

```

#####
#
# Reinhard Hoepfner -- Statistik mit Rechneruebungen fuer Lehramtsstudierende -- SoSe19
#
# Uebungsblatt 3
#
# Konfidenzintervalle fuer Lokations- und Skalenmodelle
# erzeugt von Doppelexponentialverteilung
#
# fuer verschiedene Paare 'richtig skalierender' Schaetzer
#
# 21.06.19
#
#####

#####
#
# doppelexponentialverteilung und
# doppelexponentialverteilte zufallszahlen
#
#####
# quantile irgendeines datensatzes

meine_quantile <- function(dat){
  abline( v=min(dat), col=2, lty=3 ) ;
  abline( v=quantile(dat,0.025), col=2, lty=4 ) ;
  abline( v=quantile(dat,0.05), col=2, lty=2 ) ;
  abline( v=quantile(dat,0.1), col=2, lty=6 ) ;
  abline( v=quantile(dat,0.9), col=2, lty=6 ) ;
  abline( v=quantile(dat,0.95), col=2, lty=2 ) ;
  abline( v=max(dat), col=2, lty=3 ) ;
} ; # ende funktionsdef
# quantile irgendeines datensatzes

bilde_doppelexp_dichte <- function(x, m, c){ dexp( abs( (x-m)/c ) ) / (2*c) } ;
# funktion symmetrisiert exponentialverteilungen (fertig in R)
# zu doppelexponentialverteilungen

bilde_doppelexp_zv <- function(N, m, c){
  yy <- rexp( N, rate=1/c ) ;
  vz <- 2*( rbinom(N,1,0.5) - 0.5 ) ; # vorzeichen plus minus
  vz*yy + m*rep(1,N) ;
} ; # funktion erzeugt doppelexponentialverteilte zv
# mit lokationsparameter m und skalenparameter s

  # test
N <- 5000 ;
m <- 2.75 ;
c <- 1.33 ;
leg1 <- "histogramm von %%% doppelexponentialvert zv, lokationspar , skalenpar &&&" ;
leg1 <- gsub( "%%%", N, leg1 ) ;
leg1 <- gsub( "", round(m,2), leg1 ) ;
leg1 <- gsub( "&&&", round(c,2), leg1 ) ;

zv1 <- bilde_doppelexp_zv( N, m, c ) ;
hist( zv1, probability=T, nclass=150, col=8, ylim=c( 0, 1.1/(2*c) ), main=leg1 ) ;

xx1 <- seq( min(zv1)-1, max(zv1)+1, length.out=1000 ) ;
yy1 <- bilde_doppelexp_dichte( xx1, m, c ) ;
lines( xx1, yy1, col=2, lwd=2, lty=6 ) ;
meine_quantile( zv1 ) ;

```

```

#####
#
# unterschied zwischen doppexponeponentialverteilung und
# normalverteilung mit denselben parametern
#
#####

normalquantile <- function(m,c) {
  abline( v=m-3*c, col=6, lty=3 ) ;
  abline( v=qnorm(0.025,m,c), col=6, lty=4 ) ;
  abline( v=qnorm(0.05,m,c), col=6, lty=2 ) ;
  abline( v=qnorm(0.1,m,c), col=6, lty=6 ) ;
  abline( v=qnorm(0.9,m,c), col=6, lty=6 ) ;
  abline( v=qnorm(0.95,m,c), col=6, lty=2 ) ;
  abline( v=qnorm(0.975,m,c), col=6, lty=4 ) ;
  abline( v=m+3*c, col=6, lty=3 ) ;
} ; # ende funktionsdef

par( mfrow=c(2,1) ) ;
#
hist( zv1, probability=T, nclass=150, col=8, ylim=c( 0, 1.1/(2*c) ), main=leg1 ) ;
lines( xx1, yy1, col=2, lwd=2, lty=6, xlab="", ylab="" ) ;
meine_quantile( zv1 ) ;
#
yy2 <- dnorm( xx1, m, c ) ;
plot( range(zv1), range(yy2), type="n", xlab="", ylab="" ) ;
lines( xx1, yy2, col=6, lwd=2, lty=2 ) ;
normalquantile(m,c) ;
#
par( mfrow=c(1,1) ) ;

# gestalt deutlich anders als fuer eine normalverteilung
# mit denselben lokations- und skalenparametern
# ganz besonders in den tails

#####
#
# definiere drei verschiedene schaetzer fuer das paar
# (m,c) = (lokationsparameter, skalenparameter )
#
#####

# schaetzer (Mi,Ci) fuer das paar (m,c) , die dieselben
# skalierungseigenschaften wie ( emp mw, sqrt(emp var) ) besitzen
# und daher zur festlegung von konfidenzintervallen
# zu vorgegebenem konfidenzkoeffizient benutzt werden koennen

# lokationsparameter
M1 <- function(daten) median(daten) ;
# median
M2 <- function(daten) median(daten) ;
# median
M3 <- function(daten) mean(daten) ;
# empirischer mittelwert

# skalenparameter
C1 <- function(daten) mean( abs( daten - M1(daten) ) ) ;
# MLE im doppexponeponentialverteilungsmodell
C2 <- function(daten) M1( abs( daten - median(daten) ) ) ;
# komplett nichtparametrischer schaetzer : medianabstand
C3 <- function(daten) sqrt(var(daten)) ;
# empirische varianz

```

```

#####
# testdatensatz
#####
#####

testdat <- c(
  6.0490067, 20.0324319, 8.0917892, 5.3001702, 8.4231110, 8.4178589,
  7.9412088, 6.0004114, 7.6231672, 3.2640157, 7.9500893, 7.1471330,
  -3.7385962, 13.1849629, 15.3080767, 6.6531491, 9.1205368, 0.9610968,
  4.9916255, 11.5371074, 3.1072696, 5.7450847, 5.0906057, 9.5253568,
  4.7945269, 4.0560317, 10.1374325
) ; # der datensatz aus aufgabe 3.1 d)

# MLE im doppelexponentialverteilungsmodell
c( M1(testdat), C1(testdat) ) ;
# [1] 7.147133 3.148842

# komplett nichtparametrischer schaetzer : median und medianabstand
c( M2(testdat), C2(testdat) ) ;
# [1] 7.147133 2.056527

# emp mw und emp var fuer L^2-lokationsmodelle
c( M3(testdat), C3(testdat) ) ;
# [1] 7.285728 4.524473

# ein 'wahrer wert' ist fuer den testdatensatz natuerlich unbekannt
hist( testdat, breaks=seq(min(testdat)-5,max(testdat)+5,length.out=15), prob=T ) ;
xx3 <- seq( min(testdat), max(testdat), length.out=1000 ) ;
lines( xx3, bilde_doppelexp_dichte( xx3, M1(testdat), C1(testdat) ) ) ;
# der testdatensatz passt also zumindest ungefaehr
# zu einer doppelexponentialverteilung

#####
# lokations- und skalenexperiment
# erzeugt von der doppelexponentialverteilung
#
# empirische verteilungen fuer die statistiken
# r_n, v_n, w_n aus aufgabe 3.3 b)
#
# analog zu t-verteilungen im normalverteilungsmodell
# werden diese gebaut aus 'richtig skalierenden' schaetzern
# fuer lokations- und skalenparameter
#
#####

# empirische verteilung von T1 := v_n
# benutzt komponenten des MLE im doppelexponentialverteilungsmodell
emp_law_T1 <- function(n,N){
  hilf <- 1:N ; # startwerte zum ueberschreiben
  for ( i in 1:N ) {
    dat <- bilde_doppelexp_zv( n, 0, 1 ) ;
    hilf[i] <- sqrt(n) * M1(dat) / C1(dat) ;
  } ; # ende der i schleife
  hilf ; } ; # ende funktionsdef, argumente sind
# n = stichprobenlaenge des anvisierten datensatzes
# N = zahl der simulationslaeufe zur simulation der verteilung

N <- 10000 ;
n <- length(testdat) ; n ;
hilf1 <- emp_law_T1(n,N) ;
summary( hilf1 ) ;
leg1 <- "empirische verteilung der statistik T1 := v_n im doppelexp.vert.modell" ;
hist( hilf1, prob=T, nclass=0.02*N, main=leg1, xlab="", ylab="" ) ;

```

```

# empirische Verteilung von T2 := r_n
# komplett nichtparametrisch, benutzt
# median und Medianabstand
emp_law_T2 <- function(n, N){
  hilf <- 1:N; # Startwerte zum ueberschreiben
  for ( i in 1:N ) {
    dat <- bilde_doppelexp_zv( n, 0, 1 );
    hilf[i] <- sqrt(n) * M2(dat) / C2(dat);
  } # Ende der i Schleife
  hilf; } # Ende funktionsdef, Argumente sind
# n = Stichprobenlaenge des anvisierten Datensatzes
# N = Zahl der Simulationslaeufe zur Simulation der Verteilung

hilf2 <- emp_law_T2(n, N);
summary(hilf2);
leg2 <- "Empirische Verteilung der Statistik T2 := r_n im doppelexp.vert.modell";
hist(hilf2, prob=T, nclass=0.02*N, main=leg2, xlab="", ylab "");

# empirische Verteilung von T3 := w_n
# benutzt MW und Standardabweichung
emp_law_T3 <- function(n, N){
  hilf <- 1:N; # Startwerte zum ueberschreiben
  for ( i in 1:N ) {
    dat <- bilde_doppelexp_zv( n, 0, 1 );
    hilf[i] <- sqrt(n) * M3(dat) / C3(dat);
  } # Ende der i Schleife
  hilf; } # Ende funktionsdef, Argumente sind
# n = Stichprobenlaenge des anvisierten Datensatzes
# N = Zahl der Simulationslaeufe zur Simulation der Verteilung

hilf3 <- emp_law_T3(n, N);
summary(hilf3);
leg3 <- "Empirische Verteilung der Statistik T3 := w_n im doppelexp.vert.modell";
hist(hilf3, prob=T, nclass=0.02*N, main=leg3, xlab="", ylab "");

# Modell kommt von der Doppelexpontentialverteilung
# also ist das keine t Verteilung
# aber ist trotzdem nahe daran
x2 <- seq(-5, 5, 0.001);
y2 <- dt(x2, n-1);
lines(x2, y2, col=6);

#####
#
# Vergleich der Verteilungen r_n, v_n, w_n
#
#####

leg1 <- "Verteilung von T1 = v_n fuer n= simuliert in N=%%% laeufen im doppelexp.vert.-loc+scale-modell \n v_n gebildet aus Komponenten des MLE im Doppelexpontialverteilungs-loc+scal-modell";
leg1 <- gsub("", n, leg1);
leg1 <- gsub("%%%", N, leg1); leg1;

leg2 <- "Verteilung von T2 = r_n fuer n= simuliert in N=%%% laeufen im doppelexp.vert.-loc+scal-modell \n r_n gebildet komplett nichtparametrisch aus Median und Medianabstand";
leg2 <- gsub("", n, leg2);
leg2 <- gsub("%%%", N, leg2); leg2;

leg3 <- "Verteilung von T3 = w_n fuer n= simuliert in N=%%% laeufen im

```

```

doppelexponentialverteilungs- loc+scal-modell \n w_n gebildet wie im normalverteilungsmodell aus
mittelwert und standardabweichung" ;
leg3 <- gsub( "", n, leg3 ) ;
leg3 <- gsub( "%%%%", N, leg3 ) ; leg3 ;

m <- min( c(hilf1,hilf2,hilf3) ) - 0.1 ; m ;
M <- max( c(hilf1,hilf2,hilf3) ) + 0.1 ; M ;
meinebreaks <- seq( round(m,2), round(M,2), 0.05 ) ;
par( mfrow=c(3,1) ) ;
hist( hilf1, prob=T, breaks=meinebreaks, xlim=c(m,M), main=leg1, xlab="", ylab="" ) ;
meine_quantile(hilf1) ;
hist( hilf2, prob=T, breaks=meinebreaks, xlim=c(m,M), main=leg2, xlab="", ylab="" ) ;
meine_quantile(hilf2) ;
hist( hilf3, prob=T, breaks=meinebreaks, xlim=c(m,M), main=leg3, xlab="", ylab="" ) ;
meine_quantile(hilf3) ;
par( mfrow=c(1,1) ) ;

#####
#
# konfidenzintervalle fuer den lokationsparameter
#
#####

# T1 = v_n gebildet aus komponenten des MLE
# im doppelexponentialverteilungsmodell
conf_int_T1 <- function(daten,beta){
  n <- length(daten) ;
  hilf <- emp_law_T1(n,10000) ;
  q_oen <- -quantile( hilf, (1-beta)/2 ) ;
  q_uen <- -quantile( hilf, 1-(1-beta)/2 ) ;
  M <- M1(daten) ;
  C <- C1(daten) ;
  c( M + q_uen*C/sqrt(n) , M + q_oen*C/sqrt(n) ) ;
} ; # ende funktionsdef und ausgabe konfidenzintervall
# zum konfidenzkoeffizienten beta
# fuer den datensatz daten

# T2 = r_n gebildet komplett nichtparametrisch
# aus median und medianabstand
conf_int_T2 <- function(daten,beta){
  n <- length(daten) ;
  hilf <- emp_law_T2(n,10000) ;
  q_oen <- -quantile( hilf, (1-beta)/2 ) ;
  q_uen <- -quantile( hilf, 1-(1-beta)/2 ) ;
  M <- M2(daten) ;
  C <- C2(daten) ;
  c( M + q_uen*C/sqrt(n) , M + q_oen*C/sqrt(n) ) ;
} ; # ende funktionsdef und ausgabe konfidenzintervall
# zum konfidenzkoeffizienten beta
# fuer den datensatz daten

# T3 = w_n gebildet mit mw und standardabweichung
# wie im Normalverteilungsmodell
conf_int_T3 <- function(daten,beta){
  n <- length(daten) ;
  hilf <- emp_law_T3(n,10000) ;
  q_oen <- -quantile( hilf, (1-beta)/2 ) ;
  q_uen <- -quantile( hilf, 1-(1-beta)/2 ) ;
  M <- M3(daten) ;
  C <- C3(daten) ;
  c( M + q_uen*C/sqrt(n) , M + q_oen*C/sqrt(n) ) ;
}

```

```

} ; # ende funktionsdef und ausgabe konfidenzintervall
# zum konfidenzkoeffizienten beta
# fuer den datensatz daten

#####
#
# anwendung auf den testdatensatz
#
#####

# boxplot zur darstellung des datensatzes
boxplot( testdat , range=0.5, col=5 ) ;
title( main = "testdatensatz" ) ;

# erinnerung: voreinstellungen in 'boxplot' :
abline( h = min(testdat), lty=2, col=4 ) ;
abline( h = max(testdat), lty=2, col=4 ) ;
abline( h = median(testdat), lty=2, col=4 ) ;
abline( h = quantile(testdat,0.75), lty=2, col=4 ) ;
abline( h = quantile(testdat,0.25), lty=2, col=4 ) ;

beta <- 0.9 ;
leg1 <- "int aus komponenten des MLE" ;
leg2 <- "int aus median und medianabstand" ;
leg3 <- "int aus mw und standardabweichung" ;
xx <- rep(0,2) ;
zz1 <- conf_int_T1( testdat, beta ) ; zz1 ;
zz2 <- conf_int_T2( testdat, beta ) ; zz2 ;
zz3 <- conf_int_T3( testdat, beta ) ; zz3 ;

par( mfrow=c(1, 4) ) ;
#
boxplot( testdat , range=0.5, col=5 ) ;
title( main = "testdatensatz" ) ;
#
plot( range(xx), range(testdat), type="n", xlab="", ylab="", main=leg1 ) ;
lines( xx, zz1, lwd=4, col=6 ) ;
abline( h=zz1[1], lty=2, col=6 ) ;
abline( h=zz1[2], lty=2, col=6 ) ;
#
plot( range(xx), range(testdat), type="n", xlab="", ylab="", main=leg2 ) ;
lines( xx, zz2, lwd=4, col=6 ) ;
abline( h=zz2[1], lty=2, col=6 ) ;
abline( h=zz2[2], lty=2, col=6 ) ;
#
plot( range(xx), range(testdat), type="n", xlab="", ylab="", main=leg3 ) ;
lines( xx, zz3, lwd=4, col=6 ) ;
abline( h=zz3[1], lty=2, col=6 ) ;
abline( h=zz3[2], lty=2, col=6 ) ;
#
par( mfrow=c(1,1) ) ;

#####
#
# ende aufgabe 3.1
# 21.06.19
#
#####

```