



Lösungsskizze Serie 4

1. a) In der Scatterplot-Matrix fällt auf, dass RUT nicht linear von VISC abhängt. Werden diese Variablen logarithmiert, so ist der Zusammenhang linear. Alle anderen Variablen, braucht man nicht zu transformieren.



```
> asphalt.lm <- lm(log(RUT) ~ log(VISC)+ASPH+BASE+FINES+VOIDS+RUN, data=asphalt)
> summary(step=asphalt.lm, direction="backward")
```

```
Start: AIC=-77.35
log(RUT) ~ log(VISC) + ASPH + BASE + FINES + VOIDS + RUN
```

	DF	Sum of Sq	RSS	AIC
- FINES	1	0.021	1.648	-78.985
- BASE	1	0.034	1.662	-78.705
<none>			1.628	-77.355
- RUN	1	0.300	1.927	-74.115
- VOIDS	1	0.559	2.186	-70.208
- ASPH	1	1.265	2.892	-61.530
- log(VISC)	1	3.348	4.976	-44.713

```
Step: AIC=-78.96
log(RUT) ~ log(VISC) + ASPH + BASE + VOIDS + RUN
```

	DF	Sum of Sq	RSS	AIC
- BASE	1	0.065	1.713	-79.768
<none>			1.648	-78.985
- RUN	1	0.288	1.936	-75.987
- VOIDS	1	0.692	2.340	-70.098
- ASPH	1	1.293	2.941	-63.016
- log(VISC)	1	3.629	5.277	-44.887

```
Step: AIC=-79.77
log(RUT) ~ log(VISC) + ASPH + VOIDS + RUN
```

	DF	Sum of Sq	RSS	AIC
<none>			1.713	-79.768
- RUN	1	0.231	1.944	-77.849
- VOIDS	1	0.675	2.388	-71.470
- ASPH	1	1.245	2.958	-64.836
- log(VISC)	1	4.608	6.321	-41.294

```
Call:
lm(formula = log(RUT) ~ log(VISC) + ASPH + VOIDS + RUN, data = asphalt)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.42912	-0.15258	-0.01832	0.17435	0.40451

Coefficients:

Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	-4.01082	1.49034	-2.691	0.012284 *
log(VISC)	-0.54747	0.06547	-8.363	7.62e-09 ***

b) Schrittweise rückwärts:

Wir betrachten das volle Modell

$$\log(\text{RUT}) = \beta_0 + \beta_1 \log(\text{VISC}) + \beta_2 \text{ASPH} + \beta_3 \text{BASE} + \beta_4 \text{FINES} + \beta_5 \text{VOIDS} + \beta_6 \text{RUN}$$

und eliminieren schrittweise die am wenigsten signifikante Variable (d.h. diejenige Variable, nach deren Weglassen das verbleibende Modell den kleinsten AIC-Wert aufweist).

```

ASPH      1 0.7061      0.24631      4.347 0.000188 ***
VOIDS     0.33089      0.10338      3.201 0.003597 **
RUM       -0.51199      0.27355     -1.872 0.072545 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.2567 on 26 degrees of freedom
Multiple R-squared:  0.9708,    Adjusted R-squared:  0.9663
F-statistic:  216 on 4 and 26 degrees of freedom,    p-value:      0

```

Das Endmodell lautet mit schrittweiser Variablenselektion rückwärts:

$$\log(\text{RUT}) = \beta_0 + \beta_1 \log(\text{VISCO}) + \beta_2 \text{ASPH} + \beta_3 \text{VOIDS} + \beta_4 \text{RUM}.$$

Schrittweise vorwärts:

Wir betrachten das Modell $\log(\text{RUT}) = \beta_0$ und fügen schrittweise die signifikanteste der verbleibenden Variable hinzu (d.h. die Variable mit dem kleinsten AIC).

```

> start_lm <- lm(log(RUT)~1, asphalt)
> summary(stepAIC(start_lm,scope=list(upper=log(RUT),log(VISCO)+ASPH+BASE+
+ FIMES+VOIDS+RUM), direction="forward"))
Start: AIC= 21.76
Log(RUT) ~ 1

```

	Df	Sum of Sq	RSS	AIC
+ log(VISCO)	1	55.423	3.210	-66.302
+ RUM	1	50.565	8.067	-37.732
+ VOIDS	1	9.865	48.767	18.045
+ FIMES	1	6.021	52.612	20.397
<none>			58.632	21.756
+ BASE	1	2.095	56.537	22.628
+ ASPH	1	1.399	57.233	23.008

```

Step: AIC= -66.3
log(RUT) ~ log(VISCO)

```

	Df	Sum of Sq	RSS	AIC
+ ASPH	1	0.566	2.643	-70.321
<none>			3.210	-66.302
+ VOIDS	1	0.158	3.052	-65.868
+ RUM	1	0.122	3.087	-65.508
+ FIMES	1	0.045	3.165	-64.737
+ BASE	1	0.029	3.180	-64.587

```

Step: AIC= -70.32
log(RUT) ~ log(VISCO) + ASPH

```

	Df	Sum of Sq	RSS	AIC
+ VOIDS	1	0.699	1.944	-77.849
+ RUM	1	0.255	2.388	-71.470
<none>			2.643	-70.321
+ FIMES	1	0.115	2.529	-69.697
+ BASE	1	0.002	2.641	-68.343

```

Step: AIC= -77.85
log(RUT) ~ log(VISCO) + ASPH + VOIDS

```

	Df	Sum of Sq	RSS	AIC
+ RUM	1	0.231	1.713	-79.768
<none>			1.944	-77.849
+ FIMES	1	0.015	1.929	-76.089
+ BASE	1	0.007	1.936	-75.967

```

Step: AIC= -79.77
log(RUT) ~ log(VISCO) + ASPH + VOIDS + RUM

```

	Df	Sum of Sq	RSS	AIC
<none>			1.713	-79.768
+ BASE	1	0.065	1.648	-78.965
+ FIMES	1	0.051	1.662	-78.705

Call:

```
lm(formula = log(RUT) ~ log(VISCO) + ASPH + VOIDS + RUM, data = asphalt)
```

```

Residuals:
    Min       1Q   Median       3Q      Max
-0.42912 -0.15258 -0.01832  0.17435  0.40451

```

Coefficients:


```

(Intercept) -4.01062      1.49034     -2.691 0.012284 *
log(VISCO)  -0.54747     0.06547     -8.363 7.62e-09 ***
ASPH        1.07061     0.24631     4.347 0.000188 ***
VOIDS      0.33089     0.10338     3.201 0.003597 **
RUM       -0.51199     0.27355     -1.872 0.072545 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Residual standard error: 0.2567 on 26 degrees of freedom
Multiple R-squared: 0.9708, Adjusted R-squared: 0.9663
F-statistic: 216 on 4 and 26 degrees of freedom, p-value: 0
Das Resultat ist identisch mit demjenigen des Backward-Verfahrens.



2. a) Der Tukey-Anscombe Plot zeigt nichts unerwünschtes. Die Varianz der Fehler kann als konstant angesehen werden.



- b) Die Fehler scheinen nicht normalverteilt zu sein. Diese leichte Inhomogenität kann aber rein daher resultieren, dass die Anzahl der Daten ($n = 31$) klein ist. Der Q-Q-Plot wird daher als 'in Ordnung' betrachtet.
c) Die Fehler sind mit keiner erklärenden Variablen korreliert, d.h. die Grafiken zeigen keine unerwünschte Struktur.

Das Modell scheint die Daten gut zu beschreiben.

R-Code:



```
> asphalt.mod <- lm(log(RUM) ~ log(VOIDS)+ASPH+VOIDS+RUM, data=asphalt)
> plot(fitted(asphalt.mod), resid(asphalt.mod))
> qqnorm(resid(asphalt.mod))
> par(mfrow=c(2,2))
> plot(log(asphalt[, 'VOIDS']), resid(asphalt.lm))
> plot(asphalt[, 'ASPH'], resid(asphalt.lm))
> plot(asphalt[, 'VOIDS'], resid(asphalt.lm))
> plot(asphalt[, 'RUM'], resid(asphalt.lm))
```

3. Daten einlesen:

```
> korrelation<-read.table.url(
  'http://stat.ethz.ch/Teaching/Datasets/korrelation.dat', header=T)
```

Die Matrix des linearen Modells berechnet man folgendermassen:

```
> eins<-rep(1,30)
> X.1 <- korrelation$X1-1
> X1<-cbind(eins,X.1)
> X.2 <- korrelation$X2-1
> X2<-cbind(eins,X.2)
> X.3 <- korrelation$X3-1
> X3<-cbind(eins,X.3)
```

Die Kovarianzmatrix Σ bekommt man wie folgt:

```
> sigma<-0.8*(abs(outer(1:30,1:30,FUN='*')))
```

a) Im ersten Fall ist die Standardabweichung von $\hat{\beta}$ gegeben durch: $\sqrt{(X^T X)^{-1} \Sigma}$. Der

R-Code ist:

```
> covX1.a <- sqrt(solve(t(X1)%*%X1)[2,2]) # für i),a)
> covX2.a <- sqrt(solve(t(X2)%*%X2)[2,2]) # für i),b)
> covX3.a <- sqrt(solve(t(X3)%*%X3)[2,2]) # für i),c)
```

Das Resultat ist:

```
i),a): 0.3651484, i),b): 0.3651484, i),c): 0.3651484
```

Da die Korrelation ignoriert wird und wir überall in allen drei Fällen die gleichen 30 Modellgleichungen haben (nur in einer anderen Reihenfolge), bekommen wir überall dasselbe Resultat.

b) Im zweiten Fall ist die Standardabweichung von $\hat{\beta}$ gegeben durch:

$\sqrt{(X^T X)^{-1} (X^T \Sigma X)^{-1}}$. Der R-Code ist:

```
> covX1.b <- sqrt((solve(t(X1)%*%X1)%*%(t(X1)%*%sigma
  %*%X1)%*%solve(t(X1)%*%X1))[2,2]) # für ii),a)
> covX2.b <- sqrt((solve(t(X2)%*%X2)%*%(t(X2)%*%sigma
  %*%X2)%*%solve(t(X2)%*%X2))[2,2]) # für ii),b)
> covX3.b <- sqrt((solve(t(X3)%*%X3)%*%(t(X3)%*%sigma
  %*%X3)%*%solve(t(X3)%*%X3))[2,2]) # für ii),c)
```

Man bekommt:

```
ii),a): 0.8315447, ii),b): 0.4167435, ii),c): 0.1692576
```

c) Im letzten Fall ist die Standardabweichung von $\hat{\beta}$ gegeben durch: $\sqrt{(X^T \Sigma^{-1} X)^{-1}}$. Der R-Code ist:

```
> covX1.c <- sqrt(solve(t(X1)%*%solve(sigma)%*%X1)[2,2]) # für iii),a)
> covX2.c <- sqrt(solve(t(X2)%*%solve(sigma)%*%X2)[2,2]) # für iii),b)
> covX3.c <- sqrt(solve(t(X3)%*%solve(sigma)%*%X3)[2,2]) # für iii),c)
```

Das Resultat ist:

```
iii),a): 0.5523448, iii),b): 0.1900871, iii),c): 0.1415663
```

Zwei Dinge fallen auf:

1. Die verallgemeinerte kleinste Quadrate Methode, gibt genauere Schätzungen für $\hat{\beta}$ als die Methode in c). Sie berücksichtigt also die Korrelation besser.

2. Die letzte Versuchsreihenfolge gibt (ausser mit a)) die besten Schätzungen. Grund: Durch die zufällige, aber trotzdem alternierende Wahl, der Gruppe wird die Möglichkeit der Korrelation vermindert.