

Klasifikace objektů

hledání struktury a vzájemných vazeb v objektech

- 1) **Diskriminační analýza DA:** nový objekt se zařadí do již existující třídy.
- 2) **Analýza shluků CLU:** neuspořádanou skupinu objektů lze uspořádat do několika vnitřně sourodých tříd či shluků
- 3) **Vícerozměrné škálování MDS:** hledá strukturu a vazby mezi objekty na základě jejich podobnosti.

Analyzovaný výběr jsou trénovací data, která obsahují pro každý objekt jak výstup y , tak i hodnoty všech znaků x , $\{y; x_1, x_2, \dots x_m\}$

Klasifikovaný výběr: na základě analyzovaného výběru sestavit predikční model, který umožní zařazení nových objektů do tříd.

DISKRIMINAČNÍ ANALÝZA

TRÉNOVÁNÍ S UČITELEM (SUPERVISED LEARNING)



$x_1 x_2 x_3 x_4 \dots \dots x_m$

→ MODEL
(FISHEROVA FUNKCE)

1. TRÉNOVACÍ DATA
(ANALYZOVANÝ SOUBOR)



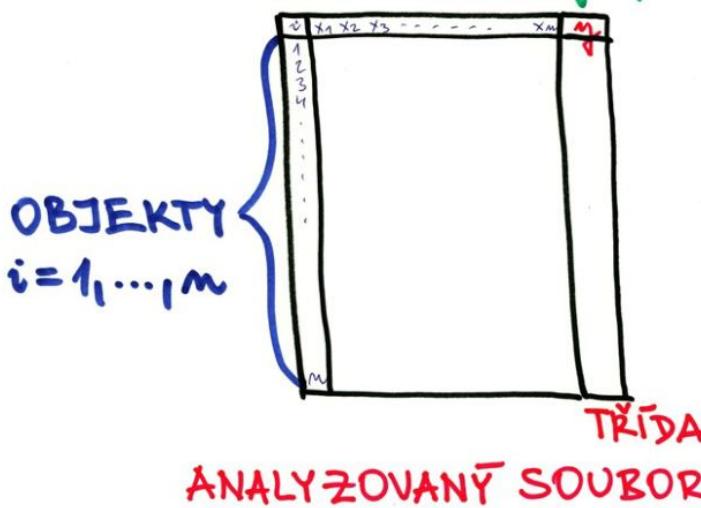
$x_1 x_2 x_3 x_4 \dots \dots x_m$

← VYUŽITÍ
MODELU

2. KLASIFIKACE OBJEKTŮ
(KLASIFIKOVANÝ SOUBOR)

DISKRIMINAČNÍ ANALÝZA

DISKRIMINÁTOŘI, $j=1, \dots, m$



Příklad: použití LDA pro dvě třídy $m = 2$. Vychází se ze známých matic:

X_1 rozměru $n_1 \times m$ pro třídu 1, X_2 rozměru $n_2 \times m$ pro třídu 2.
Jednotlivé objekty v matici X všech dat se zařadí do tříd podle výstupu G .

Postup:

- 1) Vyčíslí se výběrové průměry \bar{x}_1 a \bar{x}_2 a společná kovarianční matice

$$S = \frac{(n_1 - 1)S_1 + (n_2 - 1)S_2}{n_1 + n_2 - 2}$$

- 2a) Nejjednodušší je předpoklad $\pi_1 = \pi_2 = 0.5$.

- 2b) Pokud je výběr informativní a byl pořízen jako celek a pak rozdělen do skupin, je možné použít relativních četností

$$\hat{\pi}_1 = n_1/(n_1 + n_2) \quad \text{a} \quad \hat{\pi}_2 = n_2/(n_1 + n_2)$$

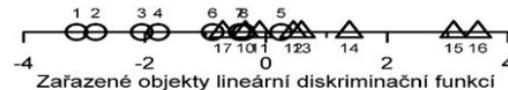
- 3) Za normality se určí koeficienty Fisherovy lineární diskriminační funkce z odhadů

$$\hat{a} = (\bar{x}_1 - \bar{x}_2) S \quad \text{a} \quad \hat{b} = -0.5 \hat{a}^T (\bar{x}_1 - \bar{x}_2) - \ln(\hat{\pi}_2/\hat{\pi}_1)$$

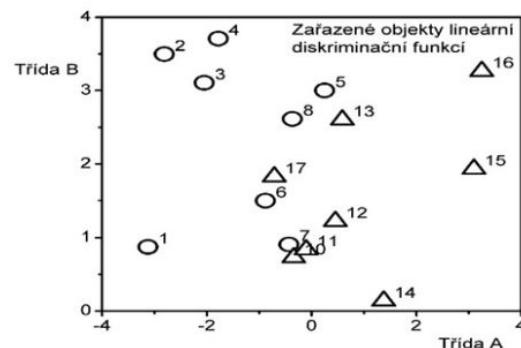
- 4) Při zařazování nových objektů s hodnotami znaků x_0 se použije pravidlo, že do první skupiny je objekt klasifikován pokud platí $\hat{a}^T x_0 + \hat{b} \geq 0$.

- 5) V opačném případě se klasifikuje do druhé skupiny.

Ukázka 1: zařazování Fisherovou lineární diskriminační funkcí:



Ukázka 2: zařazování Fisherovou lineární diskriminační funkcí:



1) **Analyzovaný výběr:** na trénovacích datech vytvoříme třídy

První třída (13 lebek z hrobů v Sikkimu) vede ke středním hodnotám [174.82, 139.35, 132.00, 69.82, 130.35]

$$\text{a kovarianční matici } S_1 = \begin{vmatrix} 45.53 & & & & \\ 25.22 & 57.81 & & & \\ 12.39 & 11.88 & 36.09 & & \\ 22.15 & 7.52 & -0.31 & 20.94 & \\ 27.97 & 48.06 & 1.41 & 16.77 & 66.21 \end{vmatrix}.$$

Druhá třída (15 lebek z bojišť v Lhasy) vede ke středním hodnotám

[185.73, 138.73, 134.77, 76.47, 137.50]

$$\text{a kovarianční matici } S_2 = \begin{vmatrix} 74.42 & & & & \\ -9.52 & 37.35 & & & \\ 22.74 & -11.26 & 36.32 & & \\ 17.79 & 0.70 & -10.72 & 15.30 & \\ 11.13 & 9.46 & 7.20 & 8.66 & 17.96 \end{vmatrix}.$$

Příklad 4.22 Třídění lebek Tibet'anů lineární diskriminační funkci

Databáze lebek na pohřebištích v Tibetu svědčí o dvou skupinách lidí:

prvních 13 bylo nalezeno v hrobech v Sikkimu a okolí,

druhých 15 lebek na bojištích okolo Lhasy.

Předpokládejme, že máme data o 2 třídách tibetských lebek.

Data: i index lebky,

$x1$ největší délka lebky [mm],

$x2$ největší horizontální šířka lebky [mm],

$x3$ výška lebky [mm],

$x4$ výška horní části obličeje [mm],

$x5$ šířka obličeje mezi body lícených kostí [mm].

$x1$	$x2$	$x3$	$x4$	$x5$
190.5	152.5	145	73.5	136.5
...
...
172.5	132	125.5	63	121
167	130	125.5	69.5	119.5
1825	131	135	68.5	136

Řešení:

Koefficienty diskriminační funkce a_1, \dots, a_5 , jsou vyčísleny podle vztahu

$$a = S^{-1}(\bar{x}_1 - \bar{x}_2) = [-0.09, 0.16, 0.01, -0.18, -0.18]$$

a vedou k **průměrům obou tříd**: $\bar{Z}_1 = -28.71$ a $\bar{Z}_2 = -32.21$.

Optimální prahový bod C ,

dle kterého se budou nezařazené objekty řídit do první nebo druhé třídy, se vyčíslí jako polosuma obou průměrů dle vztahu

$$C = (\bar{Z}_1 + \bar{Z}_2)/2 = (-28.71 + (-32.21))/2 = -30.46.$$

Diskriminace:

2) **Klasifikovaný výběr:** na nových datech provedeme zařazení dosud nezařazených objektů

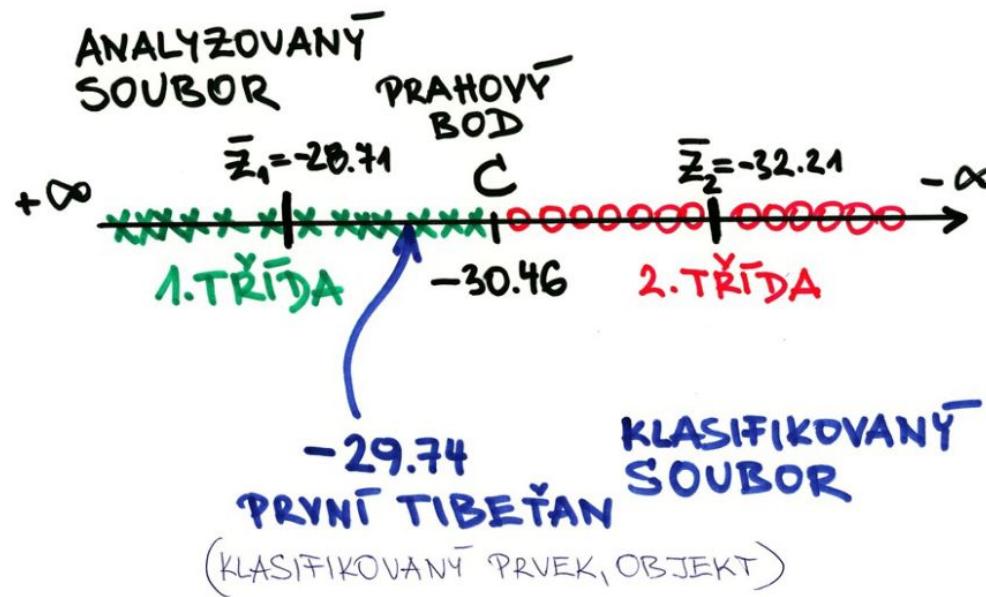
Vezmeme data pro lebku prvního Tibetána a pokusíme se ji zařadit do 1. nebo do 2. třídy.

Vyčíslíme proto pro ni hodnotu **lineární diskriminační funkce**

$$Z_1 = -0.09 \times 190.5 + 0.16 \times 152.5 + 0.01 \times 145.0 - 0.18 \times 73.5 - 0.18 \times 136.5 = -29.74,$$

Závěr: Protože lineární diskriminační funkce $Z_1 = -29.74$ je menší než optimální prahový bod

$$C = -30.46, \text{ patří lebka prvního Tibetána do první třídy.}$$



Úprava prahového bodu

Volba prahového bodu C poskytuje požadovaný poměr apriorních pravděpodobností π_1 a π_2 .

$$\text{Optimální volba prahového bodu } C \text{ je daná vzorcem } C = \frac{\bar{Z}_1 + \bar{Z}_2}{2} + \ln \frac{\pi_1}{\pi_2}$$

$$\text{a když bude } \pi_1 = \pi_2 = 0.5, \text{ bude prahový bod } C \text{ roven } C = \frac{\bar{Z}_1 + \bar{Z}_2}{2}$$

Standardizované koeficienty: hodnoty koeficientů a_1, a_2, \dots, a_p nejsou přímo porovnatelné.

Relativní vliv na každou proměnnou v diskriminační funkci získáme ze *standardizovaných diskriminačních koeficientů*.

Standardizované koeficienty se vypočtou vynásobením koeficientů a_i odpovídající směrodatnou odchylkou s_i .

Volba znaků, diskriminátorů

Znaky musí zajistit přesné zařazení objektů do tříd čili diskriminaci.

Principem selekce znaků je zajištění dostatečné separability tříd a maximalizace některé zvolené míry:

- Začneme se všemi znaky. Pak se a vypouštějí se takové znaky, které provedou nedostatečnou separaci.

- V mnoha situacích může být DA užita jako exploratorní pomůcka.

- Nejprve jsou do dat zahrnutы všechny využitelné znaky. Na začátku není známo, které znaky jsou k zařazení objektů do tříd účinné.

- V diskriminační analýze místo testování změny hodnoty čtverce korelačního koeficientu R^2 přidáním nebo odebráním proměnné testujeme změnu Mahalanobisovy vzdálenosti D_M^2 .

- Užívají se stejná testační kritéria jako při výběru nezávisle proměnných v lineární regresní analýze.

- **Krokový výběr znaků** kombinuje jak jejich přidávání, tak i jejich odstraňování.

- První znak, zahrnutý do modelu ve výběrovém kritériu, má největší přijatelnou hodnotu.

- **Vybírání znaků** se ukončí, když žádné další znaky nesplňují zaváděcí nebo odstraňovací kritérium.

Kritéria k vybírání znaků

Wilkovo kritérium λ : když znak poskytuje v diskriminační funkci nejmenší hodnotu Wilkova kritéria λ , je zahrnut do modelu:

- k zavedení nebo odstranění znaku je dovolen jeden krok.
- maximální počet kroků je roven dvojnásobku počtu znaků.

- **tolerance** je mírou stupně lineární asociace mezi znaky. Pro i -tý znak platí vztah $1 - R_i^2$, kde R_i^2 je čtverec vícenásobného korelačního koeficientu, když je uvažován i -tý znak za závisle proměnnou a když je uvažována regresní rovnice mezi tímto i -tým znakem a ostatními znaky.

- **využití tolerance:** malé hodnoty tolerance indikují, že i -tý znak je lineární kombinací ostatních znaků. Znaky s tolerancí menší než 0.001 nejsou do modelu zařazeny.

Testování: významnost změny Wilkova kritéria λ po zavedení znaku do modelu nebo odstranění z modelu je založena na testačním kritériu F .

Na začátku procesu vybírání znaků: tolerance a minimum tolerance jsou položeny rovny 1, protože v modelu zatím nejsou znaky.

N=143	Výsledky diskriminační funkční analýzy (B23)					
	Wilk. Lambda	Parc. Lambda	F na vyj (2,136)	p-hodn.	Toler.	1-toler. R^2
B23x1-RELWT	0,117426	0,925075	5,50754	0,005012	0,745200	0,254800
B23x2-GLUFAST	0,149708	0,725594	25,71637	0,000000	0,149227	0,850773
B23x3-GLUTEST	0,199867	0,543500	57,11504	0,000000	0,143100	0,856900
B23x4-INTEST	0,122473	0,886949	8,66731	0,000286	0,813954	0,186046
B23x5-SSPG	0,112112	0,968922	2,18109	0,116853	0,562221	0,437779

↓
Test statistické významnosti
dotvárného diskriminátoru

N=150	Výsledky diskriminační funkční analýzy (73Iris)					
	Wilk. Lambda	Parc. Lambda	F na vyj (2,144)	p-hodn.	Toler.	1-toler. R^2
SEPALLENGTH	0,024976	0,938464	4,72115	0,010329	0,347993	0,652007
SEPALWIDTH	0,030580	0,766480	21,93593	0,000000	0,608859	0,391141
PETALLENGTH	0,035025	0,669206	35,59018	0,000000	0,365126	0,634874
PETALWIDTH	0,031546	0,743001	24,90433	0,000000	0,649314	0,350686

Raovo V kritérium, známé jako **Lawley-Hotellingova stopa**, je

$$V = (n - g) \sum_{i=1}^m \sum_{j=1}^m w_{ij} \sum_{k=1}^g (\bar{x}_{ik} - \bar{x}_i)(\bar{x}_{jk} - \bar{x}_j)$$

kde p udává počet znaků v modelu,

g značí počet tříd,

n_k je velikost k -té třídy,

\bar{x}_{ik} je střední hodnota i -tého znaku v k -té třídě,

\bar{x}_i je průměr i -tého znaku pro všechny třídy kombinované dohromady a

w_{ij} představuje prvek inverzní kovarianční matice mezi třídami B^{-1} .

Testování: čím větší jsou rozdíly mezi středními hodnotami (průměry) tříd, tím větší je hodnota Raova V .

Může se však stát, že znak po zařazení do modelu sníží hodnotu Raova V .

F-test významnosti každého znaku: hodnota F pro změnu Wilkova kritéria

λ při přidání znaku do modelu se vyčíslí dle

$$F_{\text{změny}} = \frac{n - g - p}{g - 1} \begin{pmatrix} \frac{1 - \lambda_{p+1}}{\lambda_p} \\ \frac{\lambda_{p+1}}{\lambda_p} \end{pmatrix}$$

kde n je celkový počet objektů,

g udává počet tříd,

p je počet znaků,

λ_p značí Wilkovo lambda před přidáním a

λ_{p+1} je Wilkovo lambda po přidání znaku do modelu.

Testování: Do modelu je zařazen ten znak, který způsobuje nejmenší hodnotu Wilkova kritéria λ

Mahalanobisova vzdálenost $D_{1,2}^2$ je zobecněná míra vzdálenosti mezi dvěma třídami 1 a 2 definovaná vztahem

$$D_{1,2}^2 = (n - g) \sum_{i=1}^m \sum_{j=1}^m w_{ij} (\bar{x}_{i1} - \bar{x}_{i2})(\bar{x}_{j1} - \bar{x}_{j2})$$

kde m udává počet znaků v modelu,

\bar{x}_{ij} je průměr i -tého znaku ve třídě 1,

w_{ij} je prvek inverzní kovarianční matice B^{-1} .

Testování: kritérium všech páru tříd vyčísleno je jako první. Znak, který měl pro dvě od začátku nejtěsnější třídy, nejmenší hodnotu $D_{1,2}^2$, je zařazen do modelu.

F-testační kritérium mezi třídami testuje nulovou hypotézu H_0 : *dva vektory středních hodnot třídy objektů jsou stejné.*

Kritérium je postaveno na Mahalanobisově vzdálenosti $D_{1,2}^2$.

Testační kritérium F je definováno vztahem

$$F = \frac{(n - 1 - p) n_1 n_2}{p(n - 2) (n_1 + n_2)} D_{1,2}^2$$

a může být použito k výběru znaků.

Testování: V každém kroku je zařazen do modelu ten znak, který vykazuje největší hodnotu kritéria F .

Po zavedení dalších znaků do modelu jsou sledovány změny hodnoty testačního kritéria $F_{změny}$.

Proces přidávání znaků do modelu buď pokračuje, nebo je zastaven terminačním kritériem.

Vlastnosti testu:

Test je citlivý na velikost výběru, protože velké výběry jsou náchylné snadněji vykazovat statistickou významnost než výběry malé.

I když se totiž velikosti výběru zvyšují, menší klasifikační poměr bude stále významný.

Například, pro $n = 50$, $n_s = 42$ a $k = 2$ bude $q = (50 - 42 \times 2)^2 / (50(2 - 1)) = 23.12$ a kritická hodnota pro $\alpha = 0.01$ je $\chi^2_{1-\alpha}(1) = 6.63$.

Závěr: Predikce jsou statisticky významnější než apriorní pravděpodobnost π_i , která uvádí správnou klasifikaci pro 50 %.

Například zvětšíme velikost výběru na 100 a klasifikační poměr zůstane 84 %, Pressovo q se zvýší na 46.24.

Statistické míry klasifikace spolehlivosti diskriminace:

- 1) **Pressovo q-kritérium** vyjadřuje míru porovnání počtu správných klasifikací vůči celkové velikosti výběru a počtu tříd. Vyčíslí se vztahem

$$q = \frac{(n - n_s k)^2}{n(k - 1)}$$

kde n je velikost výběru,
 n_s udává počet objektů správně klasifikovaných a
 k značí počet tříd,

Testování: vyšetřuje diskriminační sílu klasifikační matice v porovnání s modelem pravděpodobnosti: vypočtené q se porovnává s $\chi^2_{1-\alpha}(1)$ při dané α , a to když q překročí $\chi^2_{1-\alpha}(1)$, klasifikační matice se jeví statisticky lepší než klasifikační pravděpodobnost.

5. krok: Interpretace výsledků

Tři metody určují relativní důležitost znaku:

- 1) **Standardizované diskriminační koeficienty:** interpretace diskriminačních funkcí vyšetřuje znaménko a velikost standardizovaných diskriminačních koeficientů $a^T = [a_0, a_1, \dots, a_p]$, které představují relativní příspěvek svého znaku do Fisherovy lineární diskriminační funkce:

Diskuze:

- 1) Znaky s relativně velkými koeficienty přispívají více do diskriminační síly diskriminační funkce než znaky s menšími koeficienty.
- 2) Znaménko ukazuje, že znak dává buď kladný, nebo záporný příspěvek.
- 3) Malý koeficient indikuje buď, že odpovídající znak je nevýznamný k určování vztahu nebo je neúplným vztahem, protože je zde vysoký stupeň multikolinearity.
- 4) Problémem je také značná nestabilita diskriminačních koeficientů.

Proměnná	Standardiz. koeficienty (73Iris) pro kanonické proměnné	
	Kořen1	Kořen2
SEPALLENGTH	0,42695	0,012408
SEPALWIDTH	0,52124	0,735261
PETALLENGTH	-0,94726	-0,401038
PETALWIDTH	-0,57516	0,581040
Vlastní	32,19193	0,285391
KumPodíl	0,99121	1,000000

6. krok: Ověření výsledků

Konečné stadium DA se týká potvrzení diskriminačních výsledků.

DA má tendenci přečeňovat hit poměr.

Metoda dělení do skupin (cross-validation) je velmi užitečná.

Rozdělení výběru:

- 1) Soubor je náhodně rozdělen na *analyzovaný výběr* a na *klasifikovaný výběr*.
- 2) Místo dělení na *analyzovaný* a *klasifikovaný* můžeme zcela náhodně rozdělit soubor několikrát.

Testujeme potvrzení diskriminační funkce pomocí *klasifikační matici a hit poměru*.

Když najdeme znaky, které mají největší vliv na diskriminaci mezi třídami, je dalším krokem profilování charakteristiky tříd, založené na třídních průměrech.

Příklad 4.24 Botanické třídění kosatců diskriminační analýzou

Ve Fisherově úloze o rozměrech okvětních lístků u 150 kosatců se analyzují květy tří základních tříd: (1) *Iris setosa*, (2) *Iris versicolor*, (3) *Iris virginica*. Květy kosatců jsou popsány čtyřmi znaky: délkou kališních lístků v mm anglicky *lsepal* a jejich šírkou *wsepal*, dále délkou korunních plátků v mm *lpetal* a jejich šírkou *wpetal*.

Každý objekt je popsán $p = 4$ znaky, a to *SepalLength*, *SepalWidth*, *PetalLength*, *PetalWidth*.

Data: Data jsou v pořadí proměnných E418a, E418b, E418c, E418d:

5.1	3.5	1.4	0.2	5.4	3.9	1.3	0.4	5.2	4.1	1.5	0.1	5.3	3.7	1.5	0.2
4.9	3.0	1.4	0.2	5.1	3.5	1.4	0.3	5.5	4.2	1.4	0.2	5.0	3.3	1.4	0.2
4.7	3.2	1.3	0.2	5.7	3.8	1.7	0.3	4.9	3.1	1.5	0.2	7.0	3.2	4.7	1.4
4.6	3.1	1.5	0.2	5.1	3.8	1.5	0.3	5.0	3.2	1.2	0.2	6.4	3.2	4.5	1.5
5.0	3.6	1.4	0.2	5.4	3.4	1.7	0.2	5.5	3.5	1.3	0.2	6.9	3.1	4.9	1.5
5.4	3.9	1.7	0.4	5.1	3.7	1.5	0.4	4.9	3.6	1.4	0.1	5.5	2.3	4.0	1.3
4.6	3.4	1.4	0.3	4.6	3.6	1.0	0.2	4.4	3.0	1.3	0.2	6.5	2.8	4.6	1.5
5.0	3.4	1.5	0.2	5.1	3.3	1.7	0.5	5.1	3.4	1.5	0.2	5.7	2.8	4.5	1.3
4.4	2.9	1.4	0.2	4.8	3.4	1.9	0.2	5.0	3.5	1.3	0.3	6.3	3.3	4.7	1.6
4.9	3.1	1.5	0.1	5.0	3.0	1.6	0.2	4.5	2.3	1.3	0.3	4.9	2.4	3.3	1.0
5.4	3.7	1.5	0.2	5.0	3.4	1.6	0.4	4.4	3.2	1.3	0.2	6.6	2.9	4.6	1.3
4.8	3.4	1.6	0.2	5.2	3.5	1.5	0.2	5.0	3.5	1.6	0.6	5.2	2.7	3.9	1.4
4.8	3.0	1.4	0.1	5.2	3.4	1.4	0.2	5.1	3.8	1.9	0.4	5.0	2.0	3.5	1.0
4.3	3.0	1.1	0.1	4.7	3.2	1.6	0.2	4.8	3.0	1.4	0.3	5.9	3.0	4.2	1.5
5.8	4.0	1.2	0.2	4.8	3.1	1.6	0.2	5.1	3.8	1.6	0.2	6.0	2.2	4.0	1.0
5.7	4.4	1.5	0.4	5.4	3.4	1.5	0.4	4.6	3.2	1.4	0.2	6.1	2.9	4.7	1.4

Kosatce (Iris)



Iris Setosa



Iris Versicolor



Iris Virginica

Kosatce (Iris)



Iris Setosa



Iris Versicolor



Iris Versicolor



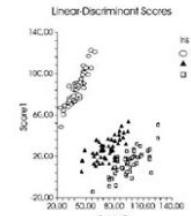
Iris Virginica

Iris Virginica

Iris Virginica

6. Klasifikační grafy.

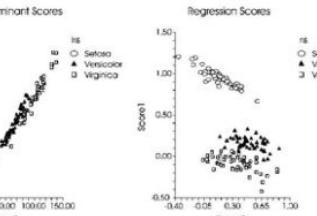
Užijeme grafy: (a) lineárních diskriminačních skóre, (b) regresních skóre nebo (c) kanonických skóre.



Obr. 7.9a Graf lineárního diskriminačního skóre 1 a 2 u 4 znaků 150 kosatců zdrojové matici dat Iris (STATISTICA).



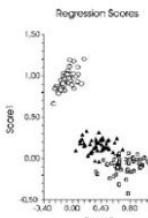
Obr. 7.9b Graf lineárního diskriminačního skóre 1 a 3 u 4 znaků 150 kosatců zdrojové matici dat Iris (STATISTICA).



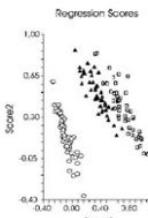
Obr. 7.9c Graf lineárního diskriminačního skóre 2 a 3 u 4 znaků 150 kosatců zdrojové matici dat Iris (STATISTICA).



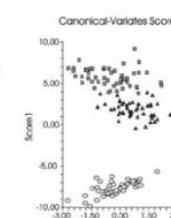
Obr. 7.9d Graf regresního skóre 1 a 2 u 4 znaků 150 kosatců zdrojové matici dat Iris (STATISTICA).



Obr. 7.9e Graf regresního skóre 1 a 3 u 4 znaků 150 kosatců zdrojové matici dat Iris (STATISTICA).



Obr. 7.9f Graf regresního skóre 2 a 3 u 4 znaků 150 kosatců zdrojové matici dat Iris (STATISTICA).



Obr. 7.9g Graf kanonických proměnných 1 a 2 u 4 znaků 150 kosatců zdrojové matici dat Iris (STATISTICA).

Cvičení v programu STATISTICA

1. Načtení dat
2. Zadání metod DA.
3. Zadání proměnných: grupovací a nezávislé.
4. Zadání kódů pro grupovací proměnné.
5. Zadání krokové analýzy
6. Definice modelu: záložky Základ, Detaily, Popisné statistiky
7. Záložka Detaily: okénko Metoda – zvol standardní (ze tří nabízených), Tolerance: 0.01
8. Záložka Popisné statistiky: volba Zobrazit popisné statistiky
- 9.-38 Ze tří záložek zvol Detaily: 7 voleb postupně otevří a prohlédni:

 - 39. STORNO a zpět do okna Popisné statistiky a zobrazit Popisné statistiky zvol záložku Všechny.
 - 40. Zadej Celková kovariance a korelace. Korelační matice 4 znaků: Celková korelace.
 - 44. Zvol korelační matici Kliknutím na Graf celkové korelace.
 - 45. Zvol Krabicevý graf průměru všechn 4 znaků.
 - 46. Upravit krabicevý graf.
 - 47. 1 krát STORNO až na Definice modelu. Metoda – kroková doplněná. Záložka Detaily a pak Výsledky: pouze shrnutí.
 - 48. Zvol Výpočet v záložce Základ nastavení. Seřadi znaky dle statistické významnosti.
 - 50. Zpět na záložku Detaily a v ní Kanonická analýza a záložka Základ nastavení.
 - 51. Zvol Výpočet: Test Chi kvadrát postupných koeficientů. Hledání ortogonálních diskriminačních funkcí čili kanonických koeficientů Chi²-testem.
 - 52. Komentovat Chi²-test.
 - 53. Kanonická analýza a v ní záložka Detaily a v ní záložka pro kanonické proměnné.
 - 54. Kanonická analýza a v ní záložka Detaily a v ní Faktorová analýza a pojmenování koeficientů: Koef 1 je o délce květů a Koef 2 je o šířce květu.
 - 55. Zpět a zvol Průměry kanonických proměnných a souřadnice jejich polohy.
 - 56. Zpět a záložka Kanonické skóre.
 - 57.-58. Záložka Bodový graf kanonických skóre. Upravit graf.
 - 59. Zpět a Uložit kanonická skóre za IRISTYPE a užít Graf, Bodové grafy. Překopírovat Popisy bodů.
 - 60. STORNO a pak záložka Klasifikace: zvol a prohlédni si záložky Klasifikaci matic, Klasifikace objektů, Mahalanobisovy vzdálenosti, Aposteriorní pravděpodobnosti.

Fisher (1936) ins data: length & width of sepals and petals, 3 types of Iris				
	1	2	3	4
	SEPALLENGTH	SEPALWIDTH	PETALLENGTH	PETALWIDTH
1	5	3,3	1,4	0,2 SETOSA
2	6,4	2,8	5,6	2,2 VIRGINIC
3	6,5	2,8	4,6	1,5 VERSICOL
4	6,7	3,1	5,6	2,4 VIRGINIC
5	6,3	2,8	5,1	1,5 VIRGINIC
6	4,6	3,4	1,4	0,3 SETOSA
7	6,9	3,1	5,1	2,3 VIRGINIC
8	6,2	2,2	4,5	1,5 VERSICOL
9	5,9	3,2	4,8	1,8 VERSICOL
10	4,6	3,6	1	0,2 SETOSA
11	6,1	3	4,6	1,4 VERSICOL
12	6	2,7	5,1	1,6 VERSICOL
13	6,5	3	5,2	2 VIRGINIC
14	5,6	2,5	3,9	1,1 VERSICOL
15	6,5	3	5,5	1,8 VIRGINIC
16	5,8	2,7	5,1	1,9 VIRGINIC
17	6,8	3,2	5,9	2,3 VIRGINIC
18	5,1	3,3	1,7	0,5 SETOSA
19	5,7	2,8	4,5	1,3 VERSICOL
20	6,2	3,4	5,4	2,3 VIRGINIC
21	7,7	3,6	6,7	2,2 VERSICOL
22	6,3	3,3	4,7	1,6 VERSICOL
23	6,7	3,3	5,7	2,5 VIRGINIC
24	7,6	3	6,6	2,1 VIRGINIC
25	4,9	2,5	4,5	1,7 VIRGINIC
26	5,5	3,5	1,3	0,2 SETOSA
27	6,7	3	5,6	2,3 VIRGINIC
28	7	3,2	4,7	1,4 VERSICOL
29	6,4	3,2	4,5	1,5 VERSICOL
30	6,1	2,8	4	1,3 VERSICOL
31	4,8	3,1	1,6	0,2 SETOSA
32	5,9	3	5,1	1,8 VIRGINIC
33	5,5	2,4	3,8	1,1 VERSICOL
34	6,3	2,5	5	1,9 VIRGINIC
35				
36				
37				
38				
39				
40				
41				
42				
43				
44				
45				
46				

1. Fisherova úloha kosatce (iris, 1936) třídí kosatce do tří tříd podle svých 4 znaků, a to délky a šířky kališních lístků a délky a šířky korunních plátků. Poslední sloupec dat je kódovaný znak.

Čtenář u své úlohy zaměňí okvětní lístky za znaky své úlohy. Poslední sloupec bude vždy kódovací znak.

The screenshot shows the STATISTICA software interface with the 'Analýza skupin' (Group Analysis) dialog box open. The 'Základní statistiky/tabulky' (Basic statistics/tables) tab is selected. In the 'Analýza skupin' section, the 'Vicerozměrné průzkumové metody' (Multivariate survey methods) button is highlighted. A context menu is open over this button, listing various statistical methods: Diskriminace, Shukarová analýza, Faktorová analýza, Analýza s využitím výšky, Výkresy, Text & Document Mining, Web Crawling, Statistiky bloku dat, STATISTICA Visual Basic, Pravidelnostní kalkulátor, Gennový analyzátor, Klasifikace objektů, Korespondenční analýza, Vicerozměrné říkání, Diskriminační analýza, and Relyability obecné diskriminační analýzy.

2. Zvolí se Diskriminační analýza v bloku Vicerozměrné průzkumové metody.

Fisher (1936) iris data: length & width of sepals and petals, 3 types of Iris

	1	2	3	4	5	Trida
1	5	3.3	1.4	0.2	SETOSA	
2	6.4	2.8	5.6	2.2	VIRGINIC	
3						
4						
5						
6						
7						
8						
9						
10	5,9	3,6	4,9	1,8	VERSICOL	
11	4,6	3,6	1	0,2	SETOSA	
12	6,1	3	4,6	1,4	VERSICOL	
13	6	2,7	5,1	1,6	VERSICOL	
14	6,5	3	5,2	1,5	VERSICOL	
15	5,6	2,5	3,9	1,2	VERSICOL	
16	6,5	3	5,5	1,4	VERSICOL	
17	5,8	2,7	5,1	1,5	VERSICOL	
18	6,8	3,2	5,9	1,8	VERSICOL	
19	5,1	3	1,7	0,2	SETOSA	
20	5,7	2,8	4,5	1,4	VERSICOL	
21	6,2	3,4	5,4	1,5	VERSICOL	
22	7,7	3,8	6,7	2,0	VERSICOL	
23	6,3	3,3	4,7	1,4	VERSICOL	
24	6,7	3,3	5,7	1,5	VERSICOL	
25	7,6	3	6,6	2,2	VERSICOL	
26	4,9	2,5	4,5	1,4	VERSICOL	
27	5,5	3,5	1,5	0,2	SETOSA	
28	6,7	3	5,2	1,5	VERSICOL	
29	7	3,2	4,7	1,4	VERSICOL	
30	6,4	3,2	4	1,5	VERSICOL	
31	6,1	2,8	4	1,4	VERSICOL	
32	4,8	3,1	5,1	1,8	VERSICOL	
33	5,9	3	5,1	1,8	VERSICOL	
34	5,5	2,4	4,5	1,4	VERSICOL	
35	6,8	2,5	4,5	1,5	VERSICOL	
36	5,4	2	4,7	1,4	VERSICOL	
37	4,9	3,6	4,5	1,4	VERSICOL	
38	5,4	3	4,5	1,4	VERSICOL	
39	7,9	3,8	6,5	2,0	VERSICOL	
40	4,4	3,2	4,5	1,4	VERSICOL	
41	6,7	3,3	5,7	1,5	VERSICOL	
42	5	3,5	4,5	1,4	VERSICOL	
43	5,6	2,9	4,5	1,4	VERSICOL	
44	4,4	3	4,5	1,4	VERSICOL	
45	7,7	2,8	5,5	1,5	VERSICOL	
46	6,3	2,7	4,5	1,4	VERSICOL	

3. Zadají se všechny nezávisle Proměnné a jedna Grupovací proměnná.

4.3 SETOSA

5. V okénku Další možnosti se zaškrtnce Kroková analýza. Díry ve zdrojové matici vedou buď k vyškrnutí řádku, objektu (značeno Celé případy) nebo k dodatečnému vyplnění díry průměrem (značeno Substituce průměrem).

Diskriminační funkční analýza: 73Iris.sta

Základní nastavení

Proměnné

grupovací: Trida

nezávislé: 1-4

Kódy pro grupovací prom.: 3 určené skupiny

Další možnosti (kroková analýza)

Pro pokročilé funkce diskriminační analýzy nebo rozšířející analytické problémy použijte Modely obecné diskriminační analýzy.

1,3 VERSICOL
0,2 SETOSA
1,8 VIRGINIC
1,1 VERSICOL

Fisher (1936) iris data: length & width of sepals and petals, 3 types of Iris

4. Grupovací proměnná má krátký název (zde Třída) a Dlouhý název (zde Three types of iris), které třídí 150 květů kosatců do tříd Setosa, Versicolor a Virginica.

1,4 VERSICOL
1,6 VERSICOL
2,1 VERSICOL

Diskriminační funkční analýza: 73Iris.sta

Základní nastavení

Proměnné

grupovací: Trida

nezávislé:

Kódy pro grupovací prom.: nic

Další možnosti (kroková analýza)

ChD vynechána

celé případy

Substitute průměrem

Výběr kódů pro grupovací proměnné

Třída

SETOSA-VIRGINIC

Výběr výběr

Další možnosti

OK

Storno

Popisné statistiky

N = 150

Přůměr = 2,000000

SmDch = 0,819232

3,3 1,4 0,2 SETOSA
2,8 5,6 2,2 VIRGINIC
2,8 4,6 1,5 VERSICOL
3,1 5,6 2,4 VIRGINIC
2,8 5,1 1,5 VERSICOL
3,4 1,4 0,3 SETOSA
3,1 5,1 2,3 VIRGINIC
2,2 4,5 1,5 VERSICOL
3,2 4,8 1,8 VERSICOL
3,6 1 0,2 SETOSA
3 4,6 1,4 VERSICOL
2,7 5,1 1,6 VERSICOL
3 5,2 2 0,2 SETOSA
2,5 3,9 1,1 0,2 SETOSA
3 5,5 1,8 0,2 SETOSA
2,7 5,1 1,9 0,2 SETOSA
3,2 5,9 2,3 0,2 SETOSA
3,3 1,7 0,5 0,2 SETOSA
2,8 4,5 1,3 0,2 SETOSA
3,4 5,4 2,3 0,2 SETOSA
3,8 6,7 2,2 0,2 SETOSA
3,3 4,7 1,6 0,2 SETOSA
3,3 5,7 2,5 0,2 SETOSA
3 6,6 2,1 0,2 SETOSA
2,5 4,5 1,7 0,2 SETOSA
3,5 1,3 0,2 0,2 SETOSA
3 5,2 2,3 0,2 SETOSA
3,2 4,7 1,4 0,2 SETOSA
3,2 4,5 1,5 0,2 SETOSA
2,8 4 1,3 0,2 SETOSA
3,1 1,6 0,2 SETOSA
3 1,8 0,2 0,2 SETOSA

Definice modelu: 73Iris.sta

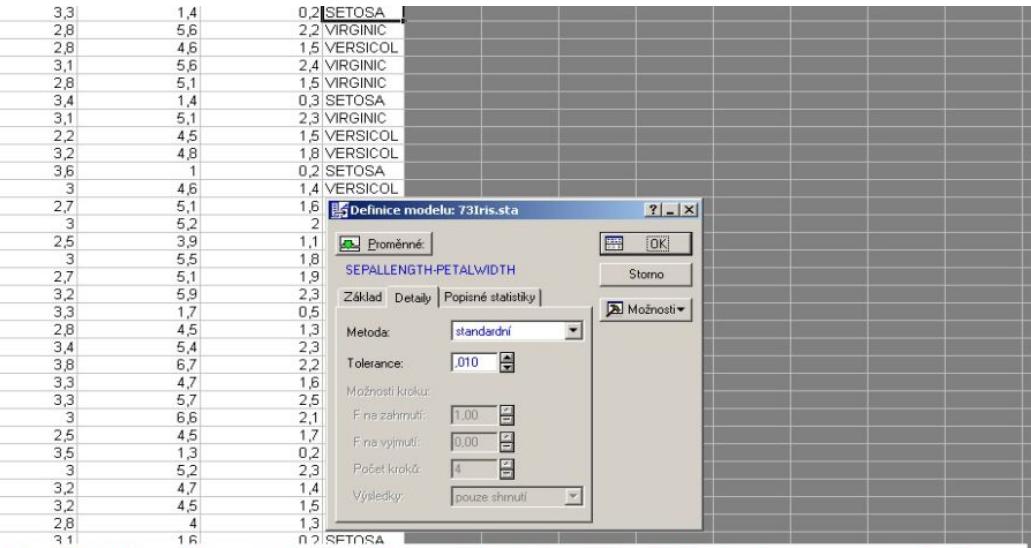
Proměnné: SEPALLENGTH-PETALWIDTH

Základ | Detaily | Popisné statistiky

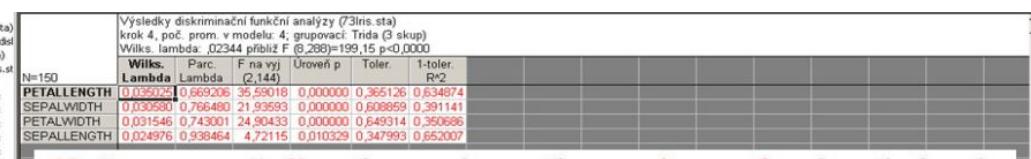
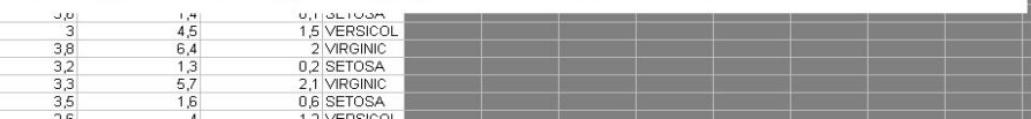
Metoda: standardní

4.5 VERSICOL
3,8 6,4 2 VIRGINIC
3,2 1,3 0,2 SETOSA
3,3 5,7 2,1 VIRGINIC
3,5 1,6 0,6 SETOSA
1,1 VERSICOL

6. Definice modelu má tři záložky to Základ, Detaily, Popisné statistiky, které si nyní postupně prohlédneme.



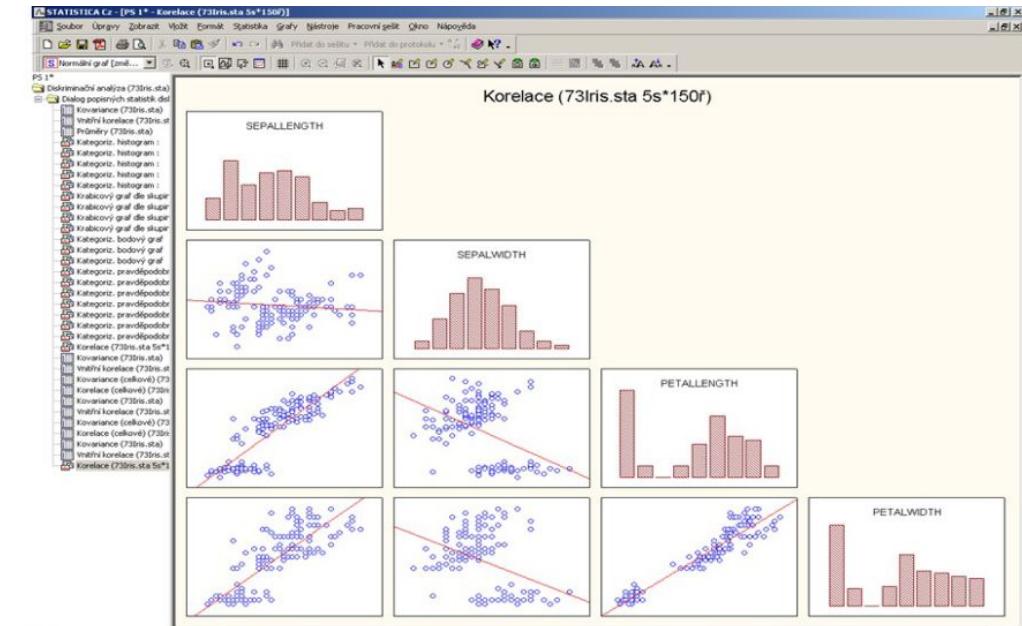
7. Záložka *Detaily*: zvolí se zde *Metoda diskriminace* a zadají se hodnoty tolerance, pokud je jiná než defaultně zadaná.



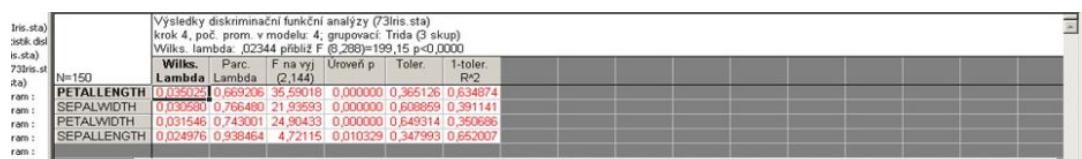
49. Program seřadí znaky a vybere přitom nejprve takový znak, který nejlépe a nejvíce přispívá k diskriminaci objektů do tříd. Jde o znak s nejvetší hodnotou F , větší hodnotou F než bylo F zadáno na začátku, při hledání nejlepších znaků se za počáteční hodnotu totiž volí obvykle nula. Když bychom ale naopak chtěli všechny znaky z modelu odebrat, zadáme na počátku pro F vysokou hodnotu, například 9999.

Tolerance $1-R^2$ je mírou redundancy (= nadbytečnosti) znaku. Vykazuje-li totiž znak toleranci třeba 0.01, pak je z 99% nadbytečný vůči dříve zadáným ostatním znakům. Když jeden nebo více znaků jsou příliš redundantní, diskriminaci nelze provést. Položíme proto mezní hodnotu tolerance rovnou 0.01.

Wilkovo λ je standardní statistika testu významnosti diskriminační síly sledovaného znaku v modelu. Nabývá hodnot od 1, značící pak žádnou diskriminační sílu znaku, do 0.0, značící perfektní diskriminační sílu znaku.



44. Červené přímky v oknech diagramu *Celkové korelace* ukazují na lineární závislost mezi dvěma znaky. Osamocené shluky bodů v každém grafu ukazují, že lze diskriminovat kosatce do několika tříd.



Parciální Wilkovo λ je jednotkový příspěvek dotyčného znaku k diskriminaci objektů do tříd. Čím je jeho hodnota bližší k 0, tím větší diskriminační síla tohoto znaku. Výpočet začíná s počáteční hodnotou rovnou 0.0. Wilkovo λ konvertuje do F kritéria a odpovídající vypočtené hladiny významnosti p .

Ukazuje se zde, že *PETALLENGTH* přispívá nejvíce, *PETALWIDTH* jako druhý, pak *SEPALWIDTH* a nejméně přispívá k diskriminaci kosatců do tříd *SEPALLENGTH*. Čím menší je totiž λ , tím více přispívá znak k diskriminaci. Z toho plyne, že *PETAL* je hlavním znakem, který vlastně vůbec umožňuje rozřídit kosatce do tříd.

STATISTICA Cz - [PS 1* - Test chí-kvadrát po odstranění post. kořenů (73Iris.sta)]

PS 1*

Diskriminační analýza (73Iris.sta)

Vlastní číslo R Wilks. Chi-kv. sv Úroveň p

0	32,19193	0,984821	0,023439	546,1153	8	0,000000
1	0,28539	0,471197	0,777973	36,5297	3	0,000000

52. Nejprve určíme, zda obě diskriminační funkce (či kanci) jsou statisticky významné. První řádek tabulky *Testu Chí-kvadrát* je statistickou významností všech (zde 2) kanonických kořenů postupném odstraňování. Druhý řádek se týká všech kořenů ale bez prvního, atd. Tabulka proto odpovídá, kolik a které statisticky ještě významné. Zde jsou obě diskriminační kanonické kořeny statisticky významné. Když proto budeme u nových kosatců dvě míry okvětních lístků, PETALS, zaručíme, že je pak možné roztrídit kosatce do tří.

STATISTICA Cz - [PS 1* - Standardiz. koeficienty (73Iris.sta)]

PS 1*

Diskriminační analýza (73Iris.sta)

Proměnná Kořen1 Kořen2

PETALLENGTH	-0,94726	-0,401038
SEPALWIDTH	0,52124	0,735261
PETALWIDTH	-0,57516	0,581040
SEPALLENGTH	0,42695	0,012408
Vlastní	32,19193	0,285391
KumPodíl	0,99121	1,000000

53. **Tabulka standardizovaných koeficientů:** Původní spojení s původními daty poskytuje skóre diskriminací. Standardizované koeficienty patří ke standardizovaným v normovaných vzájemně porovnatelných škálách. První funkce je silně vážená délkami a šírkami PETALS. Zbývající ale také trochu přispívají. Druhá diskriminační funkce je více znakem SEPALWIDTH a daleko však méně PETALLENGTH.

STATISTICA Cz - [PS 1* - Faktorová strukturní matice (73Iris.sta)]

PS 1*

Diskriminační analýza (73Iris.sta)

Proměnná Kořen1 Kořen2

PETALLENGTH	-0,706065	0,167701
SEPALWIDTH	0,119012	0,863681
PETALWIDTH	-0,633178	0,737242
SEPALLENGTH	-0,222596	0,310812

54. **Faktorová strukturní matice:** v tabulce uvedené představují korelace mezi znaky a diskriminačními funkciemi. Tato tabulka je proto k objasnění "významu" diskriminačních funkcí. Výhodné pojmenovat či názvem přidělit význam těmto diskriminačním funkcím podobně jako se to dělá v FA.

STATISTICA Cz - [PS 1* - Průměry kan. proměnných (73Iris.sta)]

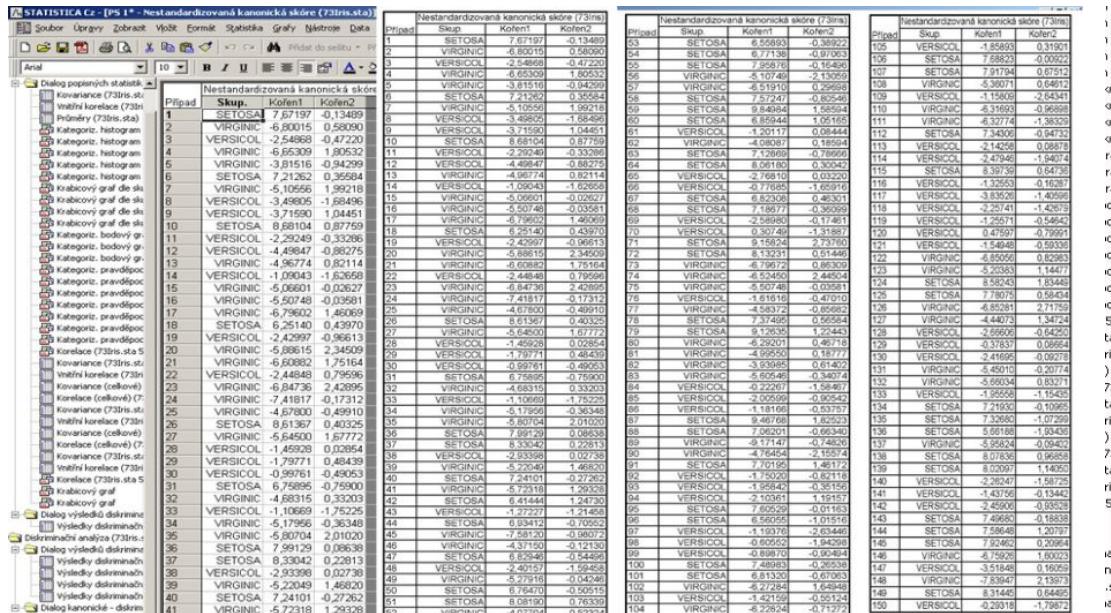
PS 1*

Diskriminační analýza (73Iris.sta)

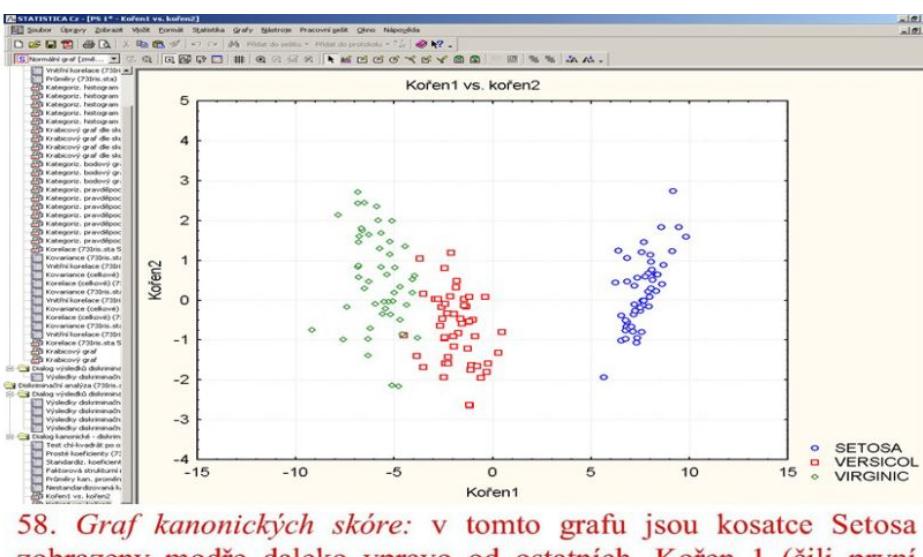
Skup. Koen1 Koen2

SETOSA	7,60760	0,215133
VERSICOL	-1,82505	-0,727900
VIRGINIC	-5,78255	0,512767

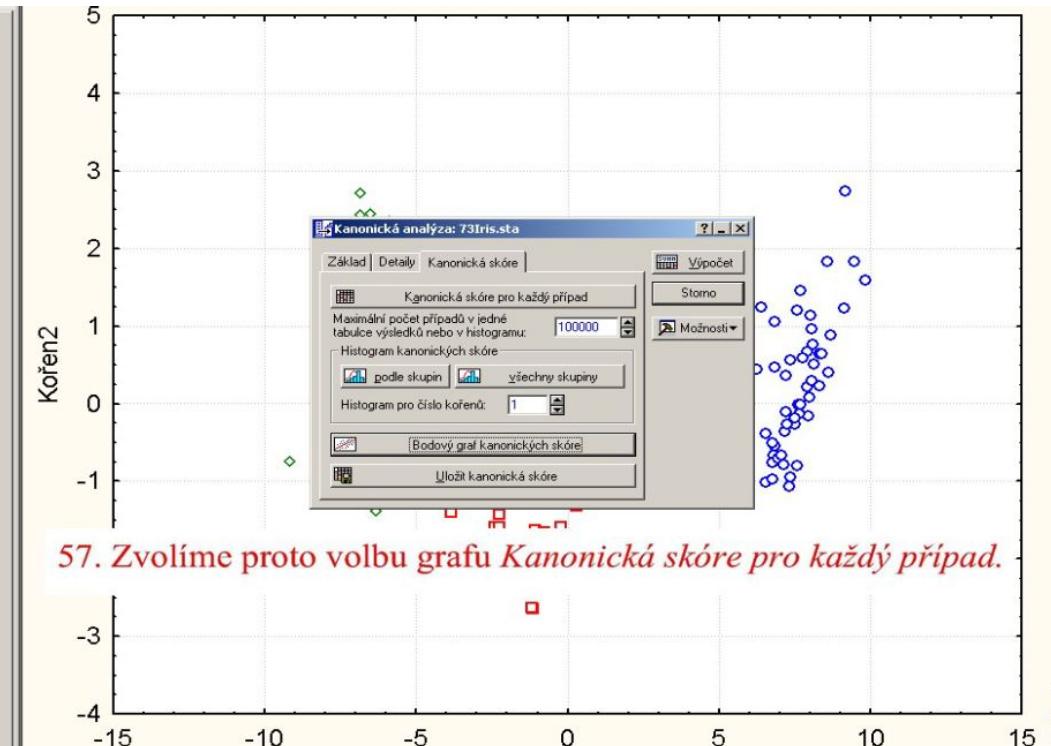
55. **Průměry kanonických proměnných:** je třeba rozlišit diskriminace kosatců v každém kanonickém kořeni. Zde je diskriminační funkce diskriminuje většinou mezi třemi ostatními kosatci. Kanonický průměr Setosy se zcela liší od průměrů Versicoloru a Virginica. Druhá diskriminační funkce rozlišuje pak mezi Virginicou a Versicolorou, avšak tato diskriminace je mnohem menší než první funkce.



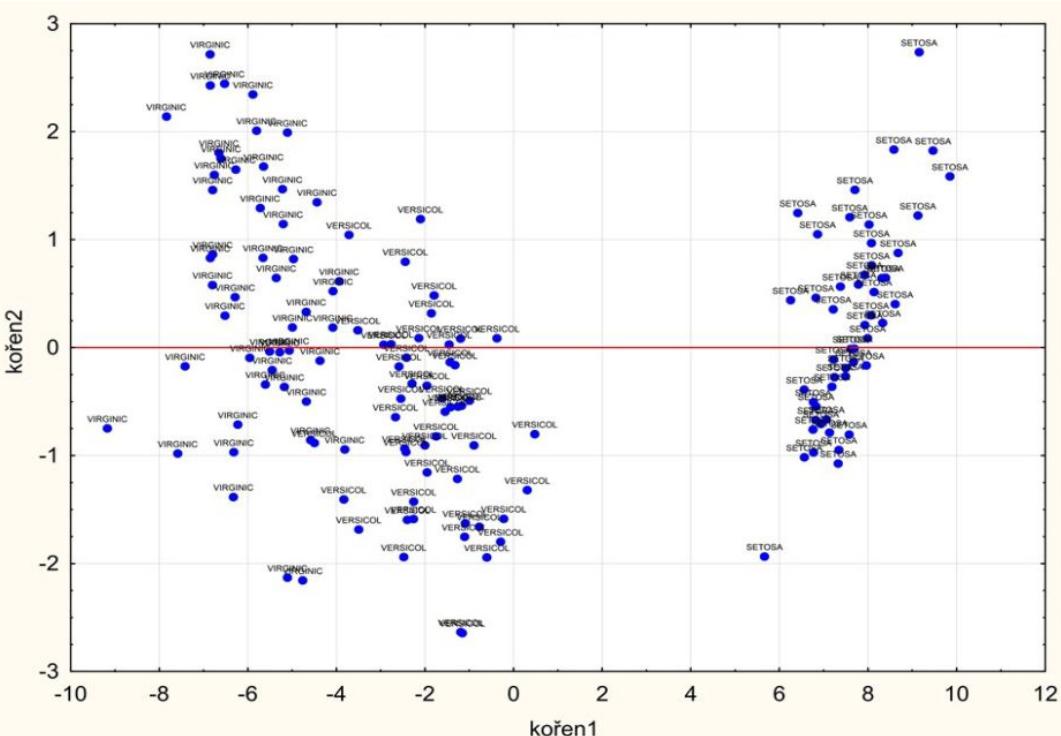
56. Nestandardizované kanonické skóre: Tabulka nestandardizovaných kanonických kořenů ukazuje na diskriminaci všech 150 kosatců. Samozřejmě by bylo zde názornější provést grafické zobrazení.



58. *Graf kanonických skóre:* v tomto grafu jsou kosatce Setosa zobrazeny modře daleko vpravo od ostatních. Kořen 1 (čili první diskriminační funkce) silně diskriminuje Setosu od ostatních kosatců. Kořen 2 (druhá diskriminační funkce) poskytuje diskriminaci mezi Versicolor se zápornými hodnotami Kořene 2 a ostatními kosatci, převážně kladného Kořene 2. Diskriminace však není tak zřetelná jakou je tomu u prvního Kořene 1.



57. Zvolíme proto volbu grafu *Kanonická skóre pro každý případ*.



STATISTICA Cz - [PS 1* - Mahalanobisovy vzdálenosti (73iris.sta)]

Soubor Úpravy Zobrazit Vložit Formát Statistika Grafy Nástroje Data Pracovní seřítk Očko Nápověda

Přidat do sestoru Přidat do protokolu Proměnné Případy

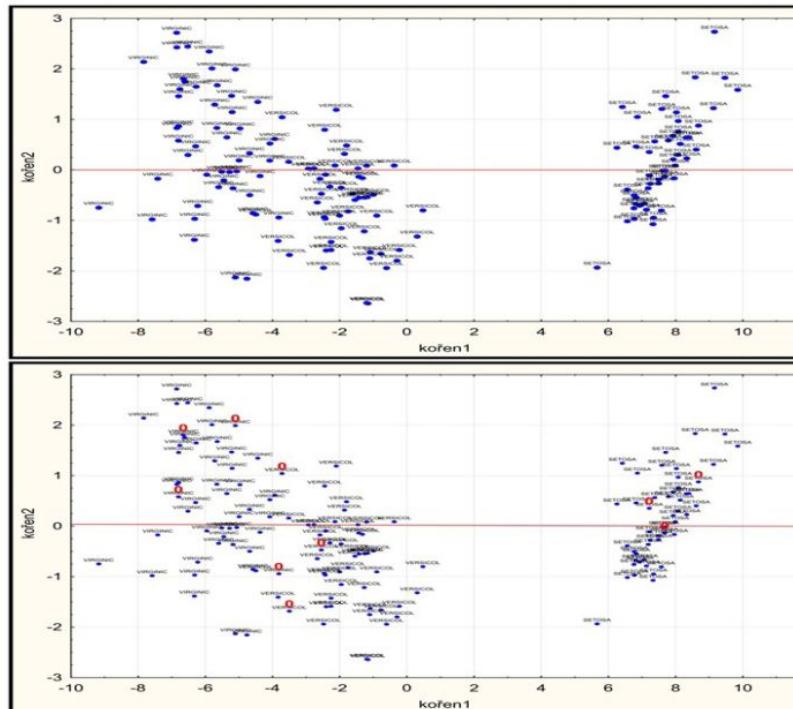
Arit

Mahalanobisovy vzdálenosti (73iris.sta)

Nesprávné klasifikace je označena *

Případ	Pozorov.	SETOSA	VERSICOL	VIRGINIC
1	SETOSA	0,2419	90,6602	181,5687
2	VIRGINIC	206,5713	27,3188	1,8944
3	VERSICOL	105,2663	2,2329	13,0720
4	VIRGINIC	207,9180	31,7492	4,4506
*	VIRGINIC	133,0668	5,2629	7,2359
6	VIRGINIC	173,1638	26,6262	1,71484
7	VERSICOL	131,6617	8,4307	14,7647
*	VERSICOL	130,8624	8,6697	6,5668
10	SETOSA	2,2064	113,6609	210,0239
11	VERSICOL	99,2338	1,2963	13,8174
*	VERSICOL	149,0303	8,4393	4,8645
13	VIRGINIC	158,9817	12,7512	1,2342
14	VERSICOL	79,1079	4,0765	26,6531
15	VERSICOL	129,1079	12,7512	1,2342
16	VIRGINIC	174,0619	16,0529	2,3902
17	VIRGINIC	209,0295	29,5143	1,9395
18	SETOSA	2,7680	67,4717	145,7007
19	VERSICOL	104,5191	2,7936	15,7979
20	VIRGINIC	188,8750	28,1928	5,6252
21	VIRGINIC	213,4056	37,9708	11,1557
22	VERSICOL	104,5191	2,7936	15,7979
23	VERSICOL	216,2034	36,6489	9,3022
24	VIRGINIC	200,2255	36,8899	4,4448
25	VIRGINIC	160,5946	17,3403	11,3905
26	SETOSA	3,9613	113,1601	210,1669
27	VIRGINIC	183,5631	26,1715	7,1695
28	VERSICOL	86,5713	5,0343	23,2534
29	VERSICOL	88,6113	1,8095	16,2119
30	VERSICOL	75,6753	35,8897	25,3660
31	SETOSA	1,0009	73,1999	159,0406
32	VIRGINIC	153,7618	11,9778	9,3069
33	VERSICOL	80,1609	1,9167	27,3454
34	VIRGINIC	166,9178	14,4570	4,2020
35	VIRGINIC	184,8178	24,9964	3,8858
36	SETOSA	0,7032	97,5630	190,4399
37	SETOSA	1,7984	105,3013	200,5307
38	VERSICOL	117,5672	32,6790	11,6659
39	VIRGINIC	176,5672	26,1790	11,6659
40	SETOSA	2,0048	84,0333	171,8626

63. Mahalanobisovy vzdálenosti: jde o míru vzdálenosti ve vícerozměrném prostoru. Nesprávné zařazení při klasifikaci je označeno hvězdičkou.



STATISTICA Cz - [PS 1* - Aposteriorní pravděpodobnosti (73iris.sta)]

Soubor Úpravy Zobrazit Vložit Formát Statistika Grafy Nástroje Data Pracovní seřítk Očko Nápověda

Přidat do sestoru Přidat do protokolu Proměnné Případy

Arit

Aposteriorní pravděpodobnosti (73iris.sta)

Nesprávné klasifikace je označena *

Případ	Pozorov.	SETOSA	VERSICOL	VIRGINIC
1	SETOSA	1,000000	0,000000	0,000000
2	VIRGINIC	0,000000	0,000003	0,999997
3	VERSICOL	0,000000	0,995590	0,004410
4	VIRGINIC	0,000000	0,000001	0,999999
*	VERSICOL	1,000000	0,279388	0,270512
6	SETOSA	1,000000	0,000000	0,000000
7	VIRGINIC	0,000000	0,000428	0,999572
8	VERSICOL	0,000000	0,959573	0,040427
*	VERSICOL	1,000000	0,253228	0,746772
10	SETOSA	1,000000	0,000000	0,000000
11	VERSICOL	0,000000	0,998093	0,001907
*	VERSICOL	0,000000	0,143392	0,866608
13	VIRGINIC	0,000000	0,003146	0,996654
14	VERSICOL	0,000000	0,999997	0,000003
15	VIRGINIC	0,000000	0,006084	0,993916
16	VIRGINIC	0,000000	0,001078	0,998922
17	Korelace (celkové) (7)	0,000000	0,000001	0,999999
18	SETOSA	1,000000	0,000000	0,000000
19	VERSICOL	0,000000	0,998502	0,001498
20	VIRGINIC	0,000000	0,000013	0,999987
21	VIRGINIC	0,000000	0,000002	0,999998
22	VERSICOL	0,000000	0,985835	0,014165
23	VIRGINIC	0,000000	0,000000	1,000000
24	VERSICOL	0,000000	0,000001	0,999999
25	VIRGINIC	0,000000	0,048620	0,951380
26	SETOSA	1,000000	0,000000	0,000000
27	VIRGINIC	0,000000	0,000075	0,999925
28	VERSICOL	0,000000	0,999889	0,000111
29	VERSICOL	0,000000	0,999257	0,000743
30	VERSICOL	0,000000	0,999991	0,000009
*	SETOSA	n nnnnn	n nnnnn	n nnnnn

64. *A posteriori pravděpodobnosti:* Každá třída je dokumentována svou vypočtenou čili *a posteriori* pravděpodobností. Největší hodnota pravděpodobnosti ve sloupečku ukazuje, že kosatec náleží do třídy dotyčného sloupce.

Úloha C32 Klasifikace a struktura znaků oxidu titaničitého dle chemických a fyzikálních vlastností (DA)

Výsledky analýz tří skupin bílého pigmentu oxidu titaničitého. Proveďte klasifikaci diskriminační analýzou (DA).

○ **Data:** Popis znaků ve sloupcích: Data **ID**, Zařazení do tříd **Klas**, tj. typy RGA, RGX, RGU tvoří tréninková data. Diskriminátory:

Ti obsah Ti (%),

TL obsah těkavých láték (%),

SpO je spotřeba oleje (g/100 g pigmentu),

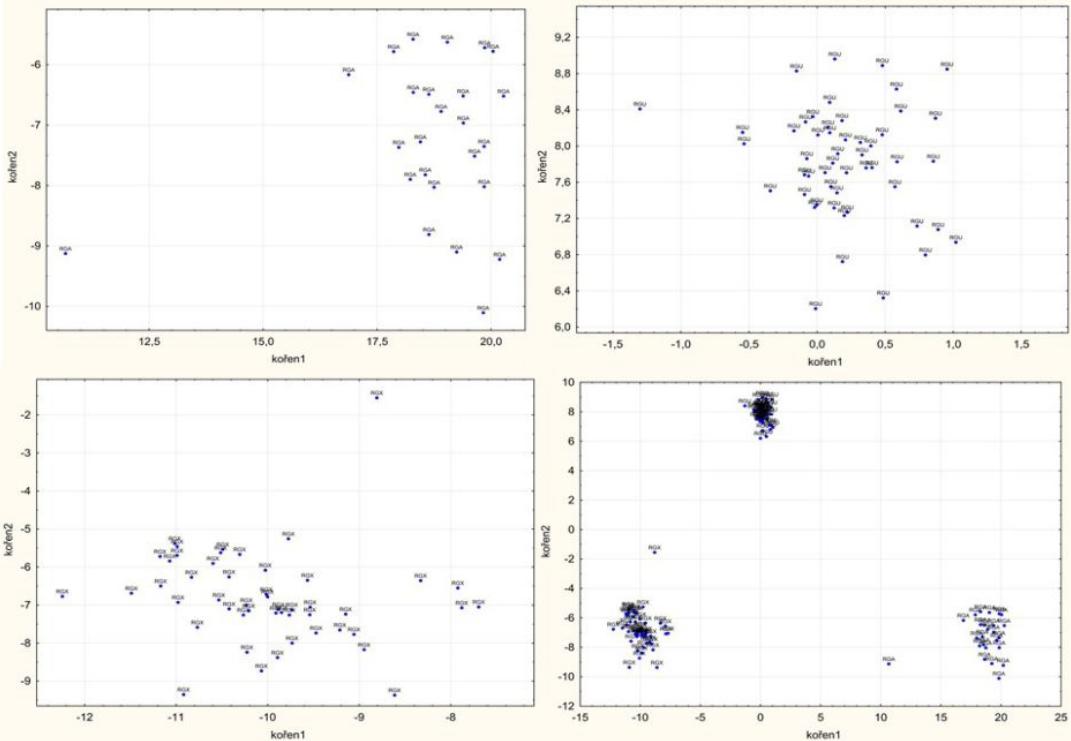
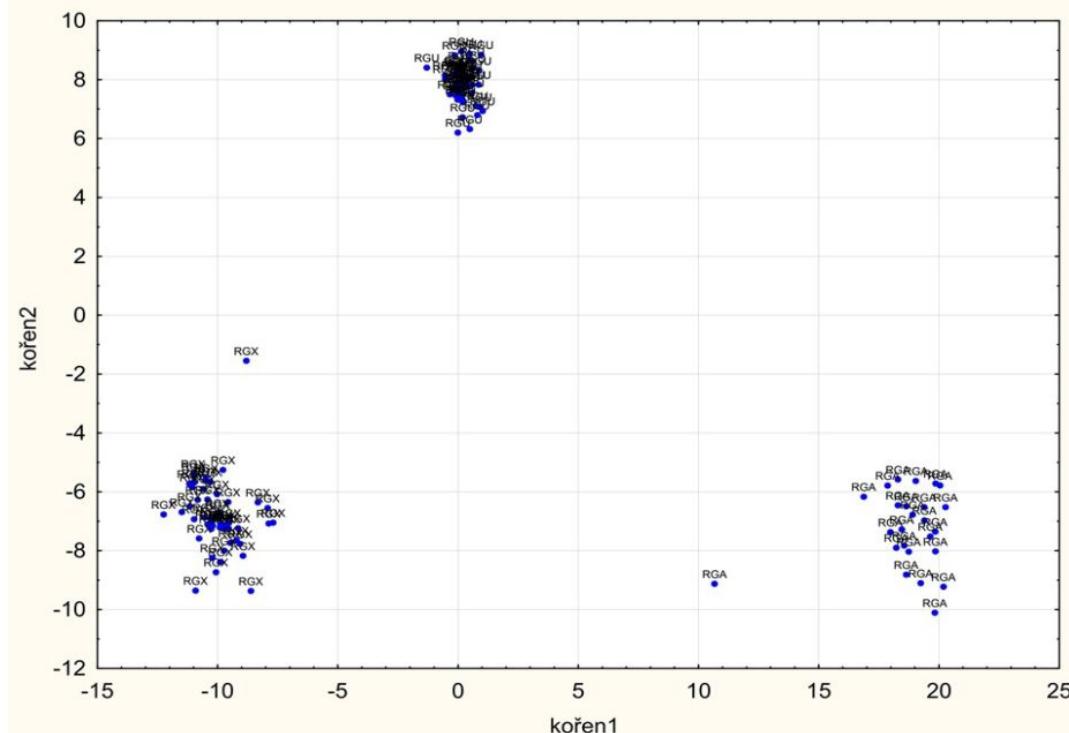
Barv značí barvivost,

Podt značí podtón,

Si značí obsah Si (%),

Al značí obsah Al (%).

ID	TI	TL	SpO	Barv	Podt	Si	AI	Klas
1	93.78	0.5	24.2	1870	10	2.174	3.511	RGA
.....
144	98.21	0.2	19	1860	13	0.354	1.014	RGX



Úloha B23 Porovnání analýzy krve diabetiků a zdravých jedinců

Jsou porovnány výsledky rozboru krve zdravých jedinců a dvou skupin diabetiků. Postavte soubor diskriminačních funkcí, které mohou předpovědět třídu a který rozlišuje mezi třídami podle hodnot ostatních kvantitativních proměnných.

○ **Data:** Výběr DIABETES se týká vyšetření 144 jedinců pro 6 znaků:

i (ID) identifikační číslo pacienta,

x1 (RELWT) značí relativní hmotnost pacienta,

x2 (GLUFAST) značí půst plasmové glukózy,

x3 (GLUTEST) značí prověrku plasmové glukózy,

x4 (INSTEST) značí plasmový inzulin v průběhu prověrky, 5 (SSTEST) značí výšku inzulinu v krvi po skončení prověrky.

x5 (SSPG) značí ustálený rovnovážný stav plazmovej glukózy, x6 (GROUP) - výklik je uvedený v dôbute.

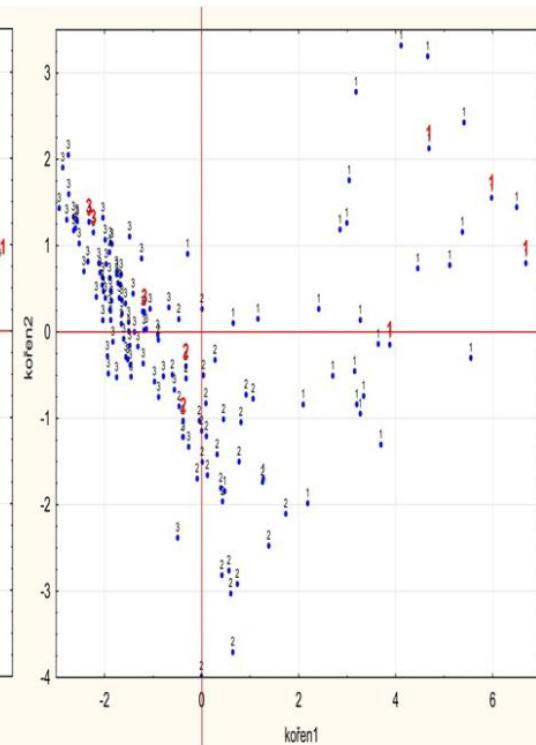
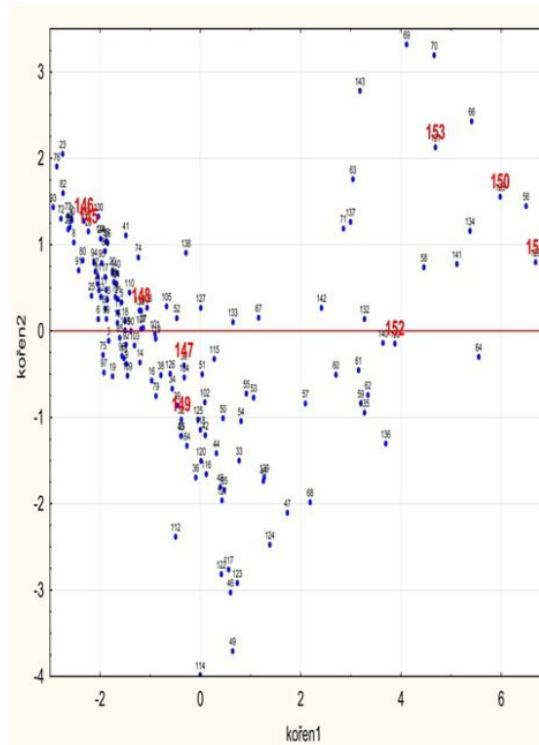
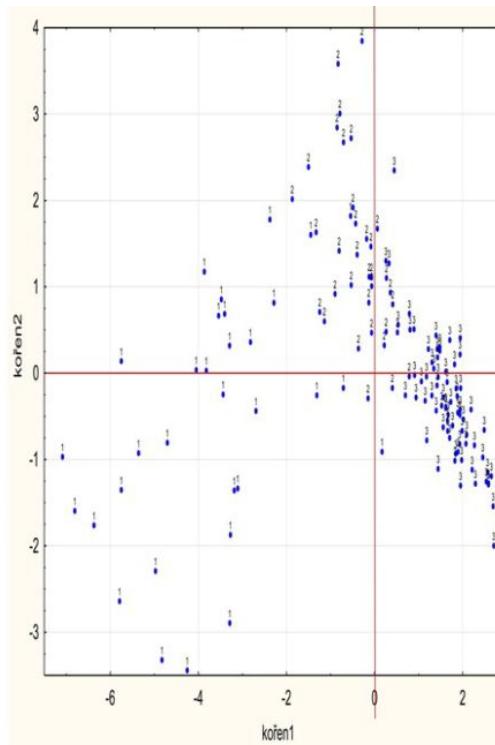
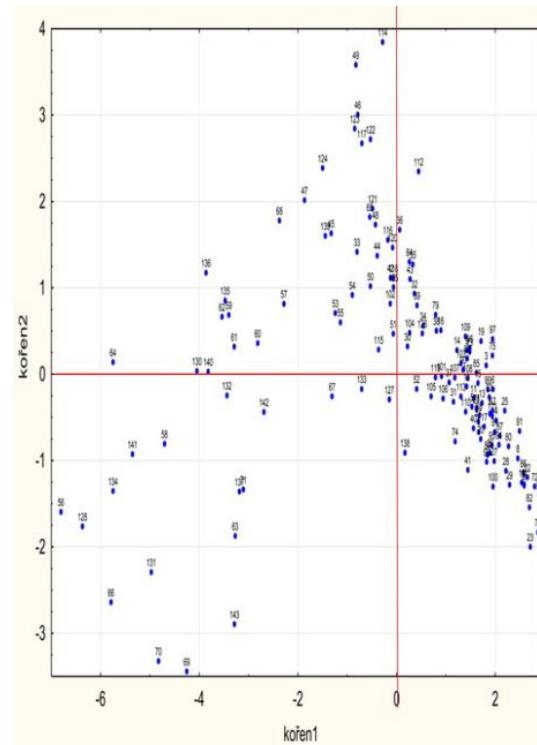
x6 (GROUP) znaci klinickou skupinu diabetes:

1 je zretelny, vylozeny diabetik,
2 je obrovsky.

2 je chemicky,
3 je normální -

3 Je normální zdravý člověk.

<i>i</i>	<i>x</i> 1	<i>x</i> 2	<i>x</i> 3	<i>x</i> 4	<i>x</i> 5	<i>x</i> 6
1	0.81	80	356	124	55	3
...
144	1.11	328	1246	124	442	1



Úloha B40 Vliv vlákninové diety ve snídaňových lupínkách na nadváhu žen

Ženy konzumují lupinky různých typů, např. otrubové lupinky, gumové, obojí a konečně i s kontrolním druhem lupinek bez vlákniny k snídani tolik, na kolik mají hlad. Kontingenční tabulka ukazuje vztah 4 různých druhů lupinek a 4 hladin nevolnosti z přesycení. χ^2 -test může otestovat, zda je přesycení nezávislé na druhu lupinek.

U diskriminační analýzy vezměte za závisle proměnnou údaje o stupni přesycení x_5 (BLOAT) a ostatní znaky pak za nezávisle diskriminátory.

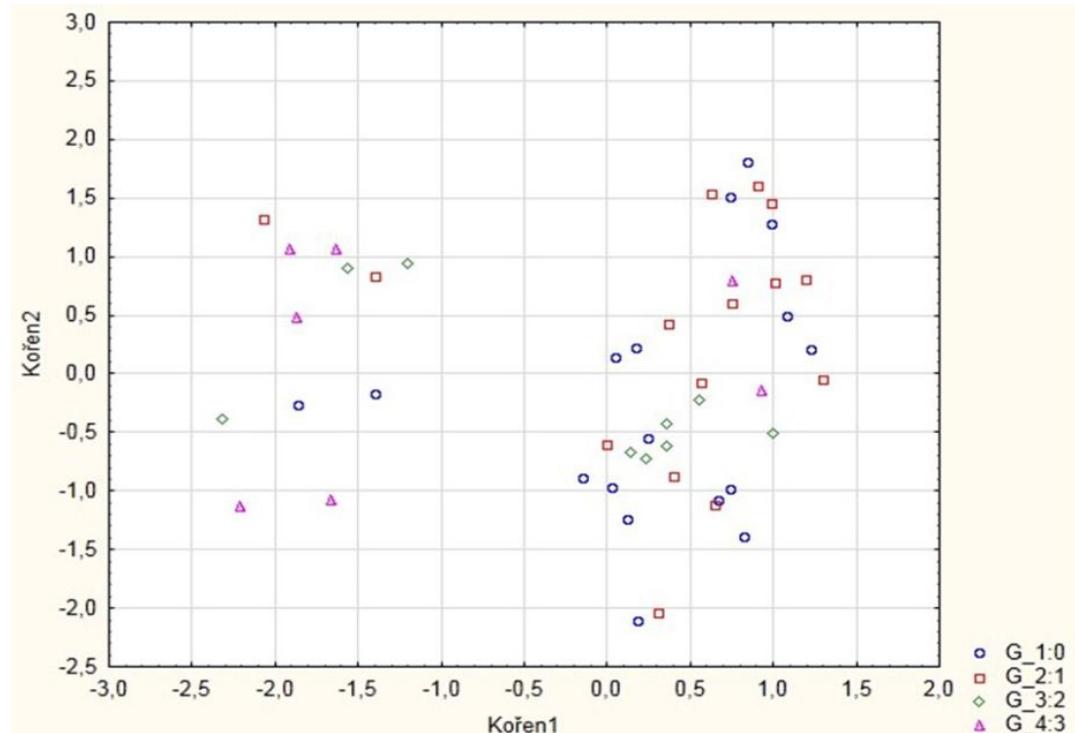
Data: Celkem 12 žen v řádcích bylo testováno na 3 diety ve sloupcích a na kontrolní dietu. Před každým jídlem otylkly jedly lupinky a) s otrubami, b) s gumovými vlákny, c) s kombinací obou, a konečně d) bez vláken. Celkem bylo provedeno 48 pokusů a užito 5 sledovaných znaků.

Datový výběr CRACKER obsahuje:

- i (ID) pořadové číslo ženy,
- x_1 (CRACKER) značící typ vlákna v lupínkách,
- x_2 (DIET) značí jednu ze 4 diet čili typu lupinek,
- x_3 (IDFEM) index sledované ženy,
- x_4 (DIGESTED) značí strávené kalorie.
- x_5 (BLOAT) značí stupeň přesycení a nadýmání po jídle: 0 žádný, 1 malý, 2 střední a 3 vysoký.

i	x_1	x_2	x_3	x_4	x_5
1	control	1	3	1772.84	0

12	bran	4	12	2287.52	0



Úloha E22 Zdravotní klasifikace 77 druhů obilninových lupinek k snídani

Zdravotní norma u lupinek požaduje, že dospělí by měli denně zkonzumovat ne více než 30% kalorií ve formě tuku, muži potřebují okolo 63 g bílkovin a ženy 50 g bílkovin a zbytek poskytnou uhlovodíky (1 cal = 4.184 joulu). 1 g tuku obsahuje asi 9 kalorií, bílkoviny a uhlovodíky 4 kalorie na 1 g. Vhodná dieta by měla obsahovat 20 - 35 g dietní vlákniny. Níže analyzovaná data obsahují počet kalorií na 1 porci, gramy bílkovin a tuků, mg Na⁺ a K⁺iontů, gramy vlákniny, uhlovodíků a cukru, typické procento FDA RDA vitaminů, hmotnost jedné porce a počet šálků na 1 porci podávanou. Data obsahují umístění na regále v prodejně: nahore, ve středu či dole u země.

O Data: Výběr CEREALS obsahuje 77 druhů obilninových lupinek v rádcích a 15 znaků:

i (ID) je index druhu lupinek, j (J) je název druhu obilninových lupinek,

x1 (MFR) značí výrobce lupinek: A je American Home Food Products; G je General Mills; K je Kelloggs; N je Nabisco; P je Post; Q je Quaker Oats; R je Ralston Purina,

x2 (TYPE) značí formu v jaké je lupinka konzumována: C je studená, H je horká,

x3 (CALORIES) značí počet kalorií jedné porce,

x4 (PROTEIN) značí obsah bílkovin v gramech v jedné porci,

x5 (FAT) značí obsah tuku v gramech v jedné porci,

x6 (SODIUM) značí obsah sodných iontů v miligramech v jedné porci,

x7 (FIBER) značí obsah dietní vlákniny v jedné porci,

x8 (CH) značí obsah komplexních uhlovodíků v gramech,

x9 (SUGARS) značí obsah cukru v gramech v jedné porci,

x10 (POTASS) značí obsah draselných iontů v miligramech v jedné porci,

x11 (VITAMINS) značí obsah vitaminů a minerálů v jedné porci (0, 25, nebo 100) ukazuje typické % doporučených FDA,

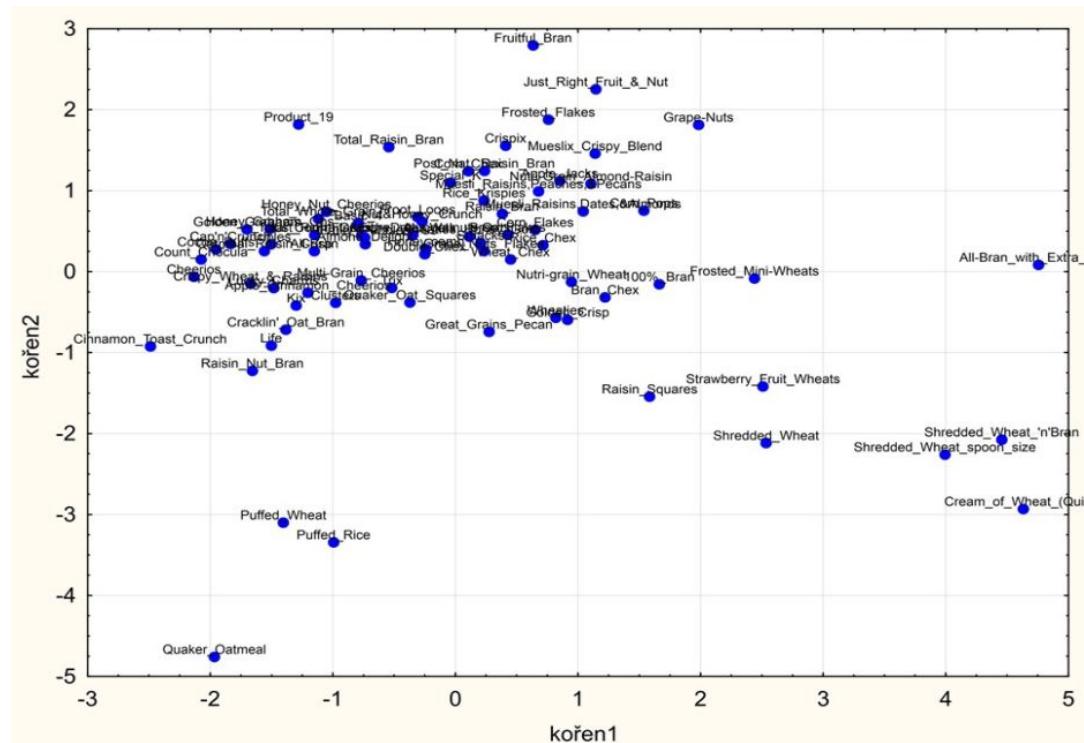
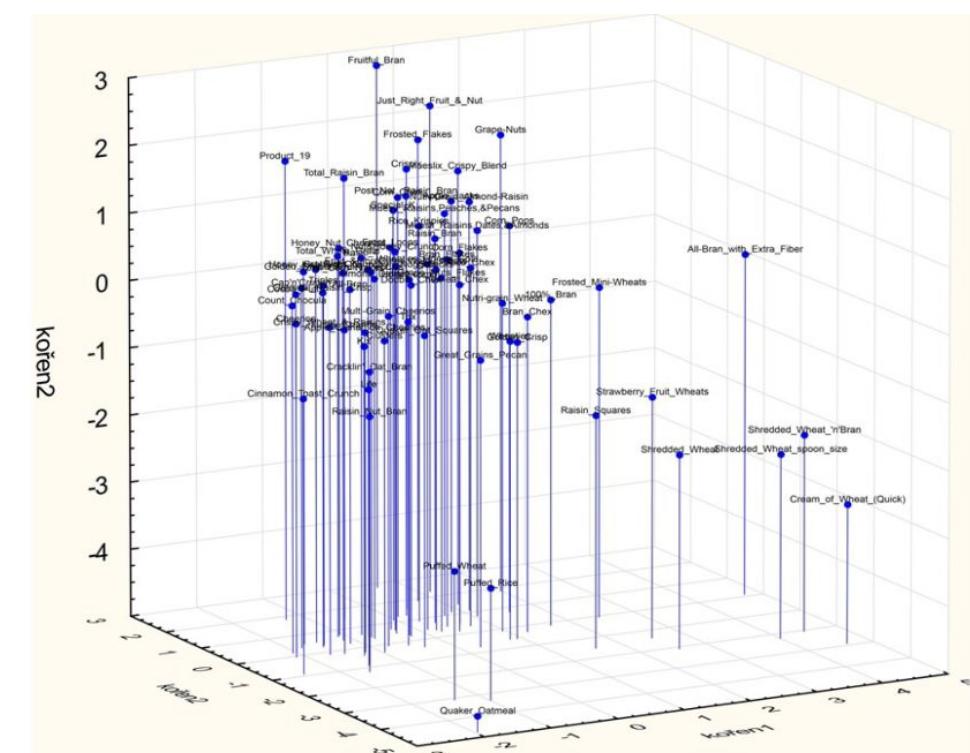
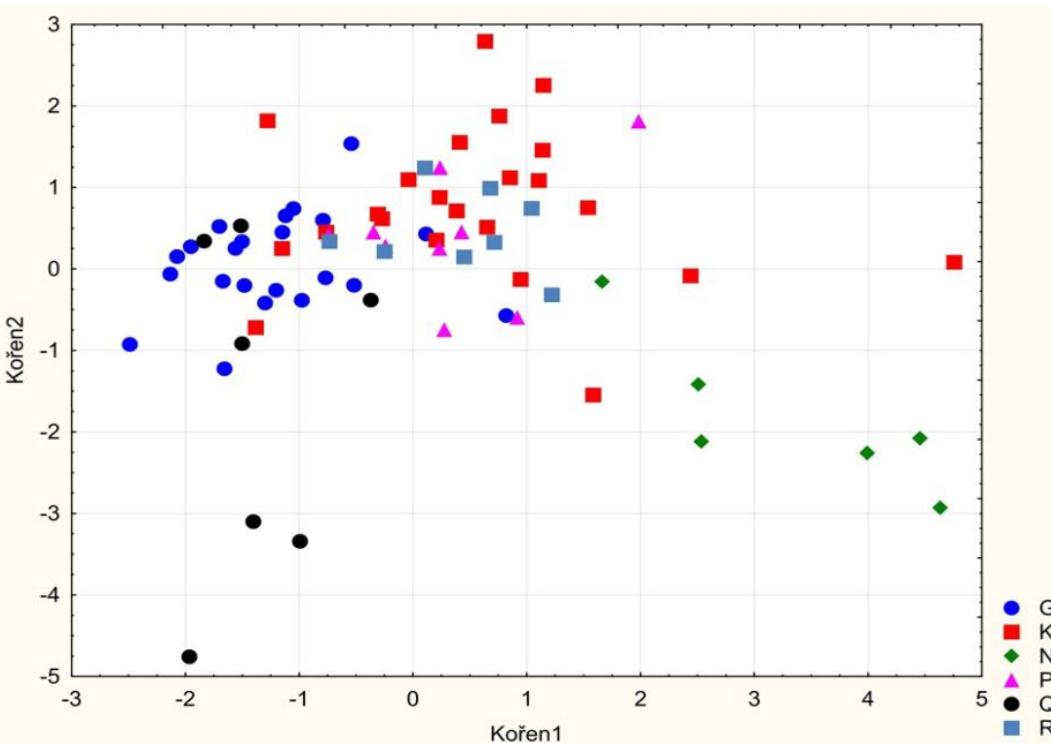
x12 (SHELF) značí umístění na regále, jehož výška je číslovaná směrem od země 1 (nejníže), 2, nebo 3 (nejvýše),

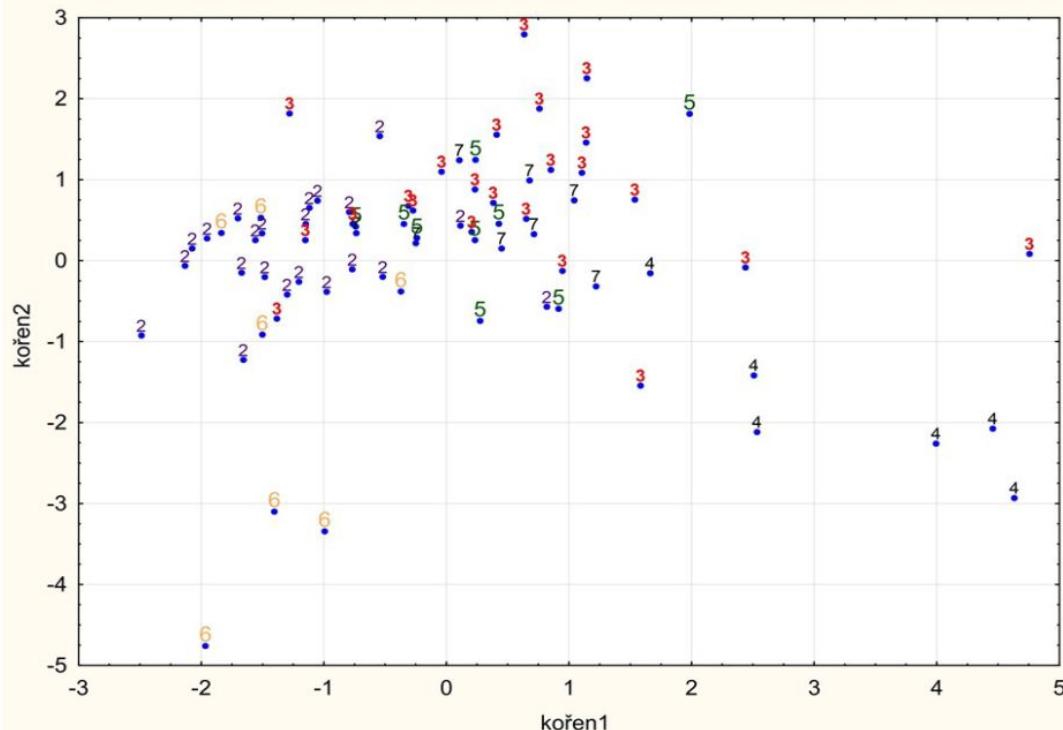
x13 (WEIGHT) značí hmotnost jedné porce v uncích,

x14 (CUPS) značí počet šálků v jedné porci,

x15 (RATING) značí hodnocení, ocenění druhu lupinek.

Císlo-1 značí chybějící numerickou informaci.





Kořeny odstraněny	Test chí-kvadrát po odstranění post. kořenů (E22)					
	Vlastní číslo	Kan. R	Wilk. Lambda	Chi-kv.	sv	p-hodn.
0	1,824023	0,803676	0,100675	149,2308	70	0,000000
1	0,971859	0,702043	0,284308	81,7502	52	0,005270
2	0,428362	0,547629	0,560616	37,6167	36	0,395068
3	0,199115	0,407495	0,800763	14,4424	22	0,885038
4	0,041442	0,199482	0,960207	2,6394	10	0,988685

Proměnná	Klasifikační funkce; grupovací : MFR (E22)				
	G_1:2 p=,.28947	G_2:3 p=,.30263	G_3:4 p=,.07895	G_4:5 p=,.11842	G_5:6 p=,.10526
TYPE	431	429	443	429	431
CALORIES	1444741	1444724	1444645	1444730	1444725
PROTEIN	-21234981	-21234726	-21233572	-21234813	-21234741
FAT	10976930	10976795	10976200	10976840	10976805
SODIUM	353534	353530	353511	353531	353530
FIBER	-22336642	-22336371	-22335156	-22336463	-22336389
CH	-7087424	-7087338	-7086952	-7087368	-7087344
SUGARS	4703311	4703254	4702999	4703273	4703257
POTASS	220361	220359	220347	220360	220359
VITAMINS	332383	332379	332361	332380	332379
SHELF	1966	1966	1963	1966	1967
WEIGHT	41729	41722	41718	41721	41730
CUPS	-5056	-5058	-5059	-5059	-5054
RATING	6487518	6487440	6487088	6487467	6487445
Konstant	-178184354	-178180076	-178160726	-178181531	-178180305

Úloha B77 Rozlišení mono-, di- a trifazické hormonální antikoncepce u žen

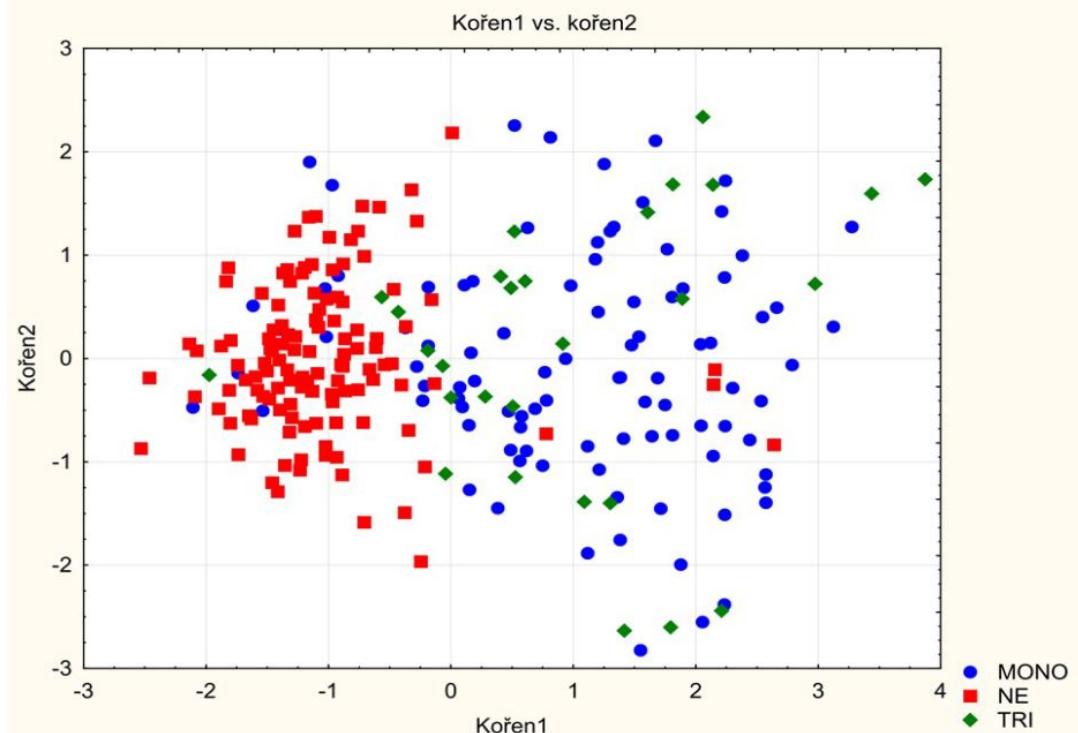
247 žen se dělí do tří tříd podle užívání hormonální antikoncepce.

V 1. třídě je 123 žen, které neužívají hormonální antikoncepci (**HA = NE**) – zavisle p., ve 2. třídě je 152 žen užívající monofazickou (**HA = MONO**) antikoncepci, ve 3. třídě je 95 žen, které užívají trifazickou hormonální antikoncepci (**HA = TRI**).

Cílem diskriminační analýzy je zjistit, zda lze na základě diskriminátorů zde steroidních hormonů a proteinem přenášejícím steroidní hormony (**SHBG**) rozpoznat ženy neužívající a užívající hormonální antikoncepci, a dále rozpozнат mono- a trifazickou antikoncepci, lišící se dávkováním účinné látky.

○ Data: Zdrojová data s popisem znaků ve sloupcích 5 diskriminátory (**Kortizol, Testosteron, SHBG, DHEAS a DHEAS**).

HA	Kortisol	SHBG	DHEAS	DHEA	Testosteron
i	x1	x2	x3	x4	x5
MONO	1383	85.2	5.68	46.28	1.62
....
TRI	620	86.5	4.16	12.02	1.68



Kořeny odstraněny	Test chí-kvadrát po odstranění post. kořenů (B68-B77)					
	Vlastní číslo	Kan. R	Wilk. Lambda	Chi-kv.	sv	p-hodn.
0	1,087462	0,721768	0,474520	180,3991	10	0,000000
1	0,009547	0,097245	0,990543	2,2994	4	0,680877

Skup.	Průměry kan. proměnných (B68-B77)	
	Kořen1	Kořen2
MONO	1,02516	-0,076571
NE	-1,04063	0,000854
TRI	1,05541	0,247217

Proměnná	Standardiz. koeficienty (B68-B77) pro kanonické proměnné	
	Kořen1	Kořen2
B77x1	0,545676	0,915162
B77x2	0,723332	-0,865965
B77x3	0,204730	-0,234211
B77x4	-0,277455	-0,206162
B77x5	-0,072968	0,261355
Vlastní	1,087462	0,009547
KumPodíl	0,991297	1,000000

Proměnná	Faktorová strukturní matice (B68-B77) Korelační proměnné - Kanonické kořeny (vnitřní korelace)	
	Kořen1	Kořen2
B77x1	0,705334	0,637291
B77x2	0,840542	-0,458747
B77x3	-0,162699	0,016145
B77x4	-0,157594	0,037997
B77x5	0,045107	0,119113

Úloha E19 Klasifikace smrku ztepilého z pokusné plochy v Orlických horách

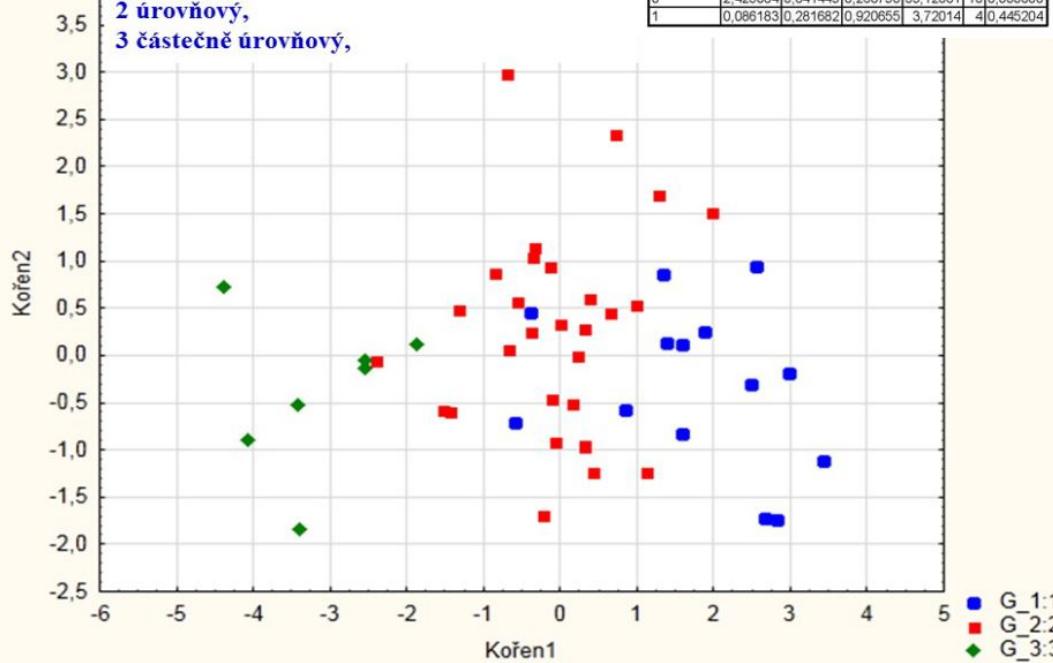
Při klasifikaci 50 stromů smrku ztepilého (*Picea abies L.*) z pokusné plochy v Orlických horách byl vyšetřován dle 6 charakteristik každý strom zvlášť.

○ Data: Výběr STROMY:

i (ID) index stromu,
 x1 (D) značí výčetní tloušťku stromu v cm, měřenou ve výšce 1,3 m nad zemí,
 x2 (RTP) značí roční tloušťkový přírůstek v cm (tamtéž),
 x3 (H) značí výšku stromu v m,
x4 (KRAFT) značí Kraftovu klasifikaci stromů v porostu: 1 předrůstavý, 2 úrovňový, 3 částečně úrovňový,
 x5 (ZDRAV) značí zdravotní stav: 1 olistění 90 – 100 %, 2 olistění 70 – 80 %, 3 olistění pod 60 %),
 x6 (RAŠ) značí rašení letorostů: 1 pozdní, 2 střední, 3 časně.

<i>i</i>	x1	x2	x3	x4	x5	x6
1	8.9	0.8	4.60	2	1	2
...
50	7.0	0.5	5.80	2	3	3

Kraftovu klasifikaci stromů v porostu: 1 předrůstavý, 2 úrovňový, 3 částečně úrovňový,



Proměnná	Test chí-kvadrát po odstranění post. kořenů (E01-E19)					
	Vlastní číslo	Kan. R	Wilk. Lambda	Chi-kv.	sv	p-hodn.
0	2,425084	0,841449	0,268798	59,12081	10	0,000000
1	0,086183	0,281682	0,920655	3,72014	4	0,445204

Proměnná	Průměry kan. proměnných (E01-E19)					
	Kořen1	Kořen2	G_1:1	G_2:2	G_3:3	p=,14000
E19x1	0,806638	0,521042	9,1286	7,8943	4,7326	
E19x2	0,277166	0,507606	-12,7102	-9,8558	-7,5089	
E19x3	0,653265	-0,292438	10,0572	8,4413	7,5413	
E19x5	0,272048	-0,523211	7,4350	5,8572	4,0769	
E19x6	0,033093	0,174083	2,0369	2,3188	2,1130	
Konstant	-84,6280	-62,2406				-35,8244

Skup.	Klasifikační funkce; grupovací : E19x4 (E01-E19)			
	G_1:1	G_2:2	G_3:3	p=,14000
E19x1	9,1286	7,8943	4,7326	
E19x2	-12,7102	-9,8558	-7,5089	
E19x3	10,0572	8,4413	7,5413	
E19x5	7,4350	5,8572	4,0769	
E19x6	2,0369	2,3188	2,1130	
Konstant	-84,6280	-62,2406	-35,8244	

Proměnná	Standardiz. koeficienty (E01-E19) pro kanonické proměnné			
	Kořen1	Kořen2	G_1:1	G_2:2
E19x1	0,857251	0,679610		
E19x2	-0,197606	0,291570		
E19x3	0,369694	-0,827552		
E19x5	0,449677	-0,368888		
E19x6	-0,017054	0,361201		
Vlastní	2,425084	0,086183		
KumPodíl	0,965681	1,000000		

