

Aufgabe 1:

In dieser Aufgabe sollen Sie die kieferorthopädischen Wachstumsdaten aus dem in `nlme` enthaltenen Datensatz `Orthodont` analysieren.

(a) Benutzen Sie die Funktion `lme`, um ein Random-Effects-Modell `m` der Form

$$y_{ij} = \beta_0 + b_{0i} + \beta_1(t_j - 11) + \beta_2 x(t_j - 11) + \varepsilon_{ij}$$

anzupassen. Die Variable x repräsentiert das Geschlecht, t das Alter. Visualisieren Sie die Modellanpassung von `m` mit den Befehlen

```
R>plot(augPred(m))  
R>plot(m, resid(.) ~ age | Subject, abline = 0)
```

Ist das Modell ausreichend?

Lösung:

```
R>library(nlme)  
R>data(Orthodont)  
R>m <- lme(distance ~ I(age - 11) * Sex, random = ~1 | Subject,  
+ data = Orthodont)  
R>summary(m)
```

Linear mixed-effects model fit by REML

```
Data: Orthodont  
      AIC      BIC    logLik  
445.7572 461.6236 -216.8786
```

Random effects:

```
Formula: ~1 | Subject  
      (Intercept) Residual  
StdDev:   1.816214 1.386382
```

Fixed effects: distance ~ I(age - 11) * Sex

	Value	Std.Error	DF	t-value	p-value
(Intercept)	24.968750	0.4860008	79	51.37595	0.0000
I(age - 11)	0.784375	0.0775011	79	10.12082	0.0000
SexFemale	-2.321023	0.7614168	25	-3.04829	0.0054
I(age - 11):SexFemale	-0.304830	0.1214209	79	-2.51052	0.0141

Correlation:

	(Intr)	I(g-11)	SexFml
I(age - 11)	0.000		
SexFemale	-0.638	0.000	
I(age - 11):SexFemale	0.000	-0.638	0.000


Standardized Within-Group Residuals:

Min	Q1	Med	Q3	Max
-3.59804400	-0.45461690	0.01578365	0.50244658	3.68620792


Number of Observations: 108

Number of Groups: 27

```
R>print(plot(augPred(m)))
```



```
R>print(plot(m, resid(.) ~ age | Subject, abline = 0))
```




⇒ teilweise deutlicher Trend in subjektspezifischen Residuen, Random Slope evtl. sinnvoll.

- (b) Erweitern Sie das Modell um einen zufälligen subjektspezifischen Zeittrend. Vergleichen Sie (graphisch) die Schätzungen und Residuen aus den beiden Modellen.


Hinweis: `comparePred` erstellt ein plotbares Objekt.

Lösung:

```
R>m2 <- update(m, random = ~I(age - 11) | Subject)
R>print(plot(comparePred(m, m2)))
```




```
R>print(plot(m2, resid(.) ~ age | Subject, abline = 0))
```



⇒ wenig Veränderung - Warum?

Heuristisch: Subjektspezifischen Modelle zeigen dass Unterschiede in der Slope mit große Unsicherheit behaftet sind:

```
R>lmlist <- lmList(distance ~ I(age - 11), data = Orthodont)
R>print(plot(intervals(lmlist)))
```



Dementsprechend stark werden die subjektspezifischen Slope-Unterschiede durch die im Verhältnis sehr kleine geschätzte Varianz der Random Slopes ($\widehat{\text{Var}}(\mathbf{b}_1) = 0.0325$, $\hat{\beta}_1 = 0.784$) geschrumpft (\Rightarrow Shrinkage-Effekt).

- (c) Schätzen Sie das gleiche Modell mit ML (d.h. `method='ML'`) und vergleichen Sie die resultierende Kovarianzmatrix der zufälligen Effekte mit der aus der REML-Schätzung. Vergleichen Sie auch für beide Methoden die subjektspezifischen Koeffizienten.

Hinweis: `getVarCov` produziert $\text{Cov}(\mathbf{b}_i)$. Die Koeffizienten bekommen Sie mit der Funktion `coef`, die Methode `compareFits` erstellt ein plotbares Objekt.

Lösung:

```
R>m2.ml <- update(m2, method = "ML")
R>getVarCov(m2)
```

```
Random effects variance covariance matrix
      (Intercept) I(age - 11)
(Intercept)  3.350100  0.068142
I(age - 11)  0.068142  0.032524
Standard Deviations: 1.8303 0.18035
```


```
R>getVarCov(m2.ml)
```

Random effects variance covariance matrix

```
(Intercept) I(age - 11)
(Intercept)  3.070200  0.063094
I(age - 11)  0.063094  0.023759
Standard Deviations: 1.7522 0.15414
```

⇒ REML-Schätzungen größer als ML-Schätzungen (ML ist nach unten verzerrt, s. Vorlesung).

```
R>print(plot(compareFits(coef(m2)[, 1:2], coef(m2.ml)[, 1:2])))
```



⇒ unterschiedliche Schätzung der Varianzkomponenten wirkt sich bei Intercepts praktisch nicht aus, bei Slopes etwas deutlicher. REML-Schätzungen der Slopes streuen stärker da REML-Varianz deutlich größer als ML-Varianz.

Aufgabe 2:

Im folgenden sollen Sie die Funktion `gls` benutzen um marginale Modelle mit verschiedenen Korrelationsstrukturen zu vergleichen.

- (a) Schätzen Sie für die Orthodont-Daten ein Modell mit festen Effekten wie in in Modell *m* (s.o.), in dem die Beobachtungen verschiedener Subjekte voneinander unabhängig sein sollen und die Beobachtungen eines Subjektes eine unstrukturierte Korrelationsstruktur (Korrelationsstruktur *corSymm*) besitzen. Vergleichen Sie die geschätzte Korrelationsmatrix mit der Korrelationsmatrix die sich aus der marginalen Betrachtungsweise von Modell *m* ergibt. Benutzen Sie die Funktion *intervals* um die Variabilität der geschätzten Korrelationsparameter zu bestimmen.

Lösung:

```
R>m.mar <- gls(distance ~ I(age - 11) * Sex, correlation = corSymm(form = ~1 |
+ Subject), data = Orthodont)
R>summary(m.mar)
```

```
Generalized least squares fit by REML
Model: distance ~ I(age - 11) * Sex
Data: Orthodont
      AIC      BIC    logLik
448.1706 477.2589 -213.0853
```

```
Correlation Structure: General
Formula: ~1 | Subject
Parameter estimate(s):
Correlation:
  1    2    3
2 0.575
3 0.638 0.574
4 0.515 0.749 0.721
```

```
Coefficients:
              Value Std.Error  t-value p-value
(Intercept)  25.000655 0.4852207 51.52429 0.0000
I(age - 11)   0.824340 0.0824257 10.00101 0.0000
SexFemale    -2.355437 0.7601948 -3.09847 0.0025
I(age - 11):SexFemale -0.348101 0.1291362 -2.69561 0.0082
```

```
Correlation:
              (Intr) I(g-11) SexFml
I(age - 11)      0.070
SexFemale       -0.638 -0.045
I(age - 11):SexFemale -0.045 -0.638  0.070
```

```
Standardized residuals:
      Min      Q1      Med      Q3      Max
-2.41707511 -0.64439569 -0.07388949  0.58480652  2.26288068
```

```
Residual standard error: 2.286910
Degrees of freedom: 108 total; 104 residual
```

```
R>cov.m.mar <- getVarCov(m.mar)
R>varb.m <- getVarCov(m)[1, 1]
R>cov2cor(cov.m.mar)
```

```

Marginal variance covariance matrix
      [,1] [,2] [,3] [,4]
[1,] 1.00000 0.57541 0.63757 0.51478
[2,] 0.57541 1.00000 0.57428 0.74888
[3,] 0.63757 0.57428 1.00000 0.72060
[4,] 0.51478 0.74888 0.72060 1.00000
Standard Deviations: 1 1 1 1

```

```
R>varb.m/(varb.m + m$sigma^2)
```

```
[1] 0.6318388
```

Die letzte Zeile berechnet die (marginale) geschätzte Korrelation zweier Beobachtungen des selben Subjektes (s.a. Blatt 3: Varianz der zufälligen Intercepts geteilt durch Summe der Varianzen der zufälligen Intercepts und der Residuen) in Modell *m* - diese ist immer gleich da das Random Intercept Modell einem CompoundSymmetry Modell mit positiven Korrelationen entspricht. Man sieht hier dass die unrestringiert geschätzte Korrelationsstruktur aus *gls* der CompoundSymmetry recht ähnlich ist.

```
R>intervals(m.mar, which = "var-cov")
```

Approximate 95% confidence intervals

```

Correlation structure:
      lower      est.      upper
cor(1,2) 0.2408361 0.5754124 0.7877569
cor(1,3) 0.3759471 0.6375722 0.8050547
cor(1,4) 0.1675088 0.5147787 0.7484040
cor(2,3) 0.2694383 0.5742825 0.7745177
cor(2,4) 0.5226129 0.7488760 0.8765910
cor(3,4) 0.5000277 0.7205955 0.8533694
attr(,"label")
[1] "Correlation structure:"

```

```

Residual standard error:
      lower      est.      upper
1.863055 2.286910 2.807195

```

Die Intervalle der Korrelationen überlappen sich großteils- das spricht dafür dass man die Korrelationsstruktur zu einer CompoundSymmetry-Struktur vereinfachen kann.

- (b) Schätzen Sie ein Modell mit vereinfachter Korrelationsstruktur so, dass diese der marginalen Korrelationsstruktur von Modell *m* entspricht.

Lösung:

```

R>m.mar2 <- gls(distance ~ I(age - 11) * Sex, correlation = corCompSymm(form = ~1 |
+ Subject), data = Orthodont)
R>summary(m.mar2)

```

```

Generalized least squares fit by REML
Model: distance ~ I(age - 11) * Sex
Data: Orthodont

```

AIC BIC logLik
445.7572 461.6236 -216.8786

Correlation Structure: Compound symmetry

Formula: ~1 | Subject

Parameter estimate(s):

Rho

0.6318381

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	24.968750	0.4860003	51.37600	0.0000
I(age - 11)	0.784375	0.0775011	10.12082	0.0000
SexFemale	-2.321023	0.7614161	-3.04830	0.0029
I(age - 11):SexFemale	-0.304830	0.1214209	-2.51052	0.0136

Correlation:

	(Intr)	I(g-11)	SexFml
I(age - 11)	0.000		
SexFemale	-0.638	0.000	
I(age - 11):SexFemale	0.000	-0.638	0.000

Standardized residuals:

Min	Q1	Med	Q3	Max
-2.45773173	-0.57853118	-0.07360637	0.58204364	2.29634478

Residual standard error: 2.284881

Degrees of freedom: 108 total; 104 residual

R>getVarCov(m.mar2)

Marginal variance covariance matrix

	[,1]	[,2]	[,3]	[,4]
[1,]	5.2207	3.2986	3.2986	3.2986
[2,]	3.2986	5.2207	3.2986	3.2986
[3,]	3.2986	3.2986	5.2207	3.2986
[4,]	3.2986	3.2986	3.2986	5.2207

Standard Deviations: 2.2849 2.2849 2.2849 2.2849

R>cov2cor(getVarCov(m.mar2))

Marginal variance covariance matrix

	[,1]	[,2]	[,3]	[,4]
[1,]	1.00000	0.63184	0.63184	0.63184
[2,]	0.63184	1.00000	0.63184	0.63184
[3,]	0.63184	0.63184	1.00000	0.63184
[4,]	0.63184	0.63184	0.63184	1.00000

Standard Deviations: 1 1 1 1