmatrix} d^2 + \sigma^2 & d^2 & \dots & d^2 \\ d^2 & \ddots & & \vdots \\ \vdots & & \ddots & d^2 \\ d^2 & \dots & d^2 & d^2 + \sigma^2 \end{pmatrix} \end{aligned}$$

Für die Korrelation ergibt sich daraus:

$$\begin{aligned} \text{Corr}(y_{ij_1}, y_{ij_2}) &= \frac{\text{Cov}(y_{ij_1}, y_{ij_2})}{\sqrt{\text{Var}(y_{ij_1}) \text{Var}(y_{ij_2})}} \\ &= \frac{d^2}{\sqrt{(d^2 + \sigma^2)^2}} \end{aligned}$$

In R:

```
R>(getVarCov(lmm.lin1))
Random effects variance covariance matrix
      (Intercept)
(Intercept)      4.0251
Standard Deviations: 2.0063

R>(d.sq <- getVarCov(lmm.lin1)[1])
[1] 4.025056

R>(sigma.sq <- (lmm.lin1$sigma)^2)
```

```
[1] 1.427953
R>(cor.withinGroup <- d.sq/(d.sq + sigma.sq))
[1] 0.7381348
⇒ Die Korrelation beträgt ca. 0.74.
```

(ii) Laut Modellannahme sind Beobachtungen an verschiedenen Ratten voneinander unabhängig, also auch unkorreliert.

(c) Berechnen Sie mit der Funktion `lme` ein gemischtes lineares Modell mit linearem Trend in `logT` und subjektsspezifischen zufälligen Intercepts und Trends.

(i) Bestimmen Sie die Kovarianzmatrix  $D$  (s. Folie 3.26) der zufälligen Effekte. Wie groß ist die Korrelation zwischen den zufälligen Intercepts und Slopes?

(ii) Wie kann man also das Modell vereinfachen? Schätzen Sie das entsprechende Modell mit vereinfachter Kovarianzstruktur der zufälligen Effekte.

*Hinweis:* Die Beispiele in `?anova.lme` könnten weiterhelfen.

(iii) Vergleichen Sie die Parameterschätzungen und die gefitteten Werte der subjektsspezifischen linearen Modelle und des zweiten gemischten Modells. *Hinweis:* Benutzen Sie `compareFits` und `comparePred`.

### Lösung:

```
R>lmm.lin2 <- lme(RESPONSE ~ logT, random = ~1 + logT | SUBJECT,
+ data = rats)
R>summary(lmm.lin2)
```

Linear mixed-effects model fit by REML

```
Data: rats
      AIC      BIC    logLik
905.1729 926.0567 -446.5864
```

Random effects:

```
Formula: ~1 + logT | SUBJECT
Structure: General positive-definite, Log-Cholesky parametrization
      StdDev      Corr
(Intercept) 2.0062540747 (Intr)
logT        0.0002241546 0
Residual    1.1949699031
```

Fixed effects: RESPONSE ~ logT

```
      Value Std.Error DF t-value p-value
(Intercept) 68.63524 0.3683028 198 186.35548 0
logT        7.20782 0.1549328 198 46.52223 0
```

Correlation:

```
(Intr)
logT -0.512
```

Standardized Within-Group Residuals:

```
      Min      Q1      Med      Q3      Max
-2.37783157 -0.69658657 -0.03501174 0.54495942 2.84167221
```

Number of Observations: 242  
 Number of Groups: 43

(i) `R>(D <- getVarCov(lmm.lin2))`

```
Random effects variance covariance matrix
      (Intercept)      logT
(Intercept) 4.0251e+00 8.7438e-08
logT        8.7438e-08 5.0245e-08
Standard Deviations: 2.0063 0.00022415
```

`R>cov2cor(D)`

```
Random effects variance covariance matrix
      (Intercept)      logT
(Intercept) 1.00000000 0.00019443
logT        0.00019443 1.00000000
Standard Deviations: 1 1
```

⇒ Die Korrelation zwischen  $b_{0i}$  und  $b_{1i}$  ist ca. 0.0002.

(ii) Das Modell kann vereinfacht werden indem man unkorrelierte zufällige Effekte annimmt, d.h.  $D$  wird als Diagonalmatrix geschätzt. Äquivalente Aufrufe (äquivalent weil `rats` ein `groupedData`-Objekt ist, sonst würden nur die letzten beiden, kompliziertesten `lme`-Aufruf korrekt sein.):

```
R>lmm.lin3 <- lme(RESPONSE ~ logT, random = pdDiag(~logT), data = rats)
R>lmm.lin3 <- lme(RESPONSE ~ logT, random = pdDiag(~1 + logT),
+ data = rats)
R>lmm.lin3 <- lme(RESPONSE ~ logT, random = list(SUBJECT = pdDiag(~1 +
+ logT)), data = rats)
R>lmm.lin3 <- lme(RESPONSE ~ logT, random = list(SUBJECT = pdDiag(~logT)),
+ data = rats)
R>(summary(lmm.lin3))
```

Linear mixed-effects model fit by REML

```
Data: rats
      AIC      BIC    logLik
903.1729 920.576 -446.5864
```

Random effects:

```
Formula: ~logT | SUBJECT
Structure: Diagonal
      (Intercept)      logT Residual
StdDev: 2.006254 0.0001645551 1.19497
```

Fixed effects: RESPONSE ~ logT

	Value	Std.Error	DF	t-value	p-value
(Intercept)	68.63524	0.3683028	198	186.35547	0
logT	7.20782	0.1549328	198	46.52223	0

Correlation:  
 (Intr)  
 logT -0.512

Standardized Within-Group Residuals:

Min	Q1	Med	Q3	Max
-2.37783156	-0.69658659	-0.03501173	0.54495942	2.84167219

Number of Observations: 242


Number of Groups: 43

```
R>(getVarCov(lmm.lin3))
```


Random effects variance covariance matrix

```
      (Intercept)      logT
(Intercept)  4.0251 0.0000e+00
logT         0.0000 2.7078e-08
Standard Deviations: 2.0063 0.00016456
```

```
(iii) R>print(plot(compareFits(coef(lmlist.lin), coef(lmm.lin3))))
```




```
R>print(pairs(compareFits(coef(lmlist.lin), coef(lmm.lin3))))
```



Die subjektspezifischen Unterschiede im Trend sind mit so großer Unsicherheit behaftet (s. Teilaufgabe a)) dass sie durch das gemischte Modell (fast völlig) entfernt werden. Um trotzdem eine gute Anpassung zu erreichen müssen die subjektspezifischen Intercepts deshalb für Ratten mit überdurchschnittlich starkem Trend entsprechend größer werden (unpenalisierte Intercept-Schätzung aus `lmList` kleiner als penalisierte Schätzung) und für Ratten mit unterdurchschnittlich starkem Trend entsprechend kleiner werden (unpenalisierte Intercept-Schätzung aus `lmList` größer als penalisierte Schätzung), genau das sieht man sehr gut in der 2. Grafik.

Üblicherweise beobachtet man dass subjektspezifischen Unterschiede im gemischten Modell durch die Normalverteilungsannahme in Richtung des globalen Mittelwerts geschrumpft werden ( $\Rightarrow$  Shrinkage-Effekt, Stabilisierung der Parameterschätzungen).

```
R>print(plot(comparePred(lm1list.lin, lmm.lin2)))
```



Die Unterschiede in den subjektsspezifischen Regressionsgeraden sind teilweise recht deutlich. Da der geschätzte Trend für die Ratten im gemischten Modell für alle Tiere quasi gleich ist und deswegen die subjektsspezifischen Intercepts für Ratten mit überdurchschnittlich starkem beobachteten Trend im gemischten Modell größer geschätzt werden (s.o.), sieht man hier dass die Regressionsgeraden für Tiere mit überdurchschnittlich starkem Trend durch das gemischte Modell im Ausgangsniveau nach oben verschoben werden und flacher werden, während sie für Tiere mit unterdurchschnittlich starkem Trend durch das gemischte Modell im Ausgangsniveau nach unten verschoben werden und steiler werden.

- (d) Wiederholen Sie die Analyse aus b) für Modelle mit quadratischem zeitlichen Trend. Benutzen Sie das `lme4` Paket.

**Lösung:**

```
R>lmlist.qu <- lmList(RESPONSE ~ poly(logT, 2), rats)
R>try(lmm.qu1 <- lme(RESPONSE ~ poly(logT, 2), random = ~poly(logT,
+ 2), data = rats))
```

```
Error in lme.formula(RESPONSE ~ poly(logT, 2), random = ~poly(logT, 2),:
```

```
nlminb problem, convergence error code = 1
message = iteration limit reached without convergence (9)
```

```
R>detach(package:nlme)
R>library(lme4)
R>lmm.qu1 <- lmer(RESPONSE ~ logT + I(logT^2) + (logT + I(logT^2) |
+ SUBJECT), data = rats)
R>summary(lmm.qu1)
```

```
Linear mixed-effects model fit by REML
Formula: RESPONSE ~ logT + I(logT^2) + (logT + I(logT^2) | SUBJECT)
Data: rats
AIC   BIC logLik MLdeviance REMLdeviance
904 935.4  -443      883          886
Random effects:
Groups   Name          Variance  Std.Dev.  Corr
SUBJECT (Intercept) 4.0202e+00 2.0050e+00
        logT       2.8100e-09 5.3010e-05 0.000
        I(logT^2)  6.9074e-10 2.6282e-05 0.000 0.868
Residual          1.3815e+00 1.1754e+00
number of obs: 242, groups: SUBJECT, 43
```

```
Fixed effects:
              Estimate Std. Error t value
(Intercept)  67.7137    0.4930  137.36
logT          9.1905    0.7261   12.66
I(logT^2)    -0.8536    0.3057   -2.79
```

```
Correlation of Fixed Effects:
      (Intr) logT
logT   -0.733
I(logT^2) 0.669 -0.978
```

```
R>lmm.qu2 <- lmer(RESPONSE ~ logT + I(logT^2) + (1 | SUBJECT) +
+ (-1 + logT + I(logT^2) | SUBJECT), data = rats)
R>summary(lmm.qu2)
```

```
Linear mixed-effects model fit by REML
Formula: RESPONSE ~ logT + I(logT^2) + (1 | SUBJECT) + (-1 + logT + I(logT^2) | SUBJECT)
Data: rats
AIC   BIC logLik MLdeviance REMLdeviance
900 924.4  -443      883          886
Random effects:
Groups   Name          Variance  Std.Dev.  Corr
SUBJECT (Intercept) 4.0110e+00 2.0028e+00
SUBJECT logT       1.1593e-09 3.4049e-05
        I(logT^2)  6.9105e-10 2.6288e-05 -0.636
Residual          1.3821e+00 1.1756e+00
number of obs: 242, groups: SUBJECT, 43; SUBJECT, 43
```

```
Fixed effects:
              Estimate Std. Error t value
(Intercept)  67.7137    0.4928  137.40
logT          9.1906    0.7263   12.65
I(logT^2)    -0.8537    0.3058   -2.79
```

Correlation of Fixed Effects:

```
(Intr) logT
logT      -0.734
I(logT^2)  0.670 -0.978
```

```
R>(D1 <- VarCorr(lmm.qu1))
```

```
$SUBJECT
```

```
3 x 3 Matrix of class "dpoMatrix"
```

```
(Intercept)      logT      I(logT^2)
(Intercept)  4.020195e+00 -4.769948e-09 -2.371984e-09
logT          -4.769948e-09  2.810015e-09  1.209903e-09
I(logT^2)     -2.371984e-09  1.209903e-09  6.907374e-10
```

```
attr(,"sc")
```

```
scale
1.175362
```

```
R>cov2cor(D1[[1]])
```

```
3 x 3 Matrix of class "dpoMatrix"
```

```
(Intercept)      logT      I(logT^2)
(Intercept)  1.000000e+00 -4.487823e-05 -4.501235e-05
logT          -4.487823e-05  1.000000e+00  8.684396e-01
I(logT^2)     -4.501235e-05  8.684396e-01  1.000000e+00
```

```
R>(D2 <- VarCorr(lmm.qu2))
```

```
$SUBJECT
```

```
1 x 1 Matrix of class "dpoMatrix"
```

```
(Intercept)
(Intercept)  4.011037
```

```
$SUBJECT
```

```
2 x 2 Matrix of class "dpoMatrix"
```

```
logT      I(logT^2)
logT      1.159320e-09 -5.688573e-10
I(logT^2) -5.688573e-10  6.910476e-10
```

```
attr(,"sc")
```

```
scale
1.175625
```

```
R>cov2cor(D2[[2]])
```

```
2 x 2 Matrix of class "dpoMatrix"
```

```
logT      I(logT^2)
logT      1.0000000 -0.6355469
I(logT^2) -0.6355469  1.0000000
```

Mit `nlme::lme()` kann man das quadratische Modell nicht einmal dann schätzen wenn man die numerisch günstigere Formulierung mit `poly` für den quadratischen Trend benutzt um eine orthogonale Designmatrix für den Zeittrend zu erzeugen. Die `lme4` Bibliothek ist stabiler/schneller und hat eine (meiner Meinung nach) etwas intuitivere Syntax für die

zufälligen Effekte, verfügt aber (noch?) nicht über ausgefeilte Diagnoseplots wie `nlme`. Da `nlme` und `lme4` teilweise gleichlautende Funktionen benutzen kommt es zu Konflikten wenn beide Pakete gleichzeitig geladen sind, deswegen sollte man tunlichst `detach` benutzen (s.o.) um das Paket das gerade nicht benötigt wird zu entfernen.

```
R>library(nlme)
R>lmerlmList.comparePred <- function(lmm, lmlist, primary, level = 0,
+   length.out = 51) {
+   args <- list(object = lmlist, primary = primary, level = level,
+     length.out = length.out)
+   val1 <- do.call("augPred", args)
+   val1 <- val1[val1$.type == "original", ]
+   temp1 <- cbind(val1[, 1:2], fitted(lmlist), .type = rep(deparse(substitute(lmlist)),
+     nrow(val1)))
+   temp2 <- cbind(val1[, 1:2], fitted(lmm), .type = rep(deparse(substitute(lmm)),
+     nrow(val1)))
+   names(temp1) <- names(temp2) <- names(val1)
+   val <- rbind(temp2, temp1, val1)
+   class(val) <- c("comparePred", "augPred", class(val))
+   attr(val, "labels") <- attr(val1, "labels")
+   attr(val, "units") <- attr(val1, "units")
+   attr(val, "formula") <- attr(val1, "formula")
+   val
+ }
R>print(plot(lmerlmList.comparePred(lmm.qu2, lmlist.qu, primary = "logT")))
```

— Imm.qu2      — lmlist.qu      — predicted

