

(5) Einstichproben-T²-Tests

Ziel dieses Seminar ist es, sich anhand einer Simulation der Verteilung der Einstichproben-T²-Teststatistik sich erneut der Grundlagen Frequentistischer Inferenz zu besinnen und anschließend einen T²-Test in einem Anwendungsbeispielszenario durchzuführen.

Simulation der Verteilung der Einstichproben-T²-Teststatistik

Folgender **R** Code implementiert eine Simulation der Verteilung der Einstichproben-T²-Teststatistik auf Grundlage des wiederholten identischen und unabhängigen Realisierens von multivariat normalverteilten zweidimensionalen Zufallsvariablen.

```
# Modellparameter
m = 2 # Dimensionalität
n = 15 # Anzahl der Datenpunkte
mu_0 = matrix(c(1,1), nrow = 2) # H0 Hypothesenparameter
mu = matrix(c(2,2), nrow = 2) # w.a.u. Erwartungswertparameter
Sigma = matrix(c(0.5,0.3, 0.3,0.5), nrow = 2, byrow = TRUE) # w.a.u. Kovarianzmatrixparameter

# Simulation
library(MASS) # Multivariate Normalverteilungen
nsim = 1e4 # Anzahl Datensatzrealisierungen
Yb = matrix(rep(NaN,m*nsim), nrow = 2) # Stichprobenmittelarray
T2 = rep(NaN,nsim) # T2 Statistik Array
j_n = matrix(rep(1,n), nrow = n) # 1_n
I_n = diag(n) # I_n
J_n = matrix(rep(1,n^2), nrow = n) # 1_{nn}
for(s in 1:nsim){ # Simulationsiterationen
  Y = t(mvrnorm(n,mu,Sigma)) # \ups_i \sim N(\mu, \Sigma)
  Y_bar = (1/n)*(Y %*% j_n) # Stichprobenmittel
  C = (1/(n-1))*(Y %*% (I_n-(1/n)*J_n) %*% t(Y)) # Stichprobenkovarianzmatrix
  T2[s] = n*t(Y_bar - mu_0) %*% solve(C) %*% (Y_bar - mu_0) # T2 Statistik
  Yb[,s] = Y_bar # Stichprobenmittelarray
}
```

Mit folgenden **R** Code wird obige Simulation in [Abbildung 1](#) visualisiert.

```
# Abbildungsparameter
library(latex2exp)
pdf(
  file = "../5_Abbildungen_S/mv_5_einstichproben_t2_teststatistik.pdf",
  width = 6,
  height = 6)
par(
  family = "sans",
  mfcol = c(2,2),
  pty = "s",
  bty = "n",
  lwd = 1,
  las = 1,
  mgp = c(2,1,0),
  xaxs = "i",
  yaxs = "i",
  font.main = 1,
  cex.main = 1)

# Stichprobenmittel per Simulation
plot(
  Yb[1,],
  Yb[2,],
  xlim = c(1,3),
  ylim = c(1,3),
  xlab = TeX("$\\bar{\\upsilon}_1$"),
  ylab = TeX("$\\bar{\\upsilon}_2$"),
  pch = 21,
  col = "white",
  bg = "gray60",
```

```

main      = TeX("\bar{\upsilon}$ Simulationen")

# Normalisierte T2-Teststatistik WDF
t2_min    = 0
t2_max    = 200
t2_res    = 1e3
t2        = seq(t2_min,t2_max,len = t2_res)
nu        = (n-m)/(m*(n-1))
delta     = n*t(mu - mu_0) %*% solve(Sigma) %*% (mu - mu_0)
p_T2      = nu*df(nu*t2,m,n-m,delta)
hist(
  T2,
  breaks  = 100,
  col     = "gray90",
  prob    = TRUE,
  xlim    = c(t2_min, t2_max),
  ylim    = c(0,0.03),
  xlab    = TeX("$t^2$"),
  ylab    = "",
  main    = TeX("$p(t^2) := \nu f(\nu t^2; \delta, m, n-m)$")
  fdir    = file.path(getwd(), "8_Abbildungen")
  lines(
    t2,
    p_T2,
    lwd    = 2,
    col    = "darkorange")

# Unnormalisierte T2-Teststatistik WDF
t2_min    = 0
t2_max    = 50
t2_res    = 1e3
t2        = seq(t2_min,t2_max,len = t2_res)
delta     = n*t(mu-mu_0) %*% solve(Sigma) %*%(mu-mu_0)
p_nm_T2   = df(t2,m,n-m,delta)
hist(
  ((n-m)/m)/(n-1)*T2,
  breaks  = 100,
  col     = "gray90",
  prob    = TRUE,
  xlim    = c(t2_min, t2_max),
  ylim    = c(0,0.06),
  xlab    = TeX("$\nu t^2$"),
  ylab    = "",
  main    = TeX("$\nu T^2 \sim f(\delta, m, n-m)$") )
  lines(
    t2,
    p_nm_T2,
    lwd    = 2,
    col    = "darkorange")

# Normalisierte T2-Teststatistik KVF
t2_min    = 0
t2_max    = 200
t2_res    = 1e3
t2        = seq(t2_min,t2_max,len = t2_res)
nu        = (n-m)/(m*(n-1))
P_T2      = pf(nu*t2,m,n-m,delta)
ECDF_T2   = ecdf(T2)
plot(
  ECDF_T2,
  verticals = TRUE,
  lwd       = 6,
  xlim     = c(t2_min, t2_max),
  col      = "gray90",
  xlab     = TeX("$t^2$"),
  ylab     = "",
  main     = TeX("$P(t^2) := F(\nu t^2; \delta, m, n-m)$")
  lines(
    t2,
    P_T2,
    lwd     = 2,
    col     = "darkorange")
dev.off()

```




Abbildung 1. Simulation der Frequentistischen Verteilung der T^2 -Teststatistik

Anwendungsbeispiel

Als Anwendungsbeispiel betrachten wir die Frage nach der mit der Abweichung eines zweidimensionalen Gruppenmittelwertes assoziierten Unsicherheit von einem Therapieerfolgsnormwert $\mu_0 = (30, 3.5)$ anhand der in Tabelle 1 dargestellten Daten.

Tabelle 1. Pre-Post-Interventions-Differenzwerte von BDI Scores und Glukokortikoidplasmaleveln von $n = 20$ Patient:innen

dBDI	dGlu
35	6.1
25	4.0
20	1.7
29	2.6
29	1.9
17	0.9
33	2.0
28	4.1
26	3.9
31	3.8
14	2.1
18	2.0
19	5.0
28	2.6
20	2.1
35	4.4
28	4.0
32	3.9
32	1.0
25	1.9

Mithilfe folgenden **R** Codes berechnen wir zunächst das Stichprobenmittel, die Stichprobenkovarianzmatrix und Mahalanobis Distanz des Stichprobenmittels vom Normwert.

```
# Deskriptivstatistik
D = read.csv("5_Einstichproben_T2_Tests_S.csv")
Y = rbind(D$y_1i, D$y_2i)
mu_0 = matrix(c(30,3.5), nrow = 2)
n = ncol(Y)
j_n = matrix(rep(1,n), nrow = n)
I_n = diag(n)
J_n = matrix(rep(1,n^2), nrow = n)
Y_bar = (1/n)*(Y %*% j_n)
C = (1/(n-1))*(Y %*% (I_n-(1/n)*J_n) %*% t(Y))
D = t(Y_bar - mu_0) %*% solve(C) %*% (Y_bar - mu_0)
cat("Y_bar =", Y_bar, "\nD      =", D)

# Dateneinlesen
# Datenmatrix
# Normwert
# Anzahl Datenpunkte
# i_n
# I_n
# 1_{nn}
# Stichprobenmittel
# Stichprobenkovarianzmatrix
# Mahalanobis Distanz
# Ausgabe
```

```
Y_bar = 26.25615 2.991039
D      = 0.3773184
```

Mithilfe folgenden **R** Codes visualisieren wir den Datensatz wie in Abbildung 2 gezeigt.

```
# Visualisierungsparameter
library(ellipse)
library(latex2exp)
pdf(
  file      = "../5_Abbildungen_S/mv_5_einstichproben_t2_deskription.pdf",
  width     = 4.5,
  height    = 4.5)
par(
  family    = "sans",
  mfcol     = c(1,1),
  pty       = "s",
  bty       = "l",
  lwd       = 1,
  las       = 1,
  mgp       = c(2,1,0),
  xaxs      = "i",
  yaxs      = "i",
  font.main = 1,
  cex       = 1,
  cex.main  = 1)

# Gruppe 1
plot(
  Y[1,],
  Y[2,],
  col = "Gray70",
  bg  = "Gray70",
  pch = 21,
  xlab = TeX("dBDI"),
  ylab = TeX("dGLU"),
  xlim = c(10,40),
  ylim = c(0,7))
points(
  Y_bar[1],
  Y_bar[2],
  col = "White",
  bg  = "gray70",
  pch = 24)
lines(
  ellipse(C, level = 0.40, centre = Y_bar),
  type = "l",
  col = "Gray70")

# Normwert
points(
  mu_0[1],
  mu_0[2],
  col = "White",
  bg  = "Gray30",
  pch = 24)

# Legende
legend(
  "topleft",
  c("Datenpunkte", "Stichprobenmittel", "Stichprobenkovarianz", "Normwert"),
  lty = c(NA,NA,1,NA),
  pch = c(19,17,NA,17),
  col = c("gray70","gray70","gray70","gray30"),
  bty = "n",
  cex = .8)
dev.off()
```




Abbildung 2. Deskriptivstatistik des Beispieldatensatzes

Mit folgendem **R** Code führen wir schließlich einen Einstichproben- T^2 -Test mit Signifikanzlevel $\alpha_0 = 0.05$ durch.

```
# Datenbereitstellung
D = read.csv("5_Einstichproben_T2_Tests_S.csv") # Datensatzeinlesen
Y = rbind(D$y_1i, D$y_2i) # Datenselektion

# Testparameter
m = nrow(Y) # Dimensionalität der Zufallsvektoren/Daten
n = ncol(Y) # Anzahl der Datenpunkte
nu = (n-m)/(m*(n-1)) # Parameter
mu_0 = matrix(c(30,3.5), nrow = 2) # H0 Hypothesenparameter ("Normwert")
alpha_0 = 0.05 # Signifikanzlevel
k_alpha_0 = (1/nu)*qf(1-alpha_0,m,n-m) # kritischer Wert

# Testevaluation
j_n = matrix(rep(1,n), nrow = n) # 1_n
I_n = diag(n) # I_n
J_n = matrix(rep(1,n^2), nrow = n) # 1_{nn}
Y_bar = (1/n)*Y %>% j_n # Stichprobenmittel
C = (1/(n-1))*Y %>% (I_n-(1/n)*J_n) %>% t(Y) # Stichprobenkovarianzmatrix
T2 = n*t(Y_bar - mu_0) %>% solve(C) %>% (Y_bar - mu_0) # T^2 Statistik
if(T2 > k_alpha_0){ # Test 1_{T^2 >= k_alpha_0}
  phi = 1 # Ablehnen von H_0
} else {
  phi = 0 # Nicht Ablehnen von H_0
}
p = 1 - pf(nu*T2,m,n-m) # p-Wert

# Ausgabe
cat("Y_bar = ", Y_bar,
    "\nC = ", C,
    "\nT^2 = ", T2,
    "\nalpha_0 = ", alpha_0,
    "\nk = ", k_alpha_0,
    "\nphi = ", phi,
    "\np = ", p)
```

```
Y_bar = 26.25615 2.991039
C = 38.8981 3.549813 3.549813 1.972143
T^2 = 7.546368
alpha_0 = 0.05
k = 7.504065
phi = 1
p = 0.04928746
```

Im vorliegenden Fall würden wir also die Nullhypothese eines wahren, aber unbekanntem Erwartungswertparameters der Datenverteilung ablehnen.

Zuletzt führen wir den gleichen Einstichproben- T^2 -Test noch einmal mithilfe des R Pakets `MVTests`, speziell der Funktion `MVTests::OneSampleHT2()` im Sinne eines Black-Box-Verfahrens durch.

```
# Datenbereitstellung
D = read.csv("5_Einstichproben_T2_Tests_S.csv") # Datensatzeinlesen
Y = rbind(D$y_1i, D$y_2i) # Datenselektion
library(MVTests) # R Pakete
phi = OneSampleHT2(t(Y), mu_0, alpha_0) # Einstichproben-T^2-Test
cat("Y_bar = ", phi$Descriptive[2,], # Ausgabe
    "\nT^2 = ", phi$HT2,
    "\nalpha_0 = ", phi$alpha,
    "\np = ", phi$p.value)
```

```
Y_bar = 26.25615 2.991039
T^2 = 7.546368
alpha_0 = 0.05
p = 0.04928746
```