

# X. Testování hypotéz: neparametrické testy

# Co přináší neparametrické testování hypotéz

V případě **ordinálních (pořadových) nebo nominálních dat** odpovídá na specifické otázky:

1. Existuje významný soulad dané charakteristiky rozdělení četnosti vzorku se zadanou charakteristikou populace?
2. Existuje významný rozdíl dané charakteristiky mezi 2 (nebo více) vzorky?

**Charakteristika** - např. medián, zadané pořadí, **typ rozdělení pr-sti (četnosti)** aj.

# Neparametrické testy hypotéz

- Má medián populace s neznámým rozdělením stanovenou hodnotu?  
(**mediánový test**)
- Pochází výběr z populace se zadaným (známým) rozdělením pravděpodobnosti?  
(**Chi-kvadrát test**)

# Mediánový test

(pro 1 výběr)

- Nevíme-li, zda má populace normální rozdělení, předpokládáme, že má medián  $\tilde{\mu}_0$  rozsah vzorku  $n$
- $H_0: \tilde{\mu} = \tilde{\mu}_0$   $H_1: \tilde{\mu} \neq \tilde{\mu}_0$  - oboustranný test

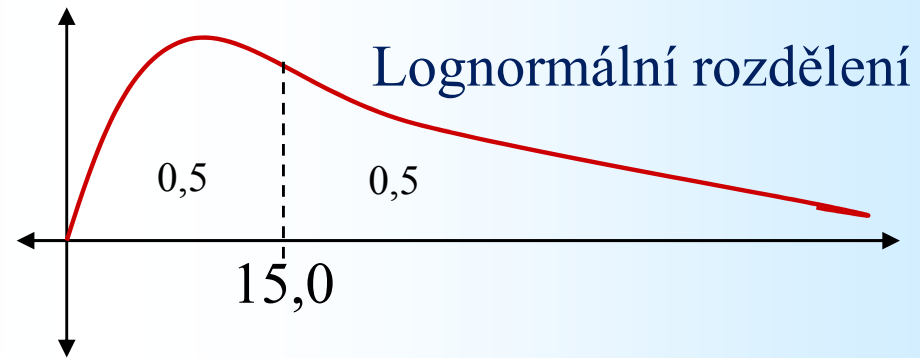
- Testové kritérium: 
$$u = \frac{|2m - n|}{\sqrt{n}}$$

$m$  je počet pozorování ve vzorku  $< \tilde{\mu}_0$

- Jestliže  $u > z_{1-\alpha/2}$  potom  $H_0$  zamítáme!

$z_{1-\alpha/2}$  je kvantil norm. normál. rozd. (viz tabulky)<sub>4</sub>

## Příklad 1: Mzdy



Náhodně vybraný vzorek 19 pracovníků jisté (dělnické) profese ve městě Karviná poskytl následující údaje o jejich měsíčních mzdách (v tis.Kč):

10,0	12,3	12,6	12,6	13,0	13,2	13,3	13,3	13,4	13,8
14,1	14,3	14,6	15,1	15,2	15,4	16,5	18,2	20,5	—

Na hladině významnosti  $\alpha = 0,05$  testujte hypotézu, že průměrná (mediánová) měsíční mzda pracovníků této profese v Karviné je 15 tis. Kč.

## Příklad 1: Řešení ...

**Populace** - měsíční mzdy všech pracovníků dané profese v Karviné

Je známo, že mzdy **nemají** normální rozdělení pr-sti!

Proto namísto **střední hodnoty** je lepší charakteristikou **medián**, jemu pak odpovídá neparametrický dvoustranný mediánový test hypotézy

$$H_0: Med(X) = 15$$

proti alternativní hypotéze

$$H_1: Med(X) \neq 15$$

## Příklad 1: ... Řešení

Z dat:  $n = 19$ ,  $m = 13$ , vypočteme:

$$u = \frac{|2 \cdot 13 - 19|}{\sqrt{19}} = 1,61$$

$\text{NORMSINV}(0,975) = 1,96$

Protože  $1,61 < 1,96$ , nulovou hypotézu  $H_0$   
**nezamítáme** (přijímáme)

**Jinými slovy:** na zvolené hladině  
významnosti 0,05 vzorek neodporuje  
hypotéze o vyšší mediánové měsíční mzdy  
prac. dané profese v Karviné (tj. 15 tis. Kč)

**Také:** vybraný vzorek je v souladu  
s karvinskou populací v této profesi!

# Chi-kvadrát test

( $\chi^2$  - test pro 1 výběr)

- Data mohou být **nominální**  
(nejslabší požadavek)!
- Testuje se (nulová) hypotéza  
 $H_0$ : výběr pochází z populace s daným  
rozdělením
- Zadané rozdělení je obvykle:
  - diskrétní rozdělení se stejnými pr- stmi  
(tzv. **test nezávislosti**)
  - diskrétní rozdělení s rozdílnými pr- stmi  
(tzv. **test dobré shody**)



## Příklad 2: Limonády

Nová limonáda se prodávala za stejnou cenu jeden týden ve 3 různých typech obalu: A, B, C, počet prodaných limonád viz tabulka:

Typ obalu	Prodané kusy
A	135
B	130
C	155
Celkem	420

Ovlivňuje styl designu obalu počet prodaných limonád?

**Jinak:** Závisí prodej na obalu?

# Příklad 2: Algoritmus a řešení 1:

## *Test nezávislosti*

### **Krok 1. Nulová hypotéza $H_0$ :**

Počet prodaných kusů **nezávisí** na typu obalu (rozdíly v prodeji u vzorku jsou pouze dílem náhody).

### **Očekávané četnosti (Expected):**

$$E_1 = E_2 = E_3 = 420/3 = 140$$

### **Pozorované četnosti (Observed):**

$$O_1 = 135, O_2 = 130, O_3 = 155$$

### **Krok 2. Testové kritérium:**

$$X^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$$

$k$  - počet kategorií ( $k = 3$ )

## Příklad 2: Algoritmus a řešení 2

**Krok 3.** Porovnání hodnoty vypočítaného kritéria

$$X^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} = 2,5$$

$$\text{CHIINV}(0,05;2) = 6,0$$

s tabulkovou **kritickou hodnotou** rozdělení  $\chi^2_{\alpha}(2) = 6,0$

kde  $\alpha (= 0,05)$  je zadaná hladina významnosti

**V každé kategorii:  $O_i$  alespoň 5 !**


Jestliže

$$X^2 = 2,5 < \chi^2_{0,05}(2) = 6,0$$

potom  $H_0$  nezamítáme! (jinak **zamítáme**)

**$p$ -hodnota (signifikance) = 0,287 > 0,05 (Nezamítáme)**

Kritické hodnoty  
rozdělení Chi-kvadrát  $\chi^2_{\alpha}(n)$



n \ $\alpha$	0,995	0,99	0,975	0,95	0,9	0,1	0,05	0,025	0,01	0,005
1	0,00	0,00	0,00	0,00	0,02	2,7	3,8	5,0	6,6	7,9
2	0,01	0,02	0,05	0,10	0,21	4,6	6,0	7,4	9,2	10,6
3	0,07	0,12	0,22	0,35	0,58	6,3	7,8	9,4	11,3	12,8
4	0,21	0,30	0,48	0,71	1,06	7,8	9,5	11,1	13,3	14,9
5	0,41	0,55	0,83	1,15	1,61	9,2	11,1	12,8	15,1	16,7
6	0,68	0,87	1,24	1,64	2,20	10,6	12,6	14,4	16,8	18,5
7	0,99	1,24	1,69	2,17	2,83	12,0	14,1	16,0	18,5	20,3
8	1,34	1,65	2,18	2,73	3,49	13,4	15,5	17,5	20,1	22,0
9	1,74	2,09	2,70	3,33	4,17	14,7	16,9	19,0	21,7	23,6
10	2,16	2,56	3,25	3,94	4,87	16,0	18,3	20,5	23,2	25,2
11	2,60	3,05	3,82	4,57	5,58	17,3	19,7	21,9	24,7	26,8
12	3,07	3,57	4,40	5,23	6,30	18,5	21,0	23,3	26,2	28,3
13	3,57	4,11	5,01	5,89	7,04	19,8	22,4	24,7	27,7	29,8
14	4,07	4,66	5,63	6,57	7,79	21,0	23,7	26,1	29,1	31,3
15	4,60	5,23	6,26	7,26	8,55	22,3	25,0	27,5	30,6	32,8
16	5,14	5,81	6,91	7,96	9,31	23,5	26,3	28,8	32,0	34,3
17	5,70	6,41	7,56	8,67	10,09	24,8	27,6	30,2	33,4	35,7
18	6,26	7,01	8,23	9,39	10,86	26,0	28,9	31,5	34,8	37,2
19	6,84	7,63	8,91	10,12	11,65	27,2	30,1	32,9	36,2	38,6
20	7,43	8,26	9,59	10,85	12,44	28,4	31,4	34,2	37,6	40,0
21	8,03	8,90	10,28	11,59	13,24	29,6	32,7	35,5	38,9	41,4
22	8,64	9,51	10,98	12,34	14,04	30,8	33,9	36,8	40,3	42,8
23	9,26	10,20	11,69	13,09	14,58	32,0	35,2	38,1	41,6	42,2
24	9,89	10,86	12,40	13,85	15,66	33,2	36,4	39,4	43,0	45,6
25	10,52	11,52	13,12	14,61	16,47	34,4	37,7	40,6	44,3	46,9
26	11,16	12,20	13,84	15,38	17,29	35,6	38,9	41,9	45,6	48,6
27	11,81	12,88	14,57	16,15	18,11	36,7	40,1	43,2	47,0	49,6
28	12,46	13,56	15,31	16,93	18,94	37,9	41,3	44,5	48,3	51,0
29	13,12	14,26	16,05	17,71	19,77	39,1	42,6	45,7	49,6	52,3
30	13,79	14,95	16,79	18,49	20,60	40,3	43,8	47,0	50,9	53,7

# Řešení příkladu 2 pomocí Excelu:

Tabulka → Funkce: SUMA, CHIIV, CHIDIST...

Typ obalu	O <sub>i</sub>	E <sub>i</sub>	(O <sub>i</sub> - E <sub>i</sub> ) <sup>2</sup> /E <sub>i</sub>
A	135	140	0,179
B	130	140	0,714
C	155	140	1,607
Sumy	420	420	2,500

X <sup>2</sup>	=	2,5
alfa	=	0,05
k-1	=	2
CHIINV	=	5,991
CHIDIST	=	0,287

**Signifikance** = CHIDIST = 0,287 > 0,05

⇒ H<sub>0</sub> nezamítáme!

## Příklad 2: Limonády (**nová verze**)...

Nová limonáda se prodávala za stejnou cenu jeden týden ve fakultním bufetu ve 3 různých typech obalu: A, B, C, počet prodaných limonád viz tabulka:

Typ obalu	Prodané kusy	
A	135	120
B	130	130
C	155	170
Celkem	420	420

**NOVÉ ZADÁNÍ:**

Ovlivňuje styl designu obalu počet prodaných limonád?

## Řešení příkladu 2... pomocí Excelu:

Tabulka → Funkce: SUMA, CHIIV, CHIDIST...

	O <sub>i</sub>	E <sub>i</sub>	(O <sub>i</sub> -E <sub>i</sub> ) <sup>2</sup> /E <sub>i</sub>
A	120	140	2,857
B	130	140	0,714
C	170	140	6,429
Suma	420	420	10,000

Signifikance = CHIDIST = 0,0067 < 0,05 ⇒ H<sub>0</sub>

**zamítáme!**

$\chi^2 = 10,0 > \chi_{\alpha}^2(k-1) = \text{CHINV} = 5,991 \Rightarrow H_0$

**zamítáme!**<sup>5</sup>

## Příklad 3: Barvy automobilů 1

Automobil Škoda - Felicia se prodává ve čtyřech barvách:

- 40% zákazníků požaduje zelenou barvu automobilu
- 25% červenou barvu,
- 25% modrou barvu a
- 10% bílou barvu.

K ověření správnosti předpokladu o struktuře poptávky podle barev použijte záznamy o nákupech v dané prodejně v jistém měsíci



## Příklad 3: Barvy automobilů 2

Vstupní údaje obsahuje následující tabulka:

$j$	Barva	$p_{0,j}$	$n_j$
1	zelená	0,40	201
2	červená	0,25	105
3	modrá	0,25	144
4	bílá	0,10	30
součet		1,00	480

Na hladině významnosti  $\alpha = 0,05$  testujte hypotézu, že uvedené pravděpodobnostní odhady odpovídají zjištěným hodnotám prodejů

# **Příklad 3:** Algoritmus a řešení 1: *Test dobré shody*

## **Krok 1. Nulová hypotéza $H_0$ :**

$$H_0 : p_{0,1} = 0,4, p_{0,2} = p_{0,3} = 0,25, p_{0,4} = 0,1$$

## **Očekávané četnosti:**

$$E_1 = 192, E_2 = 120, E_3 = 120, E_4 = 48$$

## **Pozorované četnosti:**

$$O_1 = 201, O_2 = 105, O_3 = 144, O_4 = 30$$

## **Krok 2. Testové kritérium:**

$$X^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$$

$k$  - počet kategorií ( $k = 4$ )

## Očekávané četnosti:

$$\text{Očekáv\_čet}_i = \text{Pravděp}_i \times \text{celk\_čet}$$

### **Příklad:**

$i = \text{zelená}$ ,  $\text{Pravděp}_i = 0,40$  ,  $\text{celk\_čet} = 480$

$$E_1 = \text{Očekáv\_čet}_i = 0,4 * 480 = 192$$

atd.

## **Příklad 3:** Algoritmus a řešení 2: ***Test dobré shody***

**Krok 3.** Porovnání hodnoty vypočítaného kritéria

$$X^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} = 13,85$$

s tabulkovou **kritickou hodnotou** rozdělení  $\chi_{0,05}^2(3) = 7,81$

**V každé kategorii:  $O_i$  je alespoň 5 ( $>30$ )**

Platí

$$X^2 = 13,85 > \chi_{0,05}^2(3) = 7,81 = \text{CHINV}(0,05;3)$$

proto  $H_0$  zamítáme! Alternativně:

$$\text{Sig} = \text{CHIDIST}(13,85; 3) = 0,003 < 0,05$$

# Testování nezávislosti kvalitativních znaků 1

V jednom vzorku (výběru) můžeme současně sledovat dva nebo i více (kvalitativních) znaků

## **Příklad:**

Při kontrole jakosti výrobku sledujeme přítomnost nebo nepřítomnost vady  $A$  (znak  $A$ ), nebo přítomnost nebo nepřítomnost vady  $B$  (znak  $B$ ).

$A$  i  $B$  nabývají pouze dvě alternativní hodnoty –

**kategorie: Ano, Ne**

**(Přítomnost, Nepřítomnost, apod.).**

# Testování nezávislosti kvalitativních znaků 2

Uvažujte soubor se dvěma **kvalitativními**  
znaky  $A$  a  $B$

Znak  $A$  má  $r$  možných kategorií hodnot  
označených:  $A_1, A_2, \dots, A_r$

znak  $B$  má  $s$  možných kategorií hodnot:

$$B_1, B_2, \dots, B_s$$

Výsledek celého složeného experimentu lze  
shrnout do **kontingenční tabulky**:

# Kontingenční tabulka:

Kategorie znaku $A/B$	$B_1$	$B_2$	$B_3$	.....	$B_s$	Součet
$A_1$	$n_{11}$	$n_{12}$	$n_{13}$	.....	$n_{1s}$	$n_{1\cdot}$
$A_2$	$n_{21}$	$n_{22}$	$n_{23}$	.....	$n_{2s}$	$n_{2\cdot}$
$A_3$	$n_{31}$	$n_{32}$	$n_{33}$	.....	$n_{3s}$	$n_{3\cdot}$
.....	.....	.....	.....	.....	.....	.....
$A_r$	$n_{r1}$	$n_{r2}$	$n_{r3}$	.....	$n_{rs}$	$n_{r\cdot}$
<b>Součet</b>	$n_{\cdot 1}$	$n_{\cdot 2}$	$n_{\cdot 3}$	.....	$n_{\cdot s}$	$n$

# Kontingenční tabulka (čtyřpolní)

Příklad: vzhled vers. hmotnost výrobku

Vzhled / Hmotnost výrobků	Vyhovující hmotnost	Nevyhovující hmotnost	Součet- Marg. četnost
Vyhovující vzhled	<b>239</b>	<b>60</b>	<b>299</b>
Nevyhovující vzhled	<b>14</b>	<b>7</b>	<b>21</b>
Součet - Marg. četnost	<b>253</b>	<b>67</b>	<b>320</b>



# Chi-kvadrát test nezávislosti: Algoritmus 1

## Krok 1. Nulová hypotéza $H_0$ :

Vzhled výrobku nezávisí na hmotnosti  
(rozdíly u vzorku jsou pouze dílem náhody).

**Očekávané četnosti:**  $E_{11} = 253 * 299 / 320 = 236,4$   
 $E_{21} = 253 * 21 / 320 = 16,6$   
 $E_{12} = 67 * 299 / 320 = 62,6$   
 $E_{22} = 67 * 21 / 320 = 4,4$

**Pozorované četnosti:**  $O_{11} = 239, O_{12} = 14, O_{21} = 60, O_{22} = 7$

**Krok 2. Testové kritérium  $X^2$ :** 
$$X^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(O_{ij} - E_{ij})^2}{E_{ij}} = 2,086$$

$df = (r-1)(s-1)$  počet stupňů volnosti ( $k = (2-1)(2-1) = 1$ )

## Očekávané četnosti:

$$\frac{\text{Očekáv}_{\check{c}}_{i,j}}{\text{celk.c.}} = \frac{\text{Marg}_{\check{c}}_{i}}{\text{celk.}\check{c}} \times \frac{\text{Marg}_{\check{c}}_{j}}{\text{celk.}\check{c}}$$

$$\text{Očekáv}_{\check{c}}_{i,j} = \text{Marg}_{\check{c}}_{i} \times \text{Marg}_{\check{c}}_{j} / \text{celk}_{\check{c}}$$

### Příklad:

$i = 1$ : Hmotnost-Nevyhovující

$j = 2$  : Vzhled-Vyhovující

$\text{celk}_{\check{c}} = 320$

$E_{12} = \text{Očekáv}_{\check{c}}_{1,2} = 299 * 67 / 320 = 62,6$

atd.

# Chi-kvadrát test nezávislosti: Algoritmus 2

**Krok 3.** Porovnání hodnoty vypočítaného kritéria s tabulkovou kritickou hodnotou rozdělení kde  $\alpha = 0,10$  je zadaná hladina významnosti.

**V každé kategorii má být alespoň 5 hodnot!**

Jestliže  $X^2 = 2,1 < \chi_{0,1}^2(1) = 2,7$  potom  $H_0$  nezamítáme!

**Alternativně:**

Pro hodnotu  $X^2$  zjistíme  $p$ -hodnotu (tj. signifikanci -  
- má být menší než 0,1)

$p = \text{CHIDIST}(2,1;1) = 0,147$  - tedy  $H_0$  nezamítáme!

## Čtyřpolní tabulka – kontingenční tabulka 2 x 2:

Znak2			<b>Součet</b>
Znak1	$h_1$	$h_2$	
$h_1$	$A$	$B$	$A+B$
$h_2$	$C$	$D$	$C+D$
<b>Součet</b>	$A+C$	$B+D$	$n$

**Kritérium:**

$$X^2 = \frac{n(AD - BC)^2}{(A+B)(C+D)(A+C)(B+D)}$$

**Jestliže**  $X^2 > \chi_\alpha^2(1)$

**pak  $H_0$  zamítáme, jinak ji nezamítáme!**

## Příklad: Vzhled vers. Hmotnost

$$A = 239, B = 60, C = 14, D = 7$$

$$X^2 > \chi_{0,1}^2(1) = 2,7$$

$$X^2 = \frac{n(AD - BC)^2}{(A + B)(C + D)(A + C)(B + D)} = 2,1$$

## Příklad 4 – Vliv kouření na úmrtnost v Karviné

Kontingenční tabulka pro 2917 zemřelých v Karviné  
v roce 1998

*Kouření versus Počet zemřelých na rakovinu plic*

Pozorované čet.	zemřel RP	zemřel JINAK
kouření ANO	137	817
kouření NE	198	1765

Analyzujte, zda kouření respondentů ovlivnilo  
úmrtnost na rakovinu plic (*RP*)

Použijte Chi-kvadrát test

# Řešení příkladu 4 pomocí Excelu:

Pozorované čet.	zemřel RP	zemřel JINAK	Suma
kouření ANO	137	817	954
kouření NE	198	1765	1963
Suma	335	2582	2917

Očekávané čet.	zemřel RP	zemřel JINAK	$(E_{ij}-O_{ij})^2/E_{ij}$	
kouření ANO	109,56	844,44	6,87	0,89
kouření NE	225,44	1737,56	3,34	0,43

CHI-SQUARE	11,54
alfa	0,05
df	1
CHIINV	3,8415
CHIDIST=Sig	0,0007

součet

Nulovou hypotézu **o nezávislosti** znaků zamítáme!  
 (Úmrtnost na rakovinu plic závisí na kouření respondentů)

$$X^2 = \frac{n(AD - BC)^2}{(A + B)(C + D)(A + C)(B + D)} = 11,54$$