

# Rozpoznávanie obrazcov

## šk.r. 2019-20

Štatistika

Doc. RNDr. Milan Ftáčnik, CSc.

# Rekapitulácia

- Definícia pravdepodobnosti a jej vlastnosti
- Podmienená pravdepodobnosť
- Bayesov vzorec
- Náhodná premenná, distribučná funkcia a funkcia hustoty pravdepodobnosti
- Rozdelenia pravdepodobnosti (binomické, rovnomerné, normálne)
- Číselné charakteristiky náhodnej premennej

# Štatistika

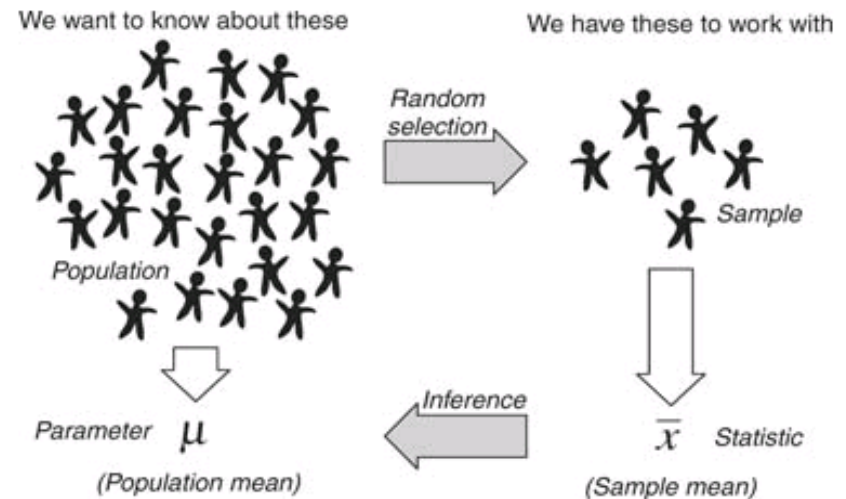
- Odhad parametrov rozdelení
- Testovanie hypotéz
- **Náhodný výber** je náhodný vektor  $(X_1, X_2, \dots, X_n)$ , pre ktorý platí, že náhodné premenné  $X_i$  majú rovnaké rozdelenie pravdepodobnosti a sú navzájom nezávislé
- Súbor všetkých jednotiek, ktoré skúmame, nazývame ***základný súbor***

# Štatistika II

- Súbor vybraných jednotiek nazývame **výberový súbor**, alebo tiež náhodný výber zo základného súboru
- Parameter rozdelenia – popisuje populáciu (základný súbor) - nepoznáme jeho hodnotu
- Funkcia jednej alebo viac náhodných premenných, ktorá nezávisí na hodnotách neznámych parametrov sa nazýva štatistika

# Štatistika III

- Štatistiku vypočítame z náhodného výberu (odhad parametra, výberová charakteristika) – napr.  $\mu$  a  $\bar{X}$
- $\mu$  je skutočná stredná hodnota populácie
- $\bar{X}$  je stredná hodnota vo výberovom súbore, pomocou ktorej odhadneme skutočnú strednú hodnotu



# Bodové odhady

- Výberový priemer  $\bar{X}$  :  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

- Výberový rozptyl

$$S^2 : S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- Výberová smerodajná odchýlka  $S$  :  $S = \sqrt{S^2}$

- Výberová kovariancia

$$S_{XY} : S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) =$$
$$\frac{n \sum_{i=1}^n X_i Y_i - \sum_{i=1}^n X_i \sum_{i=1}^n Y_i}{n(n-1)}$$

# Bodové odhady II

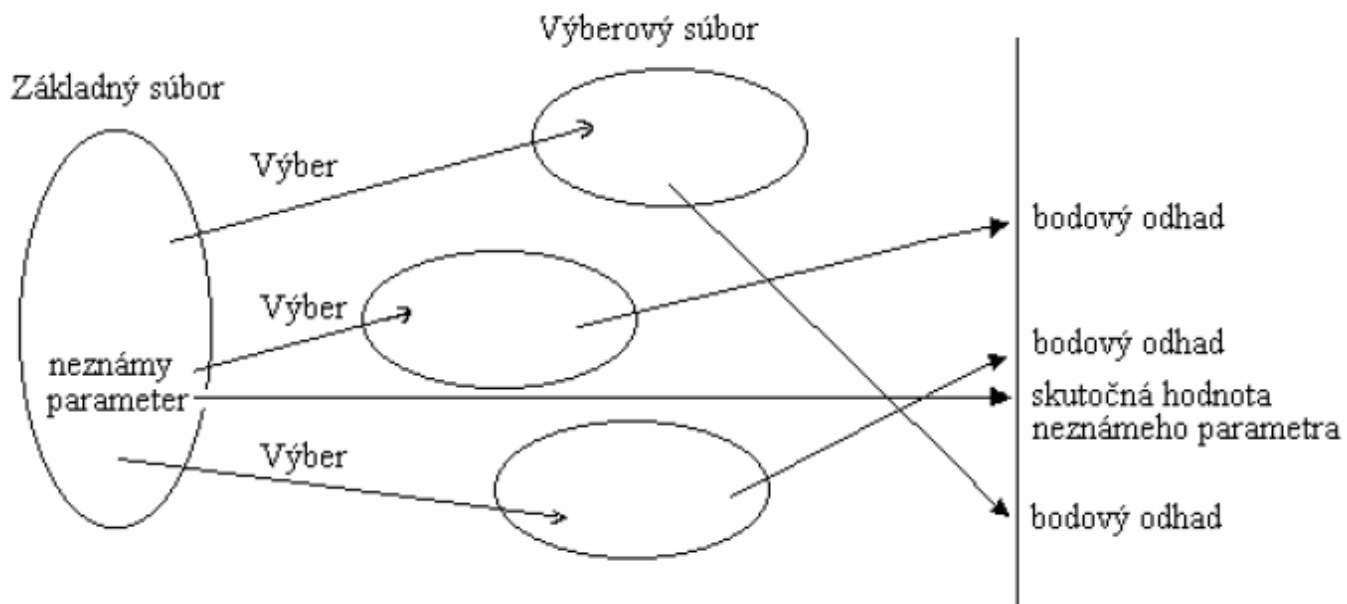
- Všetko sú to funkcie veľkosti výberového súboru  $n$  a náhodné premenné
- Podľa zákona veľkých čísel platí

$$\lim_{n \rightarrow \infty} P(|\bar{X} - E(X)| > \varepsilon) = 0$$

- Priemer z  $N(\mu, \sigma) \sim N(\mu, \frac{\sigma}{\sqrt{n}})$
- Rozptyl z  $N(\mu, \sigma) \sim \chi^2(n - 1)$

# Bodové odhady III

- Každý výber – iný bodový odhad
- Pravdepodobnosť, že určíme parameter náhodnej veličiny presne je nulová
- Pri spojitej premennej – pre interval vieme pravdepodobnosť odhadu






# Intervalový odhad

## Interval spoľahlivosti

- $P(G_D < \theta < G_H) = 1 - \alpha$
- $(G_D, G_H)$  – interval spoľahlivosti
- $1 - \alpha$  – koeficient spoľahlivosti
- $\theta$  – skutočná hodnota parametra

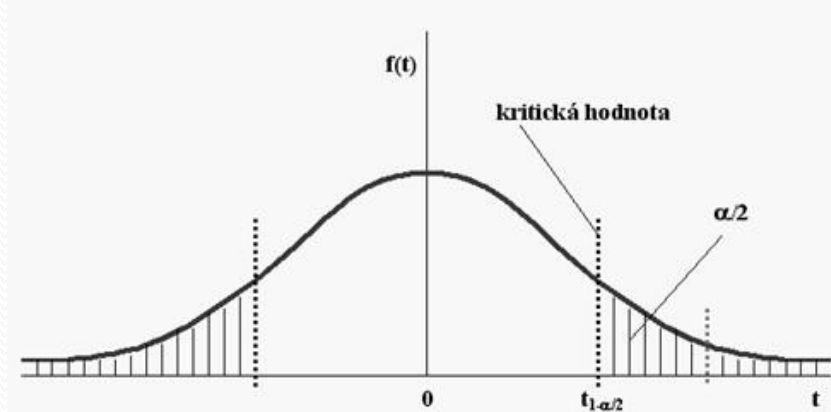


# Intervalový odhad II

- Intervalový odhad parametra  $\theta$  so spoľahlivosťou  $(1-\alpha)$ , to je  $100 \cdot (1-\alpha)$  percentný interval spoľahlivosti
- Hranice  $G_D$  a  $G_H$  sú funkcie výberovej štatistiky, pomocou ktorej intervalový odhad konštruujeme
- O výberovej štatistike vieme, aké má pravdepodobnostné rozdelenie, čiže poznáme jej funkciu hustoty pravdepodobnosti

# Príklad

- Intervalový odhad strednej hodnoty normálneho rozdelenia, keď poznáme hodnotu  $\sigma$
- Štatistika  $U = \frac{\bar{X} - \mu}{\sigma} \cdot \sqrt{n} \sim N(0,1)$
- Kritická hodnota normálneho rozdelenia  $N(0,1)$  pre dané  $\alpha$  sa označuje  $u_\alpha$



$$\begin{aligned} 1 - \alpha &= P(-u_\alpha \leq U \leq u_\alpha) = P\left(-u_\alpha \leq \frac{\bar{X} - \mu}{\sigma} \cdot \sqrt{n} \leq u_\alpha\right) = \\ &= P\left(\bar{X} - u_\alpha \cdot \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + u_\alpha \cdot \frac{\sigma}{\sqrt{n}}\right). \end{aligned}$$

$G_H$

# Príklad II

- náhodný výber 100 výrobkov
- priemerná váha 2,2 kg
- smerodajná odchýlka váhy výrobkov  $\sigma = 0,6$  kg
- Určite 95-percentný obojstranný interval spoľahlivosti strednej hodnoty váhy

$$\left\langle \bar{x} - u_{\alpha} \cdot \frac{\sigma}{\sqrt{n}}; \bar{x} + u_{\alpha} \cdot \frac{\sigma}{\sqrt{n}} \right\rangle = \left\langle 2,2 - 1,96 \cdot \frac{0,6}{10}; 2,2 + 1,96 \cdot \frac{0,6}{10} \right\rangle = \langle 2,08; 2,31 \rangle$$

$$X \sim N(0,1), P(|X| > u_{\alpha}) = \alpha$$

$\alpha$	0,01	0,02	0,05	0,1	0,2
$u_{\alpha}$	2,5758	2,3263	1,9599	1,6448	1,299

Rozp

# Špeciálne (výberové) rozdelenia

- $\chi^2$  (chí kvadrát) rozdelenie
- Studentovo t - rozdelenie
- Fischerovo F – rozdelenie
- Používajú sa pri určovaní odhadov a intervalových odhadov neznámych parametrov a pri testovaní štatistických hypotéz
- Majú tabuľkovo definované kritické hodnoty

# Špeciálne (výberové) rozdelenia II

- $\chi_n^2$  (Chí kvadrát) s  $n$  stupňami voľnosti

$$X = X_1^2 + X_2^2 + \dots + X_n^2 \quad X_i \sim N(0,1)$$

- Ak máme náhodnú premennú  $X \sim N(0,1)$ , potom náhodná premenná  $Y = X^2$  má  $\chi^2$  - rozdelenie s 1-stupňom voľnosti  $Y \sim \chi^2(1)$
- Ak máme  $k$  náhodných premenných s rozdelením  $X_i \sim N(0,1)$ , tak náhodná premenná = súčet ich druhých mocnín má rozdelenie  $\chi^2(k)$

# Špeciálne (výberové) rozdelenia III

- Stredná hodnota Chí kvadrát s  $n$  stupňami voľnosti je  $n$  a rozptyl  $2n$
- Graf hustoty tohto rozdelenia je pre malé  $n$  nesymetrický, ale pre väčšie hodnoty je hustota premennej tvaru  $\frac{X-n}{\sqrt{2n}}$
- Pre hodnoty  $n$  väčšie ako 30 môžeme hustotu aproximovať hustotou normovaného normálneho rozdelenia  $N(0,1)$

# Špeciálne (výberové) rozdelenia IV

Studentove  $t$ -rozdelenie - náhodnú premennú možno vyjadriť pomocou dvoch iných náhodných premenných, z ktorých jedna má normálne rozdelenie a druhá chí kvadrát

$$\frac{X}{\sqrt{\frac{Y}{N}}} \quad X \sim N(0,1) \text{ a } Y \sim \chi_n^2$$

Studentove rozdelenie sa používa pri testovaní hypotéz s malým počtom vzoriek do 30



# Špeciálne (výberové) rozdelenia V

Fischerovo  $F$ -rozdelenie – dá sa vyjadriť pomocou dvoch nezávislých náhodných premenných, ktoré majú chí kvadrát rozdelenie, s tým, že má  $m$  a  $n$  stupňov voľnosti

$$\frac{\frac{\bar{X}}{\frac{n}{Y}}}{\bar{m}} \quad X \sim \chi_n^2 \text{ a } Y \sim \chi_m^2$$

# Testovanie hypotéz

- Hypotéza = tvrdenie o základnom súbore, ktoré môžeme overiť štatistickými metódami na základe údajov výberového súboru

$$H_0: \theta = \theta_0$$

- Každá hypotéza implikuje svoj protiklad alebo alternatívu

- $H_1: \theta = \theta_1$

$$H_1: \theta > \theta_0$$

- $H_1: \theta < \theta_0$

$$H_1: \theta \neq \theta_0$$

# Čo rieši testovanie hypotéz?

- Je vhodné zamietnuť testovanú - tzv. *nulovú hypotézu*  $H_0$  - v prospech *alternatívnej hypotézy*  $H_1$  alebo nie?
- Na testovanie hypotézy  $H_0$  oproti hypotéze  $H_1$  použijeme vhodné *testovacie kritérium* (tzv. testovaciu štatistiku)  $g$ .
- Testovacia štatistika  $g$  je funkciou náhodného výberu

# Testovacie štatistiky

- Pre priemer

- 1. Ak poznáme  $\sigma$
- 2. Ak nepoznáme  $\sigma$  a  $n > 30$
- 3. Ak nepoznáme  $\sigma$  a  $n < 30$

$$u = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}}$$

1

$$u = \frac{\bar{x} - \mu_0}{\frac{s_1}{\sqrt{n}}}$$

2

$$t = \frac{\bar{x} - \mu_0}{\frac{s_1}{\sqrt{n}}}$$

3

# Testovacie štatistiky II

- Pre rozptyl

- 1. Test zhody s konštantou  $\sigma_0$
- 2. Test zhody dvoch rozptylov

$$\chi^2 = \frac{(n-1) \cdot s_1^2}{\sigma_0^2}$$

1

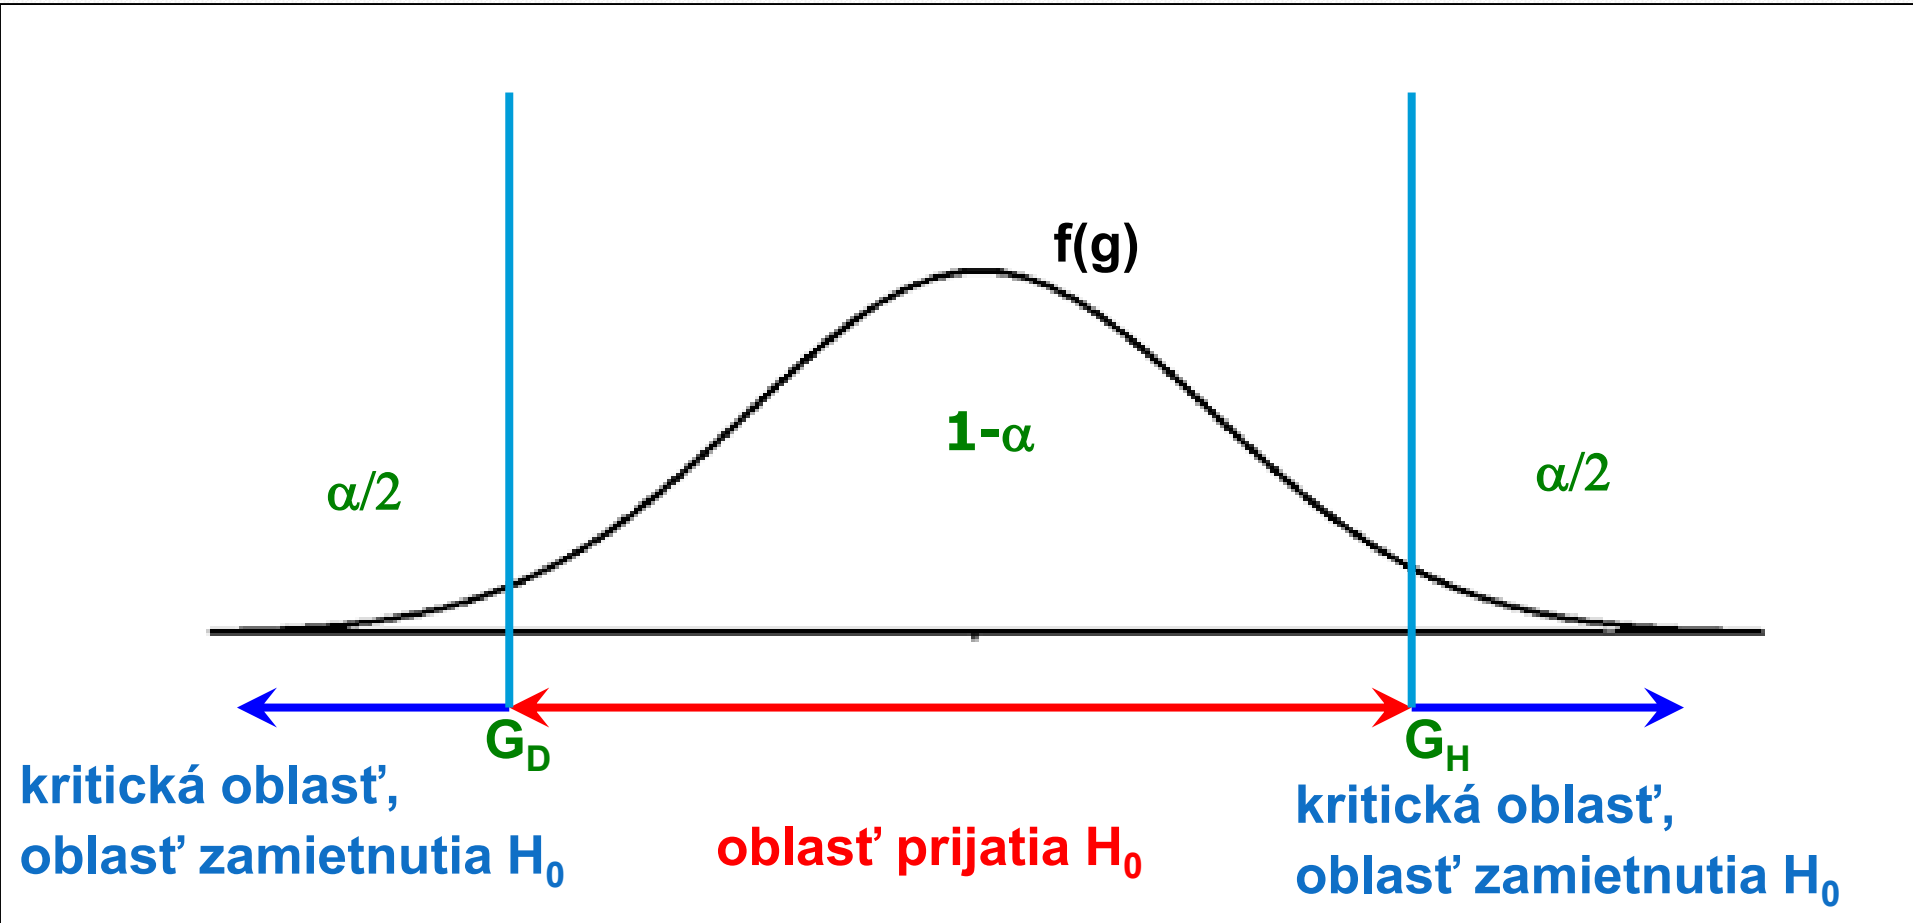
$$F = \frac{s_1^2}{s_2^2} \quad s_1^2 > s_2^2$$

2

# Použitie kritickej oblasti

- Ak hodnota testovacej štatistiky  $g$  padne do kritickej oblasti  $W_\alpha$ , zamietame testovanú hypotézu  $H_0$  a za správnu prijímame alternatívnu hypotézu  $H_1$
- Body oddeľujúce oblasť prijatia nulovej hypotézy od oblasti jej zamietnutia označujeme názvom *kritické hodnoty*

# Použitie kritickej oblasti II



# Postup

1. Formulujeme nulovú hypotézu  $H_0$  a jej alternatívnu hypotézu  $H_1$  (obojsstrannú alebo jednostrannú)
2. Zvolíme testovaciu štatistiku a určíme jej rozdelenie (väčšina má: normálne, t, F,  $\chi^2$ )
3. Vypočítame hodnotu testovacej štatistiky
4. Zvolíme úroveň (hladinu) významnosti  $\alpha$  (väčšinou 0,1; 0,05; 0,01; 0,001)



# Postup II

5. Nájdeme v tabuľkách kritické hodnoty (resp. kvantily) rozdelenia testovacej štatistiky pre zvolenú hodnotu  $\alpha$ , ktoré závisia od alternatívnej hypotézy  $H_1$  a vymedzujú kritickú oblasť
6. Urobíme konečné rozhodnutie, t.j. zamietneme alebo nezamietneme  $H_0$  na danej úrovni významnosti  $\alpha$  podľa toho, či sa vypočítaná hodnota nachádza alebo nenachádza v kritickej oblasti

# Možné výsledky

		<i>Skutočná situácia</i>	
		$H_0$ je pravda	$H_0$ nie je pravda
<i>Naše rozhodnutie</i>	$H_0$ je pravda	<i>správne rozhodnutie</i> pravdepodobnosť $1-\alpha$	<i>chyba typu II</i> pravdepodobnosť $\beta$
	$H_0$ nie je pravda	<i>chyba typu I</i> pravdepodobnosť $\alpha$ hladina významnosti	<i>správne rozhodnutie</i> pravdepodobnosť $1 - \beta$ sila testu

$$\alpha = P(g \in W_\alpha | H_0)$$


$$\beta = P(g \notin W_\alpha | H_1)$$

# P-hodnota

- Je to odhadovaná pravdepodobnosť zamietnutia pravdivej nulovej hypotézy
- Takže ak stačí rozhodnúť, či vyšiel test štatisticky významne, tak  $p$ -hodnota hovorí všetko potrebné nezávisle na tom, akú si zvolíme hladinu  $\alpha$ , dáva informáciu pre všetky hladiny
- Ak je  $p$ -hodnota  $\leq \alpha$ , zamietneme  $H_0$  na hladine významnosti  $\alpha$

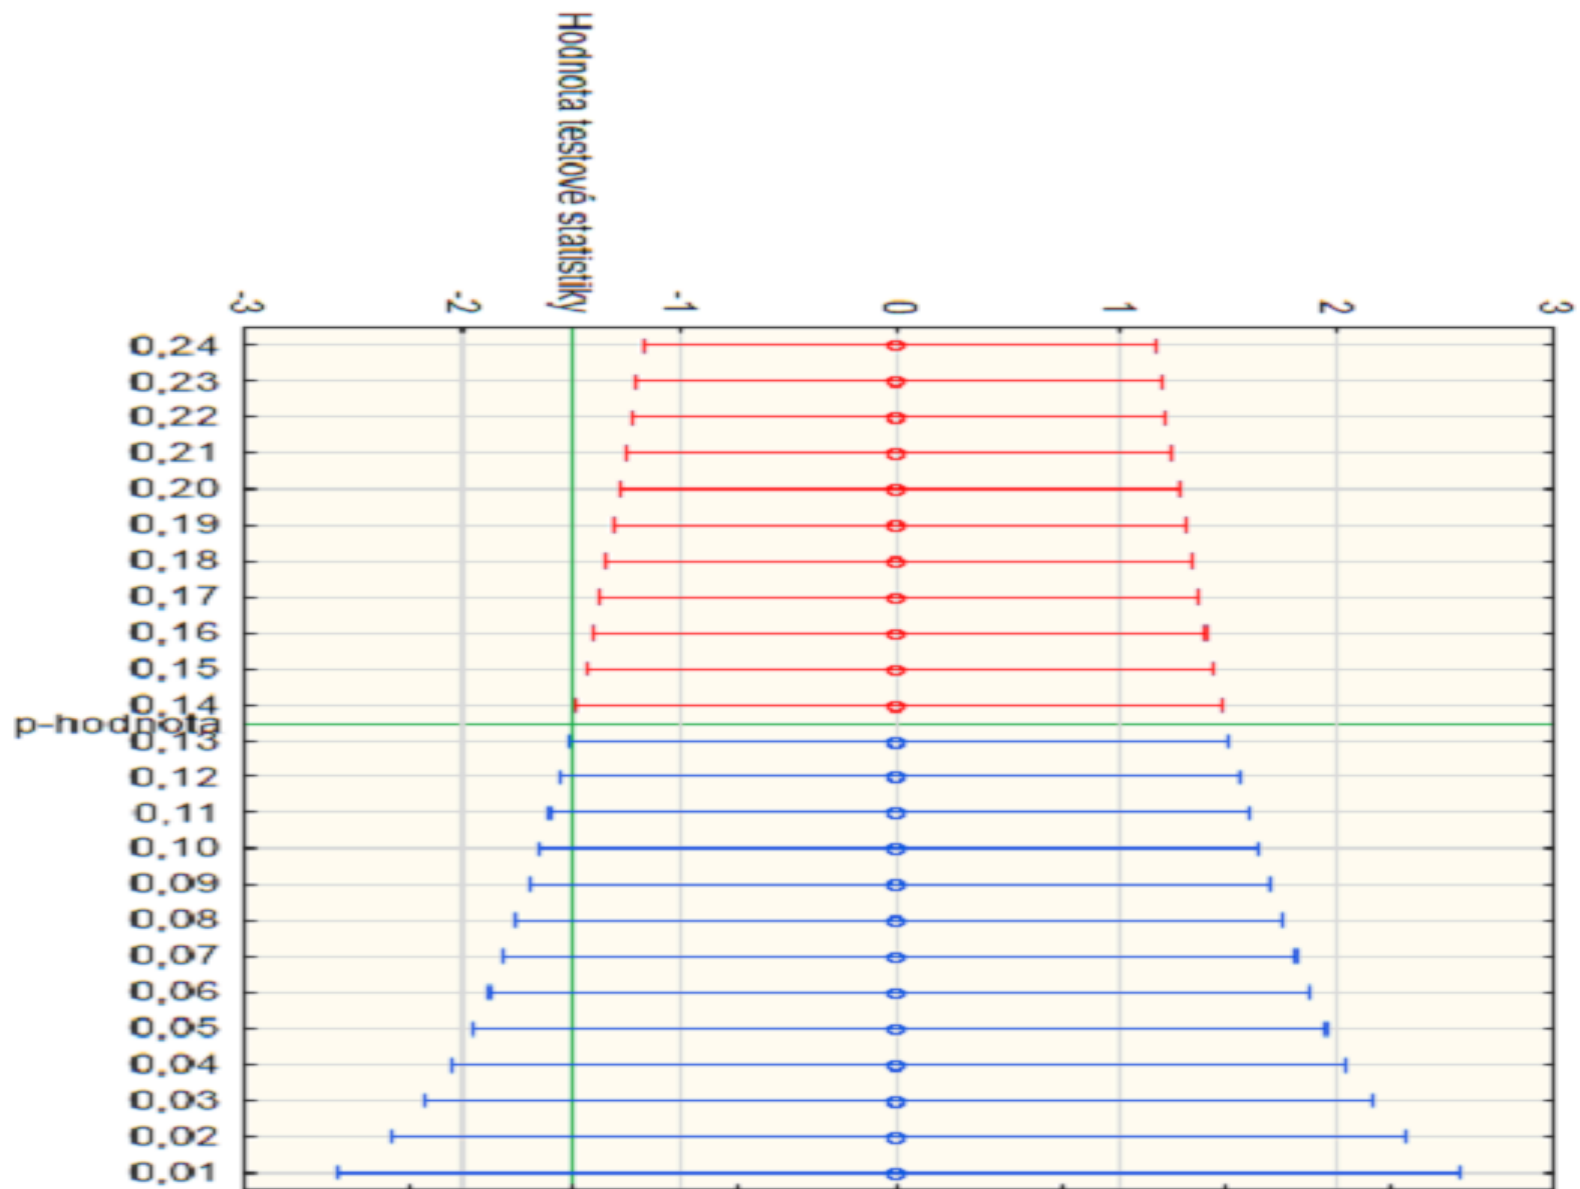
# Použitie $P$ -hodnota II

$$p = 2 \cdot \min\{P(g \leq -G), P(g \geq G)\}$$



- Ak je  $p$ -hodnota  $\leq \alpha$ , zamietneme  $H_0$  na hladine významnosti  $\alpha$

# Použitie $p$ -hodnoty II



# Príklad

- Náhodný výber 100 výrobkov ⟨2,08; 2,31⟩
- Priemerná váha 2,2 kg
- Smerodajná odchýlka váhy výrobkov  $\sigma = 0,6$  kg

- $H_0: \mu = 2$

- $H_1: \mu \neq 2$

$$X \sim N(0,1), P(|X| > u_\alpha) = \alpha$$

$\alpha$	0,01	0,02	0,05	0,1	0,2
$u_\alpha$	2,5758	2,3263	1,9599	1,6448	1,299

- Hladina významnosti  $\alpha = 0,05$


$$U = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} = \frac{2,2 - 2}{0,6} \sqrt{100} = \frac{10}{3} = 3,33 > 1,96$$

- Zamietame  $H_0$  na hladine významnosti 0,05

# Príklad II

Table 4—Standard Normal Distribution

$$U = 3,33$$



<i>z</i>	.09	.08	.07	.06	.05	.04	.03	.02	.01	.00
-3.4	.0002	.0003	.0003	.0003	.0003	.0003	.0003	.0003	.0003	.0003
-3.3	.0003	.0004	.0004	.0004	.0004	.0004	.0004	.0005	.0005	.0005
-3.2	.0005	.0005	.0005	.0006	.0006	.0006	.0006	.0006	.0007	.0007
-3.1	.0007	.0007	.0008	.0008	.0008	.0008	.0009	.0009	.0009	.0010
-3.0	.0010	.0010	.0011	.0011	.0011	.0012	.0012	.0013	.0013	.0013
-2.9	.0014	.0014	.0015	.0015	.0016	.0016	.0017	.0017	.0018	.0019

- $p = 0,0008 < 0,05$
- Zamietame hypotézu  $H_0$  na hladine 0,05

# Literatúra k štatistike

<http://mi21.vsb.cz/modul/vybrane-kapitoly-z-pravdepodobnosti>

**Dagmar Markechová, Beáta Stehlíková, Anna Tirpáková:** Štatistické metódy a ich aplikácie

**Javier R. Movellan:** Introduction to Probability Theory and Statistics

**Mirko Navara:** Pravdepodobnosť a matematická statistika



# Vlastné čísla, vlastné vektory

- Číslo  $\lambda$  nazývame vlastným číslom matice  $A$ , ak sústava lineárnych rovníc tvaru  $A\mathbf{x} = \lambda\mathbf{x}$  má okrem triviálneho riešenia aj nenulové riešenie. Príslušné nenulové riešenie sa nazýva vlastný vektor matice  $A$  zodpovedajúci vlastnému číslu  $\lambda$
- Vlastné čísla nájdeme vyriešením
$$\det(A - \lambda I) = 0$$
- Potom pre každú hodnotu  $\lambda$  vyriešime
$$(A - \lambda I)\mathbf{x} = 0$$

# Príklad

$$\mathbf{A} = \begin{bmatrix} 2 & -4 \\ -1 & -1 \end{bmatrix}$$

$$(\mathbf{A} - \lambda \mathbf{I})\mathbf{x} = \mathbf{0}$$

$$p(\lambda) = \begin{vmatrix} 2 - \lambda & -4 \\ -1 & -1 - \lambda \end{vmatrix} = \begin{bmatrix} 2 - 3 & -4 \\ -1 & -1 - 3 \end{bmatrix} \begin{bmatrix} v_1^1 \\ v_2^1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad \begin{bmatrix} 2 - (-2) & -4 \\ -1 & -1 - (-2) \end{bmatrix} \begin{bmatrix} v_1^2 \\ v_2^2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$= (2 - \lambda)(-1 - \lambda) - (-4)(-1) =$$

$$= \lambda^2 - \lambda - 6 =$$

$$= (\lambda - 3)(\lambda + 2)$$

$$-v_1^1 - 4v_2^1 = 0$$

$$-v_1^1 - 4v_2^1 = 0$$

$$v_1^1 = -4v_2^1$$

$$4v_1^2 - 4v_2^2 = 0$$

$$-v_1^2 + v_2^2 = 0$$

$$v_1^2 = v_2^2$$

$$\mathbf{v}_1 = \begin{bmatrix} 4 \\ -1 \end{bmatrix}, \quad \mathbf{v}_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

# Druhý príklad

$$A = \begin{bmatrix} -1 & 2 & 0 \\ 0 & 3 & 4 \\ 0 & 0 & 7 \end{bmatrix}$$

$$\det(\mathbf{A} - \lambda\mathbf{I}) = 0$$

$$\det\left(\begin{bmatrix} -1 & 2 & 0 \\ 0 & 3 & 4 \\ 0 & 0 & 7 \end{bmatrix} - \lambda \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}\right) = 0$$

$$\det\begin{bmatrix} -1-\lambda & 2 & 0 \\ 0 & 3-\lambda & 4 \\ 0 & 0 & 7-\lambda \end{bmatrix} = 0$$

$$(-1-\lambda)(3-\lambda)(7-\lambda) = 0$$

$$\lambda = -1, \quad \lambda = 3, \quad \lambda = 7$$

# Druhý příklad II

$$\lambda = -1$$

$$(\mathbf{A} - \lambda\mathbf{I})\mathbf{v} = \mathbf{0}$$

$$\left( \begin{bmatrix} -1 & 2 & 0 \\ 0 & 3 & 4 \\ 0 & 0 & 7 \end{bmatrix} - \begin{bmatrix} -1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & -1 \end{bmatrix} \right) \begin{bmatrix} v_1^1 \\ v_2^1 \\ v_3^1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$\begin{bmatrix} 0 & 2 & 0 \\ 0 & 4 & 4 \\ 0 & 0 & 8 \end{bmatrix} \begin{bmatrix} v_1^1 \\ v_2^1 \\ v_3^1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$0 + 2v_2^1 + 0 = 0$$

$$0 + 4v_2^1 + 4v_3^1 = 0$$

$$0 + 0 + 8v_3^1 = 0$$

$$v_1^1 = 1, \quad v_2^1 = 0, \quad v_3^1 = 0$$

$$\mathbf{v}_1 = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}, \quad \mathbf{v}_2 = \begin{bmatrix} 1 \\ 2 \\ 0 \end{bmatrix}, \quad \mathbf{v}_3 = \begin{bmatrix} 1 \\ 4 \\ 4 \end{bmatrix}$$

# Singulárne číslo, singulárne vektory

- Nezáporné číslo  $\sigma$  sa nazýva singulárne číslo matice  $\mathbf{A}$  rozmeru  $N \times D$ , ak existuje  $N$ -rozmerný vektor  $\mathbf{u}$  (ľavý singulárny vektor) a  $D$ -rozmerný vektor  $\mathbf{v}$  (pravý singulárny vektor) a platí

$$\mathbf{A}\mathbf{v} = \sigma\mathbf{u},$$
$$\mathbf{A}^H\mathbf{u} = \sigma\mathbf{v},$$

# Singulárne číslo, singulárne vektory II

- kde  $A^H$  je Hermitovsky (komplexne združená) transponovaná matica. Pre reálne matice, s ktorými budeme pracovať platí  $A^H = A^T$ .
- Singulárne čísla sa dajú chápať ako druhé odmocniny vlastných čísel matic  $A^H A$  alebo  $AA^H$  či matice  $\begin{bmatrix} I & A \\ A^H & I \end{bmatrix}$

# Singulárne vektory II

- Ak  $\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_N]$  je matica všetkých ľavých singulárnych vektorov a  $\mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_N]$  matica pravých singulárnych vektorov, potom platí

$$\mathbf{AV} = \mathbf{US},$$
$$\mathbf{A}^T \mathbf{U} = \mathbf{VS}^T$$

- kde  $\mathbf{S} = \text{diag}(1, \dots, \text{rank}(\mathbf{A}))$  je diagonálna matica singulárnych čísel  $\mathbf{A}$

# SVD – singulárny rozklad matice

- SVD rozloží maticu  $A \in R^{N \times D}$  na súčin troch matic  $A = USV^T$ ,
- kde  $U \in R^{N \times N}$  a  $V \in R^{D \times D}$  sú ortogonálne matice obsahujúce ľavé a pravé singulárne vektory a
- $S \in R^{N \times D}$  je diagonálna matica, obsahujúca na diagonále singulárne čísla matice  $A$  zostupne podľa veľkosti



# Singulárny rozklad matice II

- Singulárny rozklad  $A = USV^T$  môžeme napísať ako

$$[\mathbf{A}]_{N \times D} = [\mathbf{U}]_{N \times N} [\mathbf{S}]_{N \times D} [\mathbf{V}^T]_{D \times D}$$

kde  $N$  je počet vzoriek a  $D$  je dimenzia vzorky (rozmer vektora príznačkov)

# Singulárny rozklad matice III

- Pre počet nenulových vlastných čísel  $r$  platí  $r = \text{rank}(\mathbf{A}) \leq \min(N, D)$  a úsporná forma SVD je

$$\mathbf{U} = \left[ \begin{array}{c|c} \mathbf{U}_1 & \mathbf{U}_2 \\ \hline \mathbf{U}_3 & \mathbf{U}_4 \end{array} \right],$$

$$\mathbf{S} = \left[ \begin{array}{c|c} \text{diag}(\sigma_1, \dots, \sigma_r) & \mathbf{0} \\ \hline \mathbf{0} & \mathbf{0} \end{array} \right] = \left[ \begin{array}{c|c} \mathbf{S}_1 & \mathbf{0} \\ \hline \mathbf{0} & \mathbf{0} \end{array} \right],$$

$$\mathbf{V}^T = \left[ \begin{array}{c|c} \mathbf{V}_1 & \mathbf{V}_3 \\ \hline \mathbf{V}_2 & \mathbf{V}_4 \end{array} \right],$$


$$\begin{aligned} \mathbf{A} &= \left[ \begin{array}{c|c} \mathbf{U}_1 & \mathbf{U}_2 \\ \hline \mathbf{U}_3 & \mathbf{U}_4 \end{array} \right] \left[ \begin{array}{c|c} \mathbf{S}_1 & \mathbf{0} \\ \hline \mathbf{0} & \mathbf{0} \end{array} \right] \left[ \begin{array}{c|c} \mathbf{V}_1 & \mathbf{V}_3 \\ \hline \mathbf{V}_2 & \mathbf{V}_4 \end{array} \right] = \\ &= \left[ \begin{array}{c} \mathbf{U}_1 \\ \hline \mathbf{U}_3 \end{array} \right]_{(N \times r)} [\mathbf{S}_1]_{(r \times r)} [\mathbf{V}_1 | \mathbf{V}_3]_{(r \times D)}. \end{aligned}$$

# Nelineárne programovanie

- Využívame ho na hľadanie viazaného extrémumu s využitím Lagrangeovej metódy neurčitých koeficientov
- Najprv hľadáme extrém funkcie za podmienky, že riešenie spĺňa ohraničenie v podobe rovnosti, čiže

$$\min_{\mathbf{x}} \{ (f(\mathbf{x}) \mid g_j(\mathbf{x}) = c_j) \text{ pre } j = 1, 2, \dots, m \}$$

# Nelineárne programovanie II



# Nelineárne programovanie III

- Lagrangeova funkcia má tvar

$$L(\mathbf{x}, \boldsymbol{\lambda}) = f(\mathbf{x}) - \sum_{j=1}^m \lambda_j (g_j(\mathbf{x}) - c_j)$$

- Pri splnení podmienok existuje jediný vektor  $\boldsymbol{\lambda}$  (vektor Lagrangeových multiplikátorov), že funkcia má stacionárny bod, a platí

$$\frac{\partial L}{\partial x_i} = 0 \text{ a } \frac{\partial L}{\partial \lambda_j} = 0$$

# Nelineárne programovanie IV

- Ak zmeníme podmienku viazanosti z rovností na nerovnosti, tak dostaneme
- Riešime


$$\min f(\mathbf{x})$$

$$\text{aby } g_i(\mathbf{x}) \leq c_i \quad i = 1, \dots, n$$

- čo prevedieme na

$$\min f(\mathbf{x})$$

$$\text{aby } g_i(\mathbf{x}) - c_i \leq 0 \quad i = 1, \dots, n$$



# Nelineárne programovanie V

- Aj pri nerovnostiach existuje minimum  $f(\mathbf{x})$  a vektor Lagrangeových multiplikátorov, ktorý spĺňa tzv. Kuhn-Tuckerove podmienky

$$\frac{\partial L(\mathbf{x}, \boldsymbol{\lambda})}{\partial x_j} = \frac{\partial f(\mathbf{x})}{\partial x_j} + \sum_{i=1}^n \lambda_i \frac{\partial g_i(\mathbf{x})}{\partial x_j} = 0$$

$$\frac{\partial L(\mathbf{x}, \boldsymbol{\lambda})}{\partial \lambda_i} = g_i(\mathbf{x}) \leq 0$$

$$\lambda_i \frac{\partial L(\mathbf{x}, \boldsymbol{\lambda})}{\partial \lambda_i} = \lambda_i g_i(\mathbf{x}) = 0$$

$$\lambda_i \geq 0$$

# Koniec odbočky



- ale nie matematiky 😊