

# Vícerozměrné metody - cvičení



RNDr. Eva Koriťáková, Ph.D.


# Cvičení 2

## Vícerozměrné normální rozdělení a vícerozměrný t-test


# Vícerozměrné normální rozdělení

# Motivace

Histogram




Hustota jednorozměrného normálního rozdělení




# Motivace – pokračování

Dvourozměrný  
histogram



Hustota dvourozměrného  
normálního rozdělení



# Vícerozměrné normální rozdělení

**Hustota jednozměrného normálního rozdělení:**

$$f(x) = \frac{1}{\sqrt{(2\pi)\sigma^2}} \cdot \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

$\mu$  - střední hodnota       $\sigma^2$  - rozptyl

**Hustota vícerozměrného normálního rozdělení:**

$$f(x_1, \dots, x_k) = \frac{1}{\sqrt{(2\pi)^k |\Sigma|}} \cdot \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$

$\boldsymbol{\mu}$  - vektor středních hodnot       $\boldsymbol{\Sigma}$  - kovarianční matice

**Hustota dvourozměrného normálního rozdělení:**



$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[ \frac{(x - \mu_x)^2}{\sigma_x^2} + \frac{(y - \mu_y)^2}{\sigma_y^2} - \frac{2\rho(x - \mu_x)(y - \mu_y)}{\sigma_x\sigma_y} \right]\right),$$

$$\boldsymbol{\mu} = \begin{pmatrix} \mu_x \\ \mu_y \end{pmatrix}, \quad \boldsymbol{\Sigma} = \begin{pmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_x\sigma_y & \sigma_y^2 \end{pmatrix}$$



$\rho$  - korelace mezi X a Y;  
 $\sigma$  - směrodatná odchylka

# Hustota u nekorelovaných a korelovaných proměnných

Nekorelované proměnné  
( $\mu_1 = \mu_2 = 0$ ,  $\sigma_1 = \sigma_2 = 1$ ,  
 $\rho = 0$ )



Korelované proměnné  
( $\mu_1 = \mu_2 = 0$ ,  $\sigma_1 = \sigma_2 = 1$ ,  
 $\rho = 0,5$ )



# Vícerozměrný průměr a kovarianční matice

- vícerozměrný průměr (např. pro datový soubor se 2 proměnnými):

$$\bar{\mathbf{x}} = \left[ \frac{1}{n} \sum_{i=1}^n x_{i1} \quad \frac{1}{n} \sum_{i=1}^n x_{i2} \right]$$


- výběrová kovarianční matice (např. pro datový soubor se 2 proměnnými):

$$\mathbf{S} = \begin{bmatrix} s_{11} & s_{12} \\ s_{21} & s_{22} \end{bmatrix}, \text{ kde } s_{11} = \frac{1}{n-1} \sum_{i=1}^n (x_{i1} - \bar{x}_1)^2$$



# Výpočet rozptylu a směrodatné odchylky - opakování

- Příklad čtverců odchylek od průměru pro  $n = 3$ .
- Rozptyl je možno značně ovlivnit odlehlými pozorováními.



Rozptyl:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

Směrodatná odchylka:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$


# Úkol 1

- Spočtete vícerozměrný průměr a výběrovou kovarianční matici pro soubor 3 subjektů, u nichž byly naměřeny hodnoty objemu hipokampu a mozkových komor, přičemž naměřené hodnoty byly zaznamenány do následující datové matice:

$$\mathbf{X} = \begin{bmatrix} 2 & 12 \\ 4 & 10 \\ 3 & 8 \end{bmatrix}$$

# Úkol 1 - řešení

ID	Objem hipokampu	Objem mozkových komor
1	2	12
2	4	10
3	3	8



Vícerozměrný průměr:

$$\bar{\mathbf{x}} = \left[ \frac{1}{n} \sum_{i=1}^n x_{i1} \quad \frac{1}{n} \sum_{i=1}^n x_{i2} \right] = \left[ \frac{1}{3} (2 + 4 + 3) \quad \frac{1}{3} (12 + 10 + 8) \right] = [3 \quad 10]$$

Kovarianční matice:  $\mathbf{S} = \begin{bmatrix} s_{11} & s_{12} \\ s_{21} & s_{22} \end{bmatrix}$ , kde:

$$s_{11} = \frac{1}{n-1} \sum_{i=1}^n (x_{i1} - \bar{x}_1)^2 = \frac{1}{3-1} ((2-3)^2 + (4-3)^2 + (3-3)^2) = \frac{1}{2} (1 + 1 + 0) = 1$$

$$s_{22} = \frac{1}{n-1} \sum_{i=1}^n (x_{i2} - \bar{x}_2)^2 = \frac{1}{3-1} ((12-10)^2 + (10-10)^2 + (8-10)^2) = 4$$

$$s_{21} = s_{12} = \frac{1}{n-1} \sum_{i=1}^n (x_{i1} - \bar{x}_1)(x_{i2} - \bar{x}_2) = \frac{1}{3-1} ((2-3)(12-10) + (4-3)(10-10) + (3-3)(8-10)) = -1 \rightarrow \mathbf{S} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$


# Úkol 1 - doplnění

Kovarianční matice:  $\mathbf{S} = \begin{bmatrix} s_{11} & s_{12} \\ s_{21} & s_{22} \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$



Korelační matice:  $\mathbf{R} = \begin{bmatrix} r_{11} & r_{12} \\ r_{21} & r_{22} \end{bmatrix} = \begin{bmatrix} 1 & -0,5 \\ -0,5 & 1 \end{bmatrix}$

$$r_{12} = r_{21} = \frac{s_{12}}{\sqrt{s_{11}} \cdot \sqrt{s_{22}}} = \frac{-1}{\sqrt{1} \cdot \sqrt{4}} = -0,5$$


# Je normalita v jednorozměrném prostoru jedinou podmínkou vícerozměrné normality?





+




# Je normalita v jednorozměrném prostoru jedinou podmínkou vícerozměrné normality?





+



# Je normalita v jednorozměrném prostoru jedinou podmínkou vícerozměrné normality?




+



Vícerozměrná odlehlá hodnota (outlier)

# Ověření dvourozměrné normality

Bagplot = „bivariate boxplot“ (tzn. „dvourozměrný krabicový graf“)




v softwaru Statistica: Graphs – 2D Graphs – Bag Plots



# Ověření dvourozměrné normality


Vykreslení regulační elipsy („control“ ellipse):



v softwaru Statistica: Graphs – Scatterplots – na záložce Advanced zvolit Elipse Normal

# Normalizace dat

- Převod na normální rozdělení (normalita je předpokladem řady statistických testů).
- Např. **logaritmická transformace**:  $X = \ln(Y)$  nebo  $X = \ln(Y+1)$ , pokud data obsahují hodnotu 0



- Další příklady:
  - **odmocninová transf.** (pro proměnné s Poissonovým rozložením nebo obecně data typu počet jedinců, buněk apod.:  $X = \sqrt{Y}$  nebo  $X = \sqrt{Y + 1}$ )
  - **arcsin transformace** (pro proměnné s binomickým rozložením)
  - **Box-Coxova transformace**



# Další typy transformací vícerozměrných dat

---

- standardizace dat
- min-max normalizace
- centrování dat
- odstranění vlivu kovariát na jiné proměnné


# Standardizace dat

- důvod: převod proměnných na stejné měřítko
- standardizace:  $z_i = \frac{x_i - \bar{x}}{s}$  (tzn. odečtení průměru od jednotlivých hodnot a podělení směrodatnou odchylkou)
- proměnné budou mít rozsah přibližně od -3 do 3
- získáme tím současně i tzv. z-skóre (které vyjadřuje, o kolik směrodatných odchylek se i-tá hodnota odchýlila od průměru)
- **pozor: standardizace je nevhodná v případě, když proměnné nemají normální rozdělení a když se v datech vyskytují odlehlé hodnoty!!!**





# Min-max normalizace

- důvod: převod proměnných na stejné měřítko
- oproti standardizaci vhodná i na proměnné nemající normální rozdělení či obsahující odlehlé hodnoty
- min-max normalizace:  $y_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}$
- rozsah hodnot proměnných po min-max normalizaci je od 0 do 1



# Centrování dat


- odečtení průměru od dat – získáme novou proměnnou, která bude mít průměr roven nule
- důvod: centrování je důležitou podmínkou některých pokročilých statistických metod (např. klasifikačních)
- centrování:  $z_i = x_i - \bar{x}$




# Odstranění vlivu kovariát (tzv. adjustace)

1. V prvním kroku definujeme regresní model vztahu kovariáty (např. věku) a dané proměnné
2. Pro každého pacienta je vypočteno jeho reziduum od regresní přímky  $\uparrow\downarrow$
3. Reziduum (představující hodnotu parametru po odečtení vlivu věku, jeho průměr je 0) je přičteno k průměrné hodnotě parametru  $\text{---}$
4. Výsledná adjustovaná hodnota má odečten vliv věku, ale zároveň není změněna číselná hodnota parametru

**Původní data**



**Adjustovaná data**



# Transformace dat pomocí softwaru SPSS I

- **Logaritmická transformace:**

Transform -> Compute Variable -> Target Variable: *název nové proměnné (např. vaha\_log)* -> Function group: Arithmetic -> Functions and Special Variables: *vybrat Ln a přetáhnout do okna Numeric Expression* -> *do argumentu funkce vložíme vybranou proměnnou (např. vaha)*

The screenshot shows the 'Compute Variable' dialog box in SPSS. The 'Target Variable' is 'Weight\_log'. The 'Numeric Expression' is 'LN(Weight)'. The 'Function group' is 'Arithmetic'. The 'Functions and Special Variables' list includes 'Ln'. The 'Weight' variable is selected in the variable list. A calculator keypad is visible in the center. A text box explains the 'LN' function: 'LN(numexpr). Numeric. Returns the base-e logarithm of numexpr, which must be numeric and greater than 0.' Arrows point to the 'Weight' variable, the 'LN' function, and the 'Weight' argument in the expression.

Název nové proměnné

Target Variable: Weight\_log

Numeric Expression: LN(Weight)

Function group: Arithmetic

Functions and Special Variables: Ln

Výběr proměnné, která má být transformována

„kalkulačka“

Výběr funkce z konkrétní skupiny funkcí

Popis vybrané funkce

if... (optional case selection condition)

OK Paste Reset Cancel Help



# Transformace dat pomocí softwaru SPSS II

- **Standardizace dat:**

Analyze -> Descriptive Statistics -> Descriptives -> Variables: *vybrat proměnnou* (např. vek) -> *zatrhnout* Save standardized values as variables -> OK

- **Min-max normalizace:**

Transform -> Compute Variable -> Target Variable: *zadat jméno nové proměnné* (např. vyska\_norm) -> Numeric Expression: *vybrat proměnnou, kterou chceme normalizovat, a dopsat vzoreček* (např.  $(vyska-155)/(197-155)$ )

- **Centrování dat:**

Transform -> Compute Variable -> Target Variable: *zadat jméno nové proměnné* (např. vyska\_centra) -> Numeric Expression: *vybrat proměnnou, kterou chceme centrovat, a přidat minus průměrná hodnota* (např.  $vyska - 172.24$ )

- **Odstranění vlivu kovariát:**

Analyze -> Regression -> Linear -> *zvolit proměnné* (např. cel\_cholesterol jako Dependent, vek... jako Independent(s)); *na záložce Save zaškrtnout při Residuals: Standardized nebo Unstandardized podle toho, co nám vyhovuje* -> Continue -> OK; *případně lze vytvořit novou proměnnou pomocí Compute Variable, která bude součtem RES\_1 a průměru původní proměnné*

# Transformace dat pomocí softwaru Statistica I

- **Logaritmická transformace:**

*Označit proměnnou za proměnnou, kterou chceme logaritmovat -> kliknout pravým tlačítkem myši -> Add Variables -> Name -> zadat název nové proměnné (např. vaha\_log) -> do Long name napsat =Log(vaha) (Pozor, v softwaru STATISTICA je přirozený logaritmus označen jako Log(x) místo Ln(x)!) -> OK*

- **Standardizace dat:**

*Označit proměnnou za proměnnou, kterou chceme standardizovat -> kliknout pravým tlačítkem myši -> Add Variables -> Name -> zadat název nové proměnné (např. vek\_st) -> do Long name napsat =vek -> OK -> Data -> Standardize... -> OK*

- **Min-max normalizace:**

*Označit proměnnou za proměnnou, kterou chceme centrovat -> kliknout pravým tlačítkem myši -> Add Variables -> Name -> zadat název nové proměnné (např. vyska\_cent) -> do Long name napsat  $= (vyska - 155) / (197 - 155)$  (minimum a maximum vypočítané pomocí Descriptive statistics) -> OK*

# Transformace dat pomocí softwaru Statistica II

- **Centrování dat:**

*Označit proměnnou za proměnnou, kterou chceme centrovat -> kliknout pravým tlačítkem myši -> Add Variables -> Name -> zadat název nové proměnné (např. vyska\_centr) -> do Long name napsat =vyska-172.24 (průměr vypočítaný pomocí Descriptive statistics) -> OK*



- **Odstranění vlivu kovariát:**

*Statistics -> Multiple Regression -> zvolit proměnné (např. cel\_cholesterol jako Dependent var., vek... jako Independent variables) -> OK -> OK -> na záložce Save kliknout na Save residuals & predicted -> zvolit proměnné, které bude nově vytvořená tabulka dále obsahovat -> OK  
(případně lze vytvořit novou proměnnou pomocí Add Variables, kde v Long name bude součet Residuals a průměru původní proměnné)*

# Vícerozměrný t-test

# Jednorozměrný dvouvýběrový t-test

- Srovnáváme dvě skupiny dat, které jsou na sobě nezávislé – mezi objekty neexistuje vazba.
- Příklady: srovnání objemu hipokampu u mužů a u žen, srovnání kognitivního výkonu podle dvou kategorií věku,...




- Předpoklad: **normalita dat v OBOU skupinách, shodnost (homogenita) rozptylů** v obou skupinách
- Testová statistika: 
$$t = \frac{\bar{x}_1 - \bar{x}_2 - c}{s_* \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$
, kde  $s_*$  je vážená směrodatná odchylka,

$c$  je konstanta, o kterou se rozdíl průměrů má lišit (většinou rovna 0)

# Vícerozměrný t-test

- Srovnáváme dvě skupiny dat, které jsou na sobě nezávislé – mezi objekty neexistuje vazba.
- Na rozdíl od jednorozměrného dvouvýběrového t-testu jsou dvě skupiny dat popsány více kvantitativními proměnnými.



# Vícerozměrný t-test

## Jednorozměrný dvouvýběrový t-test:

- testová statistika:  $T = \frac{(\bar{x}_D - \bar{x}_H) - c}{s_* \sqrt{\frac{1}{n_D} + \frac{1}{n_H}}}$ , kde  $T \sim t(n_D + n_H - 2)$  ← Studentovo rozdělení
- $s_*^2$  je vážený rozptyl vypočtený jako  $s_*^2 = \frac{(n_D - 1)s_D^2 + (n_H - 1)s_H^2}{(n_D - 1) + (n_H - 1)}$
- $c$  je konstanta, o kterou se rozdíl průměrů má lišit (většinou  $c = 0$ )
- nulová hypotéza zamítnuta, pokud  $|T| > t_{1-\alpha/2}(n_D + n_H - 2)$

## Je ekvivalentní testu:

$$T^2 = \left( \frac{(\bar{x}_D - \bar{x}_H) - c}{s_* \sqrt{\frac{1}{n_D} + \frac{1}{n_H}}} \right)^2 = (\bar{x}_D - \bar{x}_H - c) \left[ s_*^2 \left( \frac{1}{n_D} + \frac{1}{n_H} \right) \right]^{-1} (\bar{x}_D - \bar{x}_H - c), \text{ kde } T^2 \sim F(1, n_D + n_H - 2) \text{ ← F rozdělení}$$


## Vícerozměrný t-test:

- Hotellingova  $T^2$  testová statistika:  $T^2 = (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})^T \left[ \mathbf{S}_* \left( \frac{1}{n_D} + \frac{1}{n_H} \right) \right]^{-1} (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})$
- kde  $\mathbf{S}_*$  je vážená kovarianční matice:  $\mathbf{S}_* = \frac{(n_D - 1)\mathbf{S}_D + (n_H - 1)\mathbf{S}_H}{(n_D - 1) + (n_H - 1)}$
- $T^2 \sim T^2(p, n - p - 1)$  ← Hotellingovo rozdělení; pro malé  $n_D$  a  $n_H$  je lepší použít:  $F = \frac{n - p - 1}{p} \frac{T^2}{n - 2}$ , kde  $n = n_D + n_H$
- nulová hypotéza zamítnuta, když  $F > F_{1-\alpha}(p, n - p - 1)$  ← F rozdělení

# Úkol 2

- Zjistěte, zda se liší skupina pacientů se schizofrenií od zdravých subjektů na základě parametrů popisujících objem mozkových struktur subjektů.

$$\mathbf{X}_D = \begin{bmatrix} 2 & 12 \\ 4 & 10 \\ 3 & 8 \end{bmatrix}, \mathbf{X}_H = \begin{bmatrix} 5 & 7 \\ 3 & 9 \\ 4 & 5 \end{bmatrix}$$





# Úkol 2

- Zjistěte, zda se liší skupina pacientů se schizofrenií od zdravých subjektů na základě parametrů popisujících objem mozkových struktur subjektů.

$$\mathbf{X}_D = \begin{bmatrix} 2 & 12 \\ 4 & 10 \\ 3 & 8 \end{bmatrix}, \mathbf{X}_H = \begin{bmatrix} 5 & 7 \\ 3 & 9 \\ 4 & 5 \end{bmatrix}$$

# Úkol 2 - řešení

$$T^2 = (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})^T \left[ \mathbf{s}_* \left( \frac{1}{n_D} + \frac{1}{n_H} \right) \right]^{-1} (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})$$

Vícerozměrné průměry:

$$\bar{\mathbf{x}}_D = \left[ \frac{1}{n_D} \sum_{i=1}^{n_D} x_{i1} \quad \frac{1}{n_D} \sum_{i=1}^{n_D} x_{i2} \right] = [3 \quad 10]$$

$$\bar{\mathbf{x}}_H = \left[ \frac{1}{n_H} \sum_{i=1}^{n_H} x_{i1} \quad \frac{1}{n_H} \sum_{i=1}^{n_H} x_{i2} \right] = [4 \quad 7]$$

Výběrové kovarianční matice:

$$\mathbf{S}_D = \begin{bmatrix} s_{11}^D & s_{12}^D \\ s_{21}^D & s_{22}^D \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

$$\mathbf{S}_H = \begin{bmatrix} s_{11}^H & s_{12}^H \\ s_{21}^H & s_{22}^H \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

Vážená kovarianční matice:

$$\mathbf{S}_* = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

# Úkol 2 - řešení

$$T^2 = (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})^T \left[ \mathbf{s}_* \left( \frac{1}{n_D} + \frac{1}{n_H} \right) \right]^{-1} (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})$$

Vícerozměrné průměry:  $\bar{\mathbf{x}}_D = [3 \quad 10]$ ,  $\bar{\mathbf{x}}_H = [4 \quad 7]$

Počty subjektů:  $n_D = 3$ ,  $n_H = 3$ ,  $n = n_D + n_H = 6$

Počet proměnných:  $p = 2$

Vážená kovarianční matice:

$$\mathbf{S}_* = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

Volba parametru  $\mathbf{c}$ :  $\mathbf{c} = [0 \quad 0]$

$$\begin{aligned} T^2 &= (3-4 \quad 10-7) \cdot \left[ \begin{pmatrix} 1 & -1 \\ -1 & 4 \end{pmatrix} \cdot \left( \frac{1}{3} + \frac{1}{3} \right) \right]^{-1} \cdot \begin{pmatrix} 3-4 \\ 10-7 \end{pmatrix} = (-1 \quad 3) \cdot \left[ \begin{pmatrix} \frac{2}{3} & -\frac{2}{3} \\ -\frac{2}{3} & \frac{8}{3} \end{pmatrix} \right]^{-1} \cdot \begin{pmatrix} -1 \\ 3 \end{pmatrix} = \\ &= (-1 \quad 3) \cdot \begin{pmatrix} 2 & 0,5 \\ 0,5 & 0,5 \end{pmatrix} \cdot \begin{pmatrix} -1 \\ 3 \end{pmatrix} = (-2+1,5 \quad -0,5+1,5) \cdot \begin{pmatrix} -1 \\ 3 \end{pmatrix} = (-0,5 \quad 1) \cdot \begin{pmatrix} -1 \\ 3 \end{pmatrix} = 0,5+3 = \underline{3,5} \end{aligned}$$

$$F = \frac{n-p-1}{p} \cdot \frac{T^2}{n-2} = \frac{6-2-1}{2} \cdot \frac{3,5}{6-2} = \frac{3}{2} \cdot \frac{3,5}{4} = \underline{1,3125}$$

VÝPOČET INVERZNÍ MATICE (POMOCÍ JEDNOTKOVÉ MATICE):

$$\begin{aligned} \left( \begin{array}{cc|cc} \frac{2}{3} & -\frac{2}{3} & 1 & 0 \\ -\frac{2}{3} & \frac{8}{3} & 0 & 1 \end{array} \right)_+ &\sim \left( \begin{array}{cc|cc} \frac{2}{3} & -\frac{2}{3} & 1 & 0 \\ 0 & \frac{6}{3} & 1 & 1 \end{array} \right)_{:2} &\sim \left( \begin{array}{cc|cc} \frac{2}{3} & -\frac{2}{3} & 1 & 0 \\ 0 & 1 & 0,5 & 0,5 \end{array} \right) \cdot \frac{3}{2} &\sim \left( \begin{array}{cc|cc} 1 & -1 & 1,5 & 0 \\ 0 & 1 & 0,5 & 0,5 \end{array} \right)_+ &\sim \\ &\sim \left( \begin{array}{cc|cc} 1 & 0 & 2 & 0,5 \\ 0 & 1 & 0,5 & 0,5 \end{array} \right) \end{aligned}$$

# Úkol 2 - řešení

$$T^2 = (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})^T \left[ \mathbf{s}_* \left( \frac{1}{n_D} + \frac{1}{n_H} \right) \right]^{-1} (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H - \mathbf{c})$$

Vícerozměrné průměry:

$$\bar{\mathbf{x}}_D = \left[ \frac{1}{n_D} \sum_{i=1}^{n_D} x_{i1} \quad \frac{1}{n_D} \sum_{i=1}^{n_D} x_{i2} \right] = [3 \quad 10]$$

$$\bar{\mathbf{x}}_H = \left[ \frac{1}{n_H} \sum_{i=1}^{n_H} x_{i1} \quad \frac{1}{n_H} \sum_{i=1}^{n_H} x_{i2} \right] = [4 \quad 7]$$

Výběrové kovarianční matice:

$$\mathbf{S}_D = \begin{bmatrix} s_{11}^D & s_{12}^D \\ s_{21}^D & s_{22}^D \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

$$\mathbf{S}_H = \begin{bmatrix} s_{11}^H & s_{12}^H \\ s_{21}^H & s_{22}^H \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

Vážená kovarianční matice:

$$\mathbf{S}_* = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

Vícerozměrný t-test:

n (počet subjektů)	6
p (počet proměnných)	2
$T^2$	3,5
F	1,31
df1 = p	2
df2 = n-p-1	3
$\alpha$	0,05
F-crit	9,55
p-hodnota	0,389

# Úkol 2 – řešení v softwaru R

```
install.packages("ICSNP")
```

```
library("ICSNP")
```

```
Xd=matrix(c(2,4,3,12,10,8),3,2)
```

```
Xh=matrix(c(5,3,4,7,9,5),3,2)
```

```
HotellingsT2(Xd, Xh)
```

```
Hotelling's two sample T2-test
```

```
data: Xd and Xh
```

```
T.2 = 1.3125, df1 = 2, df2 = 3, p-value = 0.3895
```

```
alternative hypothesis: true location difference is not equal to c(0,0)
```

## Použití softwaru R jako kalkulačky:

```
S=solve(2/3*matrix(c(1,-1,-1,4),2,2)) # výpočet inverzní matice
```

```
b=matrix(c(-1,3),1,2) # vektor s hodnotami rozdílu souřadnic centroidů
```

```
t2=b%*%S%*%t(b) # výpočet testové statistiky  $T^2$ 
```

```
F=(3/2)*(t2/4) # výpočet testové statistiky F
```

```
qf(0.95,2,3) # 95% kvantil F rozdělení pro stupně volnosti 2 a 3
```

```
1-pf(F,2,3) # p-hodnota
```