1 BSP 1: Kenngrößen für *fvc* und *alter* des AIMU Datensatzes

	fvc	alter
xbar	553.494	30.278
xmed	550	31
sd	76.27	10.475
sdL	75.786	10.408
sq	81.542	13.343
g1	0.3	0.238
g2	0.102	-0.944
ssmin	-2.078	-1.363
ssmax	2.97	2.456
min	395	16
max	780	56

Tabelle 1: Kenngrößen laut Tabelle 1.2 des VL Skriptums.

```
n_79#Umfang der Stichproben
R_2000#Simulationsumfang
#Mat(11\times R)
sample.stats_matrix(0,11,R)
for (i in seq(1,R)){
sample_rnorm(79,stat.var[1],stat.var[3])
sample.stats[1,i]_xbar(sample)
sample.stats[2,i]_xmed(sample)
sample.stats[3,i]_sd(sample)
sample.stats[4,i]_sdL(sample)
sample.stats[5,i]_sq(sample)
sample.stats[6,i]_g1(sample)
sample.stats[7,i]_g2(sample)
sample.stats[8,i]_ssmin(sample)
sample.stats[9,i]_ssmax(sample)
sample.stats[10,i]_min(sample)
sample.stats[11,i]_max(sample)}
```

```
par(mfrow=c(3,4))
for (i in seq(1,11)){
#Histogramm der i-ten Zeile (i-te Kenngroeße)
hist(sample.stats[i,],xlab=stat.names[i],ylab="",probability=T)
#Beobachteter Wert in AIMU
abline(v=stat.var[i])}
```

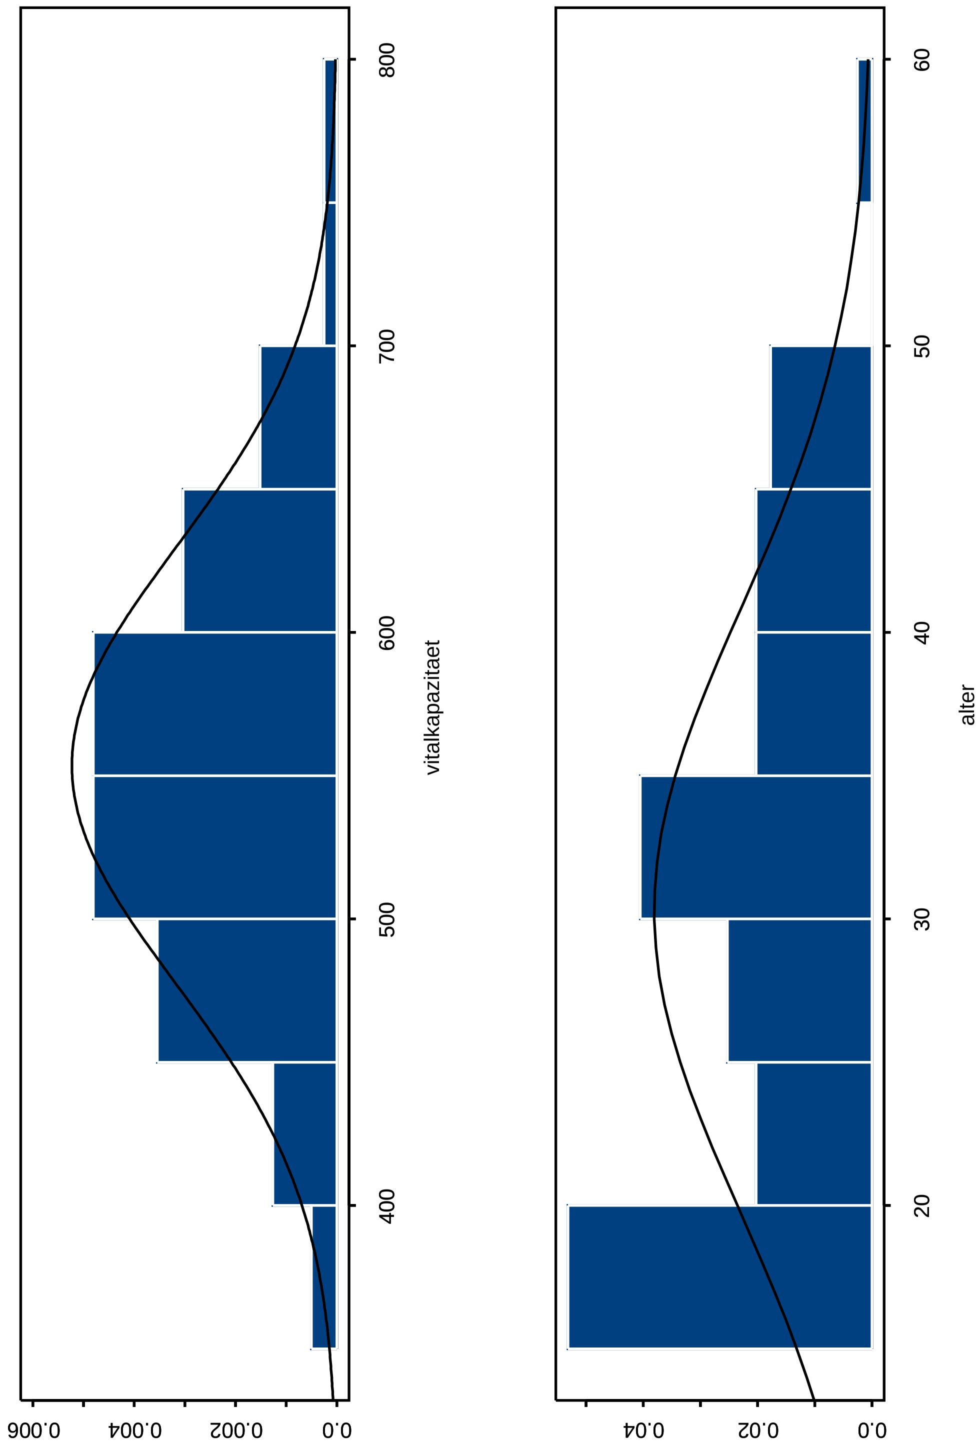

Abbildung 1: Histogramme für die *fvc* und *alter* Kennzahlen.

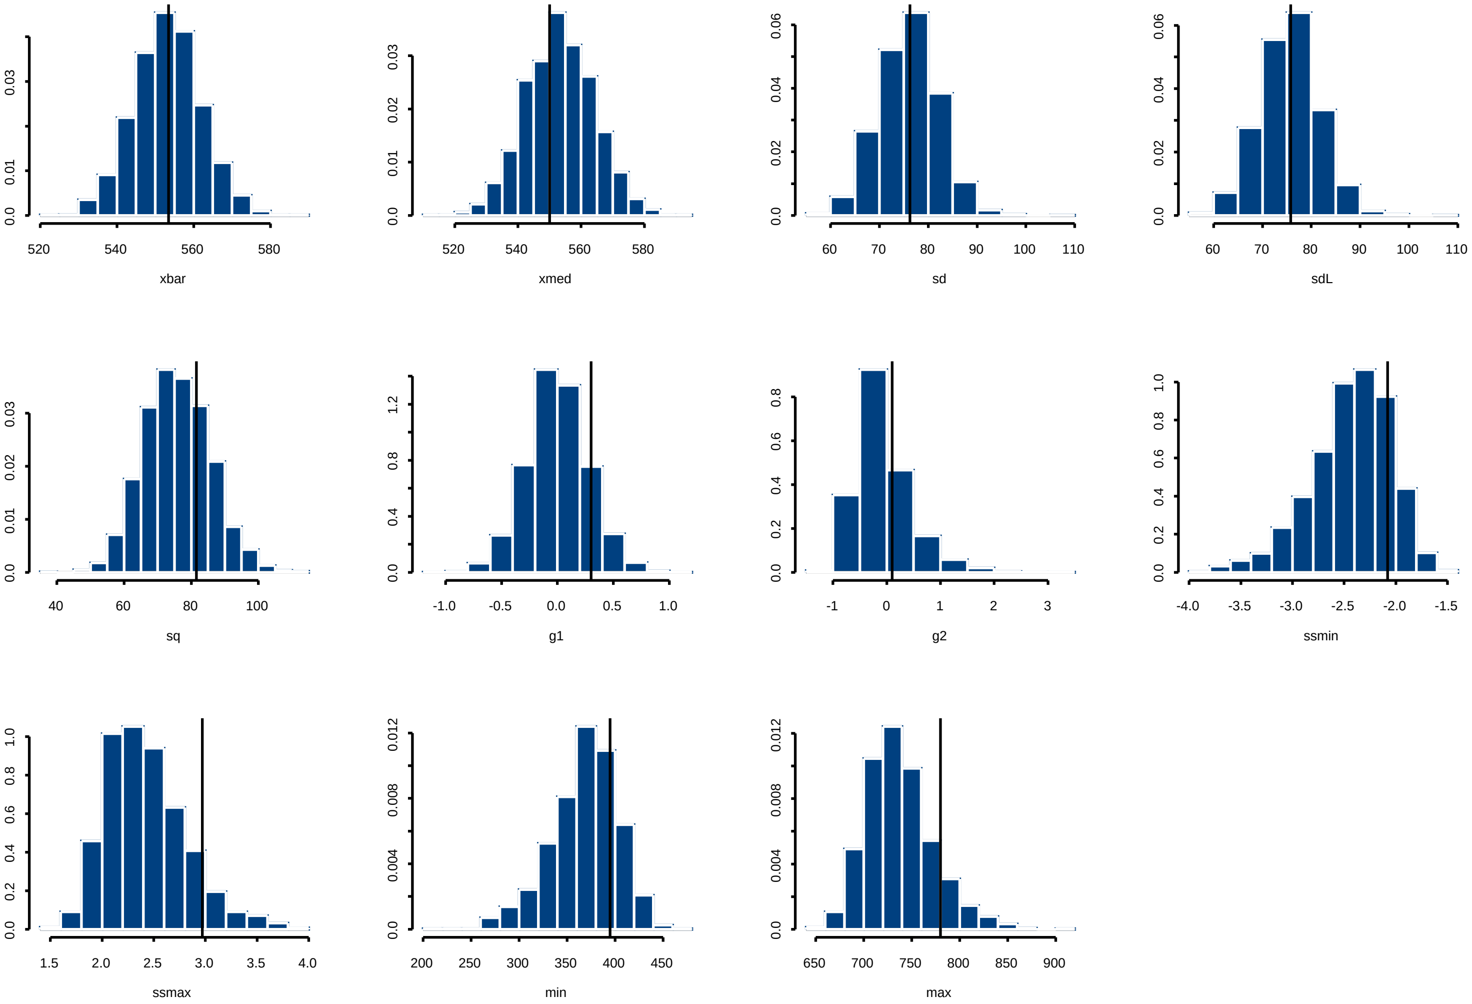

Abbildung 2: Histogramme für Simulation Kennzahlen (fvc).

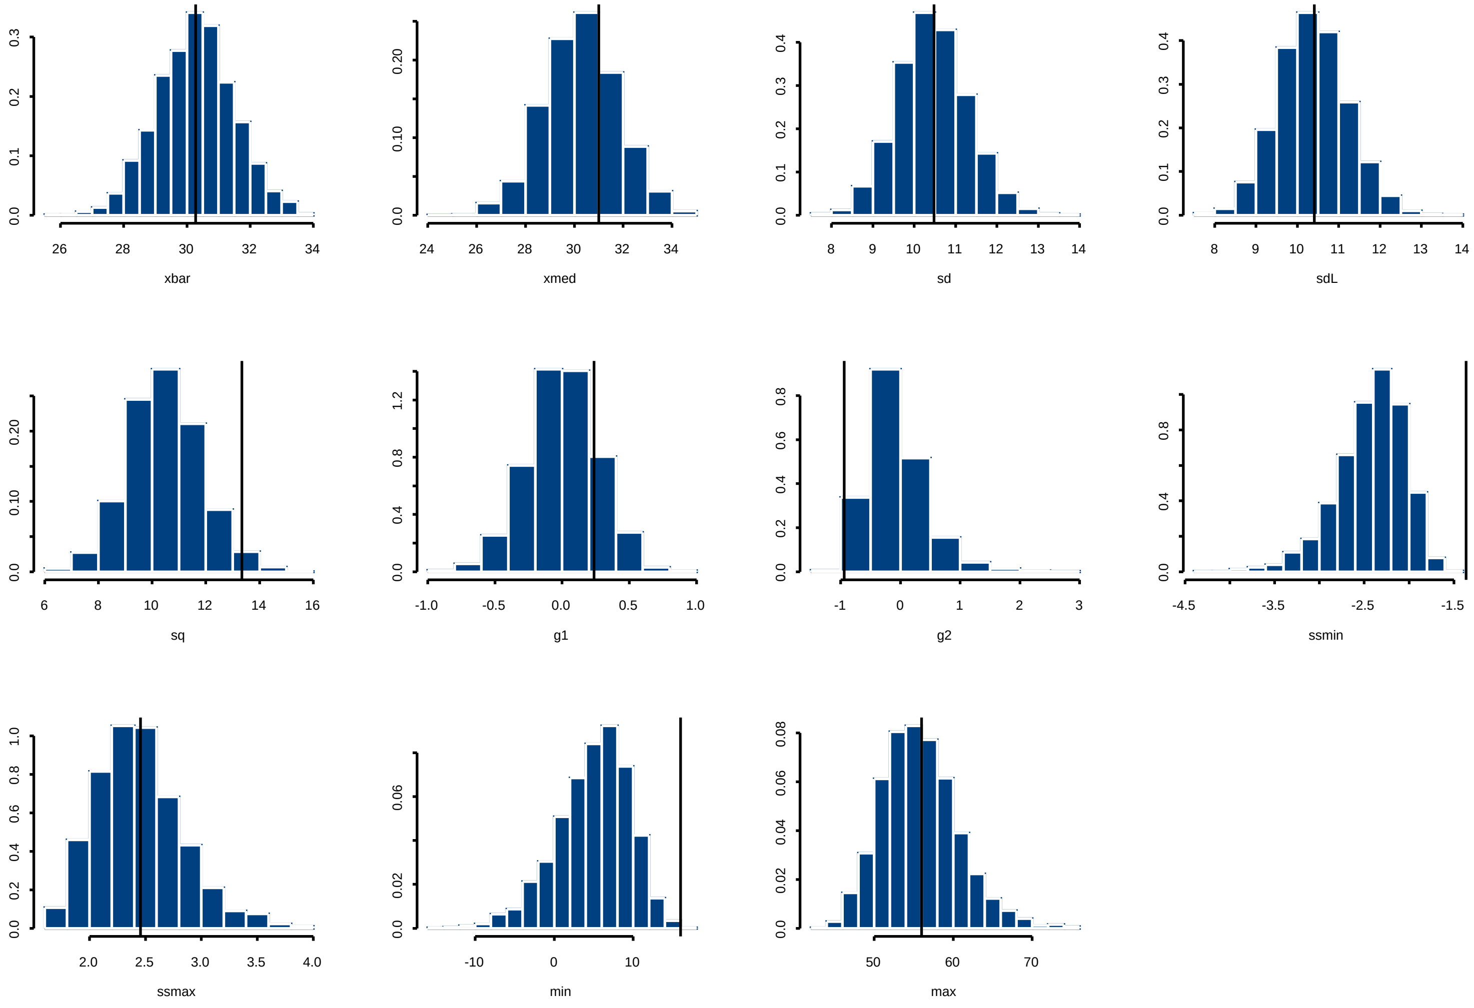

Abbildung 3: Histogramme für Simulation der Kennzahlen (*alter*).

2 BSP 2: CPU-Daten

```
#Kennzahlen
summary.zeit_mysummary(zeit)
texout(cbind(summary.zeit,rep(0,11)),rn=rn)
#Optimale Klassenbreite
k_2*sqrt(n) = 10
hist(zeit,nclass=10,probability=T)
boxplot(zeit)
symmplot(zeit)
```

	Zeit
xbar	1.63
xmed	1.38
sd	1.193
sdL	1.169
sq	1.086
g1	0.916
g2	0.301
ssmin	-1.35
ssmax	2.616
min	0.02
max	4.75

Tabelle 2: Kenngrößen für CPU-Daten.

Die Parameter der Gamma-Verteilung für den Q–Q–Plot der Daten versus Quantile der Gamma-Verteilung sind

```
Gamma distribution parameters estimated:
shape=1.9216755 scale=1.1660652
```

Siehe Abbildungen 4.

3 BSP 5: Simulation von empirischen Verteilungsfunktionen

```
n=20 #40,80,160
par(mfrow=c(3,4))
for (i in seq(1,12))
{
sample_rnorm(n,0,1)
```

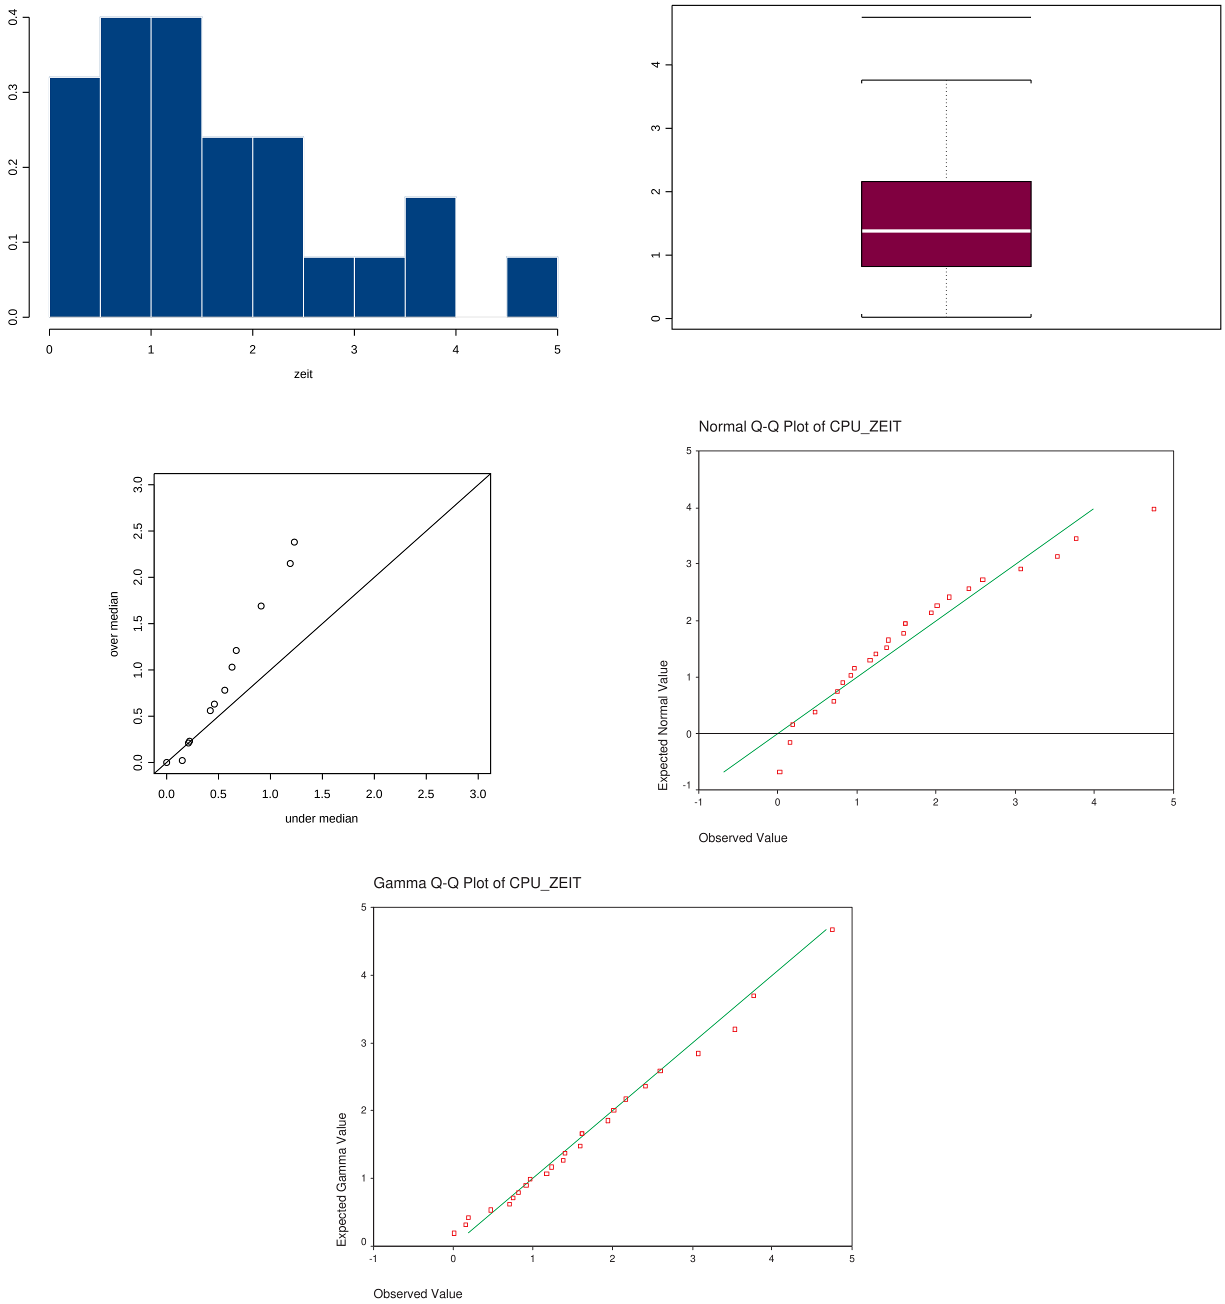

Abbildung 4: Graphiken für die CPU Daten.

```
cdf.plot(sample,xl="kuenstl. Stichprobe")
}
```

Mit wachsendem n wird die Anpassung an das theoretische Modell besser. Siehe Abbildung 5, 6.

4 BSP 6: Sonnenflecken Daten

Die Boxplotserie zeigt den zyklischen Verlauf der Sonnenfleckenaktivität. Länge eines Zyklus 10-11 Jahre. Siehe Abbildung 8.

5 BSP 9: Monte Carlo Approximation für $E(X_{(75)})$, und $Var(X_{(75)})$

```
n_100
lambda_1
R_2500
mean.var_matrix(0,R,2)
for (r in seq(2,R)){
sample_rexp(n)
x75_sort(sample)[75]
if (r==1){
mean.var[r,1]_x75
mean.var[r,2]_0
}
mx75r_(mean.var[r-1,1]*(r-1) + x75)/r
mean.var[r,1]_mx75r
mean.var[r,2]_(mean.var[r-1,2]*(r-1)+(x75-mx75r)^2)/r}
```

Stabilisierung nach ca. 1000 Stichproben – sowohl bei Erwartungswert als auch Varianz. $X_{(75)}$ ist offensichtlich ein leicht verzerrter Schätzer für das 0.75–Quantil von $Exp(1)$. Siehe Abbildung 8.

6 BSP 10: Simulation von Q–Q–Plots

```
R_12
n_20 #100
for (i in seq(1,R)){
sample_rnorm(n)
qqnorm(sample)
qqline(sample)}
```

Siehe Abbildung 9 und 10

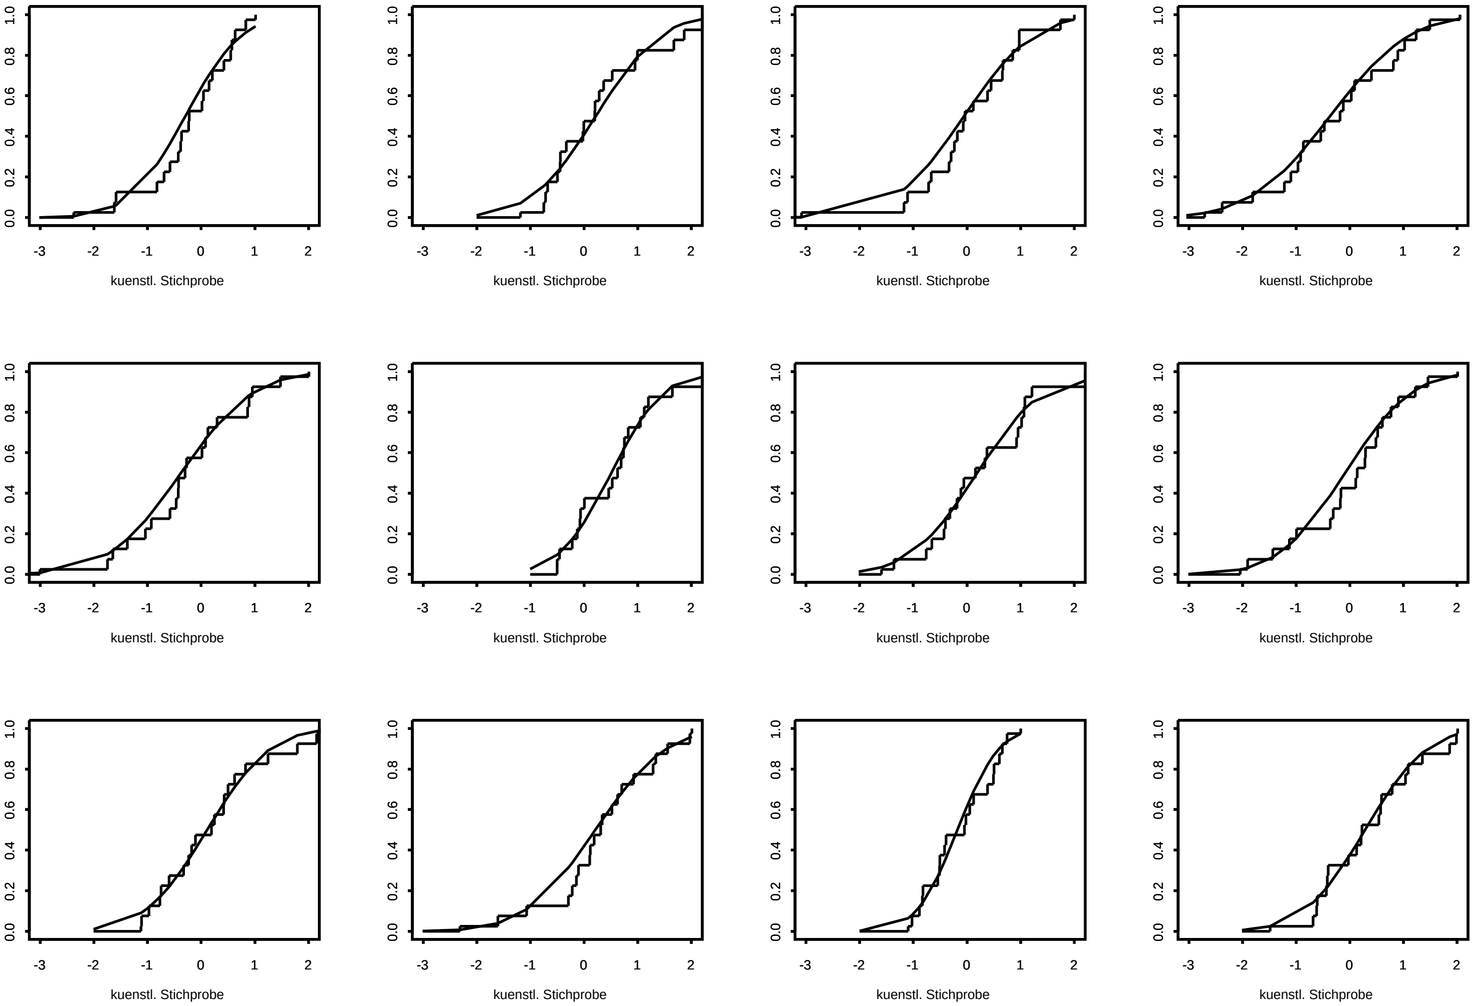

Abbildung 5: Empirische Verteilungsfunktionen, $n = 20$.

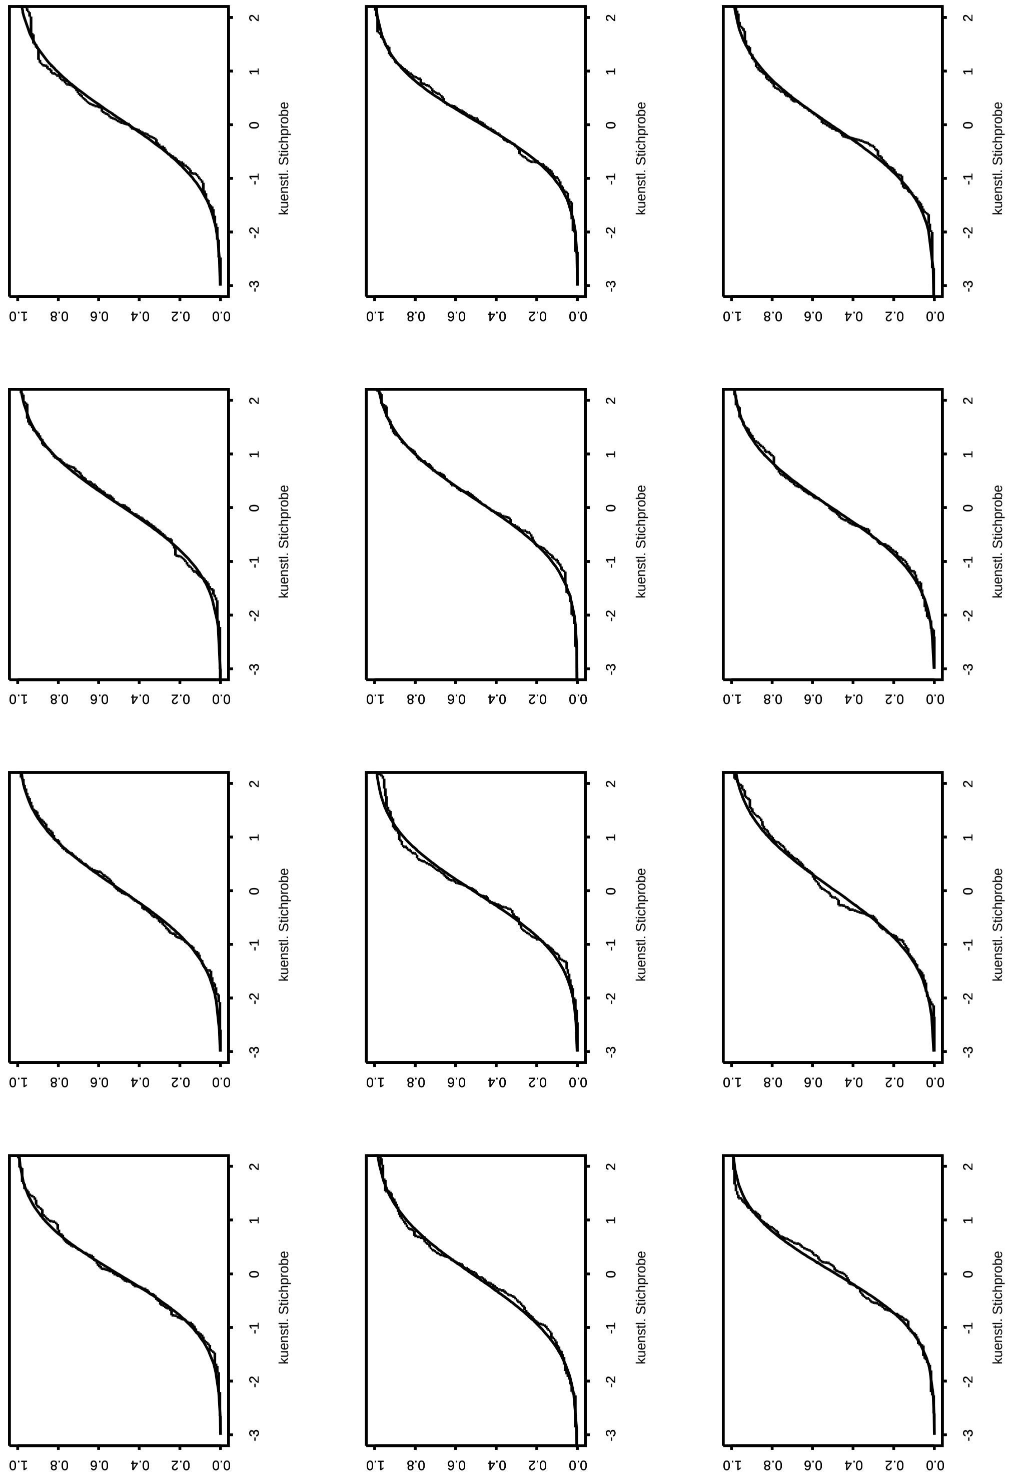

Abbildung 6: Empirische Verteilungsfunktionen, $n = 160$.

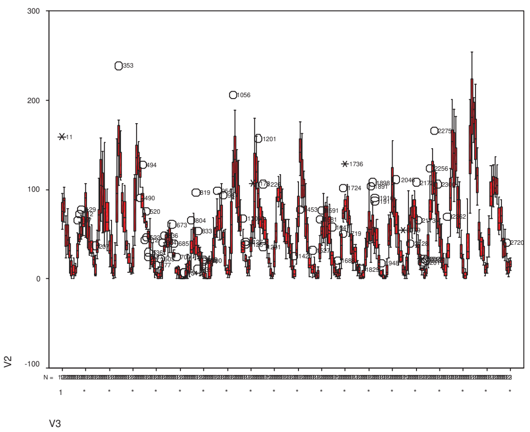

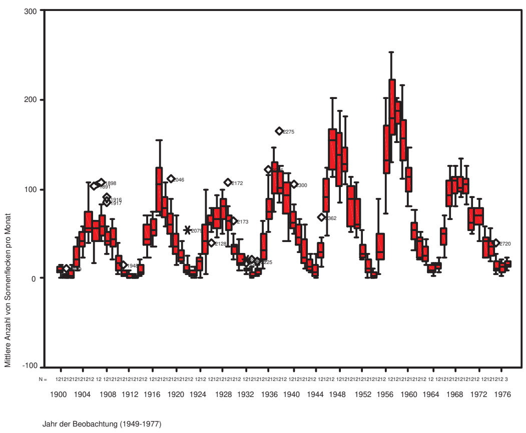

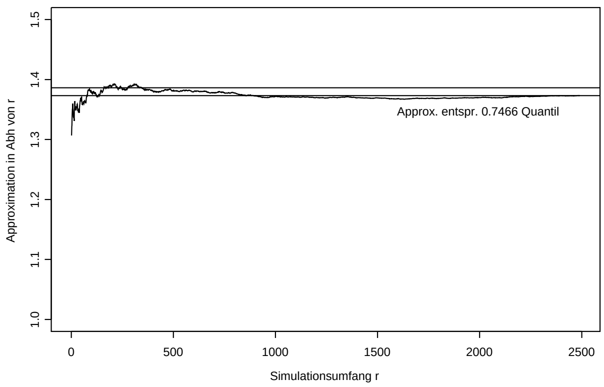

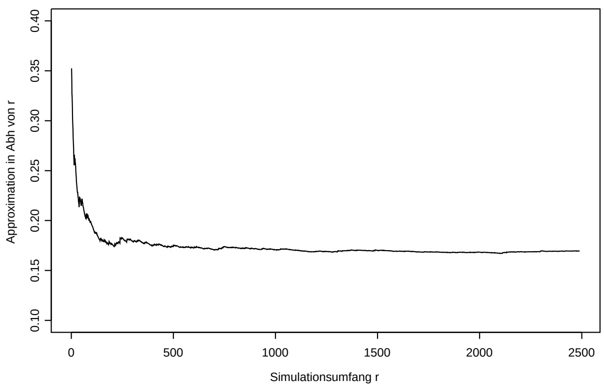

Abbildung 7: Oben: Boxplotserien der Sonnenflecken Daten.

Abbildung 8: Unten: Monte Carlo Erwartungswert (oben) und Varianz (unten) von $X_{(75)}$, $r = 10, 2500$.

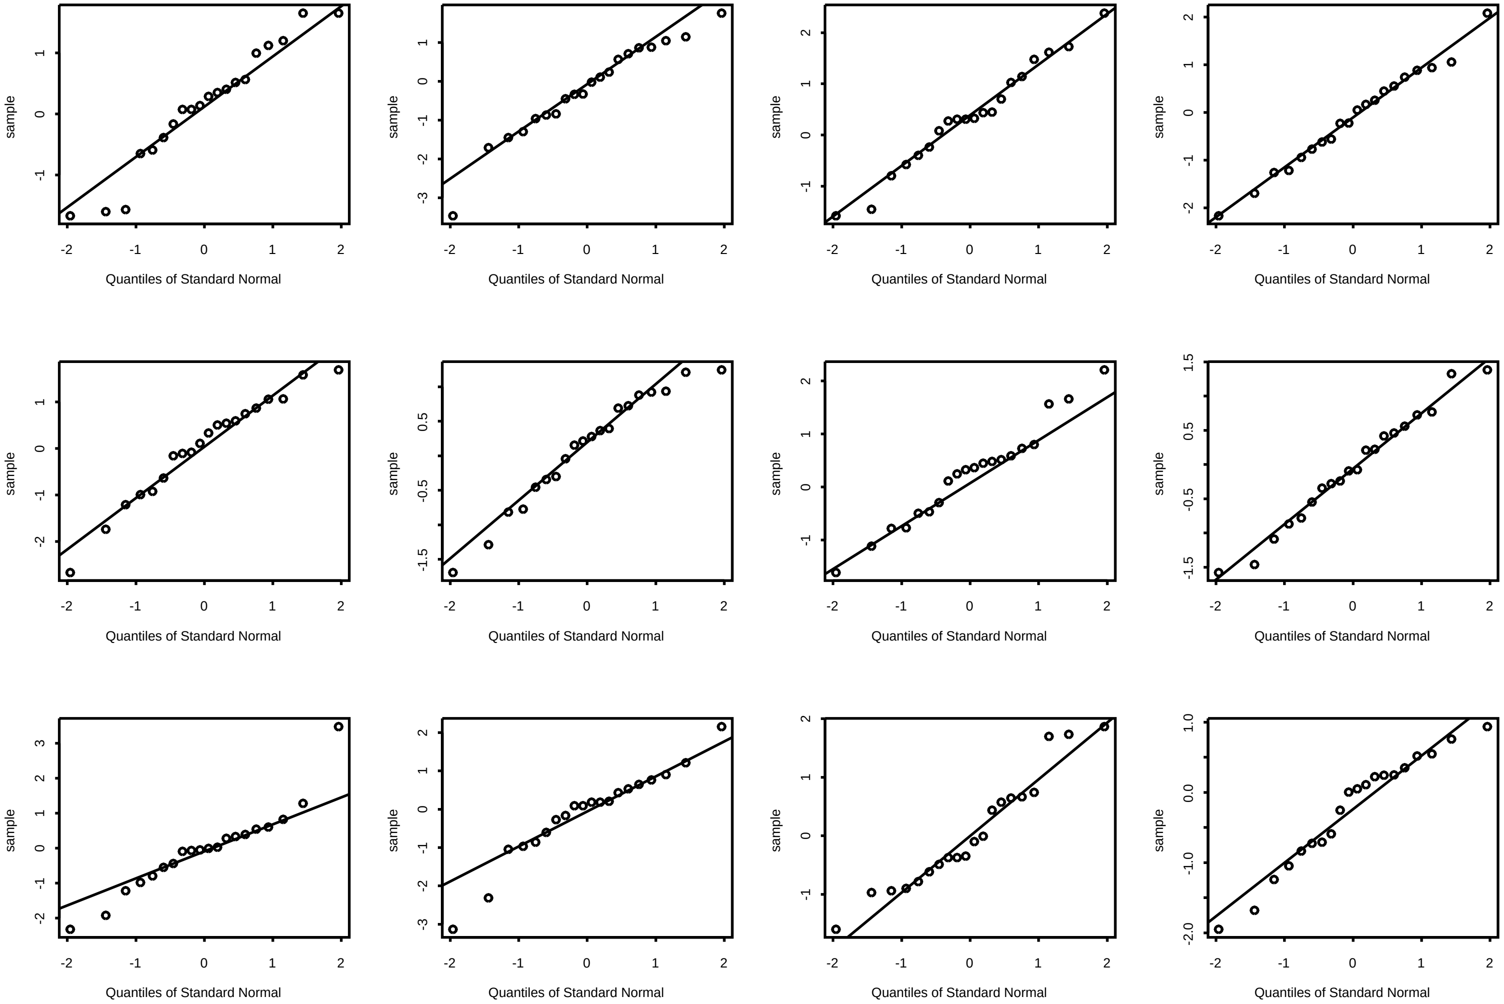

Abbildung 9: Simulation von Q–Q-Plots ($n = 20$).

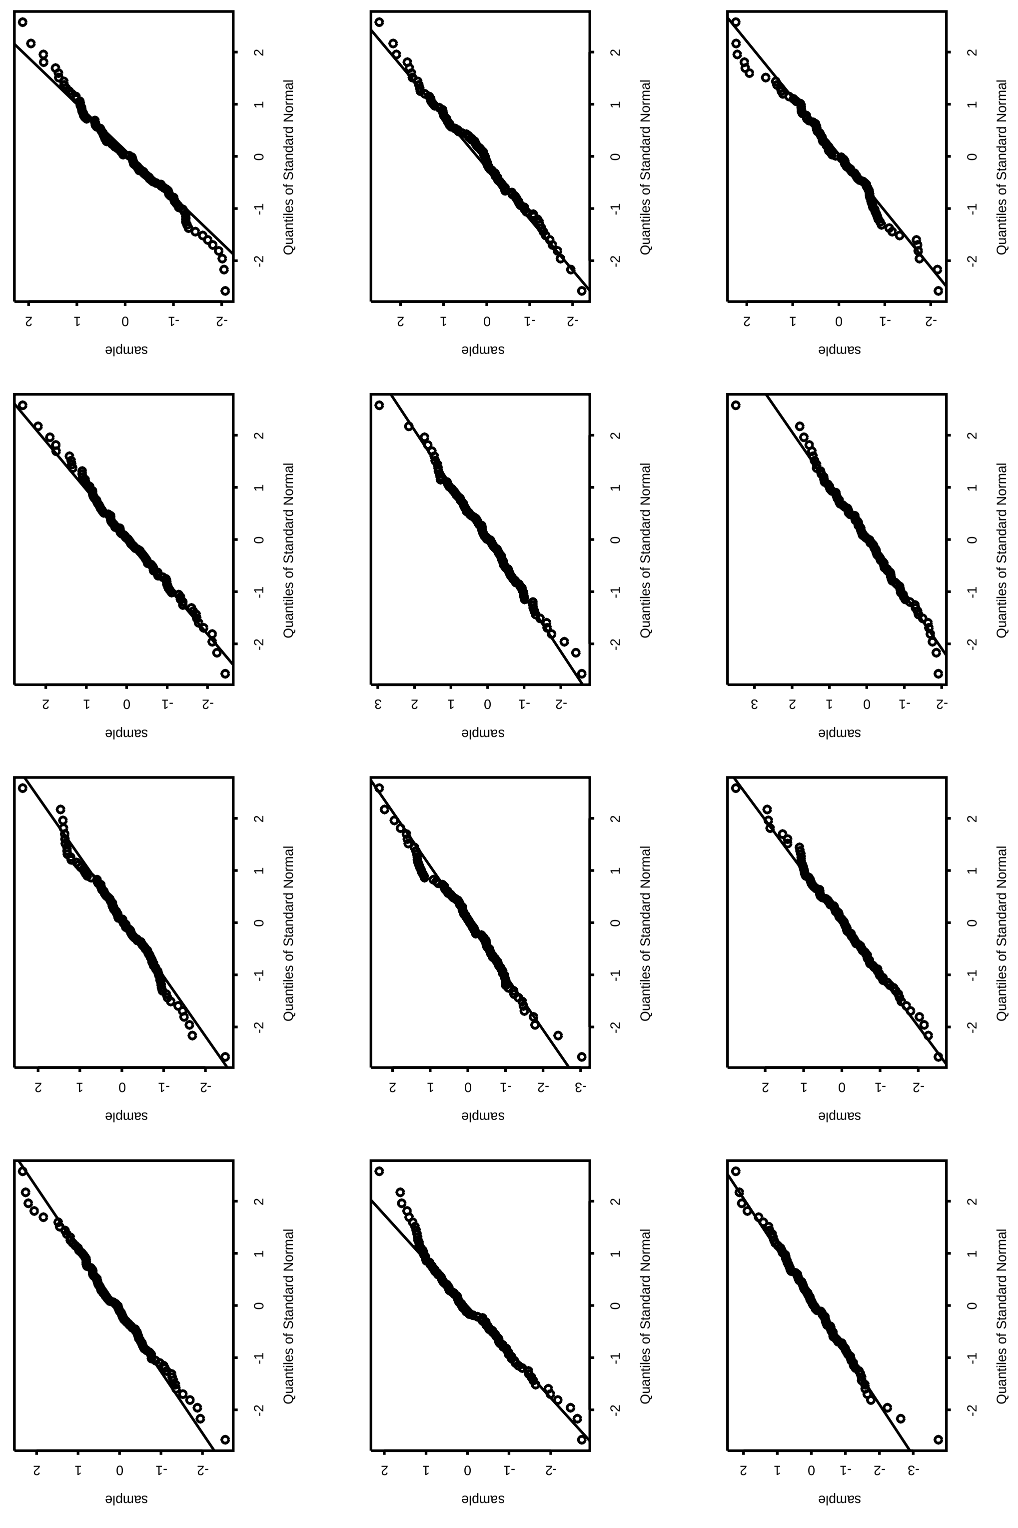

Abbildung 10: Simulation von Q–Q–Plots ($n = 100$).