

```
#####  
#  
# Reinhard Hoepfner  
#  
# Praktikum zur 'Grundlagen der Stochastik'  
#  
# Empirische Verteilungsfunktionen  
#  
# normalverteilte ZV -- Konvergenz der emp VF  
#  
# 05.11.18  
#  
#####
```

```
#####  
#  
# empirische verteilungsfunktionen vorgefertigt in R  
#  
#####
```

```
# siehe : help(ecdf) ;  
# siehe : help(rnorm) ; help(dnorm) ; help(pnorm) ;
```

```
# erzeugen von daten  
daten <- rnorm( 10000, 0, 1 ) ;  
# siehe : help(rnorm)
```

```
# ansehen mit  
yleg <- "N(0,1) hat 99.7 prozent der masse in (-3,3)" ;  
leg <- "meine daten : 10000 iid standardnormalverteilte zufallszahlen" ;  
plot( c(1,length(daten)), c( -4.5, 4.5 ), type="n",  
      ylab=yleg, xlab="", main=leg ) ;  
points( 1:length(daten), daten, col=2, pch=18, cex=0.5 ) ;  
abline( h=-3, lty=2, col=3 ) ;  
abline( h=3, lty=2, col=3 ) ;
```

```
# bereite vor : verteilungsfunktion standardnormalverteilung  
xstep <- 0.01 ;  
x <- seq( -5, 5, xstep ) ;  
y <- pnorm( x, 0, 1 ) ;  
plot( x, y, type="l", lwd=2, col=4, ylab="", xlab=yleg,  
      main="verteilungsfunktion standardnormalverteilung" ) ;  
abline( v=-3, lty=2, col=3 ) ;  
abline( v=3, lty=2, col=3 ) ;  
# siehe help(pnorm) ;
```

```
# vorgefertigt in R existiert 'ecdf'  
# die empirische verteilungsfunktion in R,  
# nichts anderes als die aufsteigend geordneten beobachtungen  
# kombiniert mit einem programm zum zeichnen einer sprungfunktion  
# mit werten in ]0,1] und fertig definierten sprunghoehen
```

```
plot( ecdf(daten[1:50]) );  
# lines(x, y, col=4) ;
```

```
plot( ecdf(daten[1:500]) );  
# lines(x, y, col=4) ;
```

```
# man kann die dicken punkte wegnehmen  
# (automatisch bei hinreichend vielen daten)  
plot( ecdf(daten[1:500]), pch="" );  
# plot( ecdf(daten[1:5000]), pch="" );
```

```
# man kann die vertikalen einzeichnen lassen oder nicht  
plot( ecdf(daten[1:50]), pch="", verticals=T,  
      main="individualisierter titel", xlab="", ylab="" );
```

```
plot( ecdf(daten[1:50]), pch="", verticals=F,  
      main="individualisierter titel", xlab="", ylab="" );
```

```
# ecdf ruft selber wieder ein programm stepfun  
# zum zeichnen einer sprungfunktion auf  
# siehe : help(stepfun) ;  
plot( ecdf(daten[1:50]) );  
# macht dasselbe wie  
plot.stepfun( daten[1:50], pch=19, verticals=F ) ;  
abline( h=0, lty=2, col=8 ) ;  
abline( h=1, lty=2, col=8 ) ;  
# programm zum zeichnen einer sprungfunktion  
lines(x, y, col=4) ;
```

```
#####  
#  
# aehnliches haette man auch selbst schreiben koennen  
#  
#####
```

```
N <- 25 ;  
xx <- sort(daten[1:N]) ;  
# aufsteigende anordnung der daten  
yy <- seq( 1/N, 1, 1/N ) ;  
plot( range(daten), c(0,1), type="n",  
      main="empirische verteilungsfunktion" ) ;  
lines( xx, yy, type="s" ) ; # sprungfunktion
```

```

points( xx, yy, pch=19 ) ; # punkte dazu
lines(x, y, col=4) ;
# unschoen : es fehlt das rechte und das linke ende

# nehme zwei kuenstliche punkte weit aussen dazu
# um die emp vf 'weit links' auf 0
# und 'weit rechts' auf 1 zu setzen

xx1 <- c( min(xx)-10, xx, max(xx)+10 ) ;
yy1 <- c( 0, yy, 1 ) ;
plot( range(daten), c(0,1), type="n", xlab="",
      ylab="", main="empirische verteilungsfunktion") ;
lines( xx1, yy1, type="s") ; # sprungfunktion
points( xx1, yy1, pch=19, cex=0.7 ) ; # die punkte dazu
lines(x, y, col=4) ; # die normaldichte zum vergleich

```

```

#####
#
#   'der zufall und sein gesetz' fuer emprische verteilungsfunktionen :
#
#   fuer grosse zahl von beobachtungen
#   sieht man das dem zufall zugrundeliegende gesetz
#   immer deutlicher, aber nie ganz
#
#   empirische verteilungsfunktionen fuer die
#   ersten N daten, konvergenz N -> \infty
#
#####

```

```

# daten <- rnorm( 10000, 0, 1 ) ;

par( mfrow=c(2,2) ) ;
n_list <- c( 25, 100, 500, 5000 ) ;

for( n in n_list ) {
  xleg <- "nach den &&&& beobachtungen" ;
  xleg <- gsub( "&&&&", n , xleg ) ;
  plot( ecdf(daten[1:n]), xlab=xleg,
        ylab="", main="", pch="", verticals=T ) ;
  lines(x, y, col=4) ;
} ;

par( mfrow=c(1,1) ) ;
title("normalverteilte zufallszahlen: konvergenz der empirischen verteilungsfunktionen \n") ;

```

```
#####
#
# datenabhaengig kann in der letzten graphik die skalierung
# der x-achse in jeder teilgraphik anders ausfallen
#
# hier eine langsamere aber individuellere variante
#
#####
```

```
relhf <- function(daten,x){
  round( length( daten[ daten<=x ] )/length(daten) , 5 ) ;
} ; # funktion berechnet die relative haeufigkeit
# von beobachtungen kleiner oder gleich x
# im datensatz daten

# daten <- rnorm( 10000, 0, 1 ) ;

c( relhf(daten,-3) , 1-relhf(daten,3) , relhf(daten,-3)+1-relhf(daten,3) ) ;
```

```
maleempdf <- function( daten, n, xmin, xmax, xfeinheit ){
  n <- min( n, length(daten) ) ;
  dat <- daten[1:n] ;
  x <- seq( xmin, xmax, xfeinheit ) ;
  y <- x ; # startwert zum ueberschreiben
  for( i in 1:length(y) ) y[i] <- relhf(dat,x[i]) ;
  leg <- "nach den ersten beobachtungen" ;
  leg <- gsub( "", n, leg ) ;
  plot( c(xmin,xmax), c(0,1), type="n", xlab=leg, ylab="" ) ;
  lines( x , y, type="s", col=2 ) ; # funktion wird als sprungfunktion rot gemalt
  title(main="empirische verteilungsfunktion") ;
} ; # funktion berechnet die empirische verteilungsfunktion
# zu den ersten N beobachtungen im datensatz daten und malt sie
# auf das interval (xmin,xmax) mit schrittweite xfeinheit
```

```
maleempdf( daten, 50, -5, 5, 0.001 ) ;
```

```
# daten <- rnorm( 10000, 0, 1 ) ;
```

```
par( mfrow=c(2,2) ) ;
n_list <- c( 25, 100, 500, 5000 ) ;
```

```
for( n in n_list ) {
  maleempdf( daten, n, -5, 5, 0.001 ) ;
  lines(x, y, col=4) ;
} ;
par( mfrow=c(1,1) ) ;
```

```
##### 05.11.18
#####
```

