

# Neparametrické testy

Dosud jsme se zabývali statistickými metodami, které zahrnovaly předpoklady o rozdělení dat. Zpravidla jsme předpokládali **normální (Gaussovo) rozdělení**.

Například:

- **Grubbsův test odlehlých hodnot** zjišťuje o kolik směrodatných odchylek se liší extrémní hodnota od průměru
- **test střední hodnoty** zjišťuje o kolik směrodatných odchylek se liší průměr od očekávané hodnoty

↑ **Metody**, které předpokládají, že **známe parametry rozdělení** nazýváme **parametrické**.

↓ **Neparametrické metody** nepředpokládají konkrétní typ rozdělení.

**Neparametrické metody nejsou tak silné jako parametrické.**


# Neparametrické testy



$\mu = 6,0$     $\sigma = 1,0$     $N = 20$



$\mu = 6,0$     $\sigma = 1,0$     $N = 20$



# Grubbsův test odlehlých hodnot

**! parametrický !**

Jako míra odlehlosti hodnoty slouží její vzdálenost testované hodnoty od aritmetického průměru výběru dat, vztažená ke směrodatné odchylce (NE výběrové, ale směrodatné odchylce celého uvažovaného souboru).

**Testovací kritérium:**

$$T = \frac{|x_i - \hat{\mu}|}{S}, \text{ kde } S = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{\mu})^2}$$

Je-li testovací kritérium  $T$  větší než kritická hodnota  $T_{N,\alpha}$ , vyloučíme testovanou hodnotu ze souboru. (Budíková et al.,2010)

**Kritické hodnoty** Grubbsova T-rozdělení (pro  $\alpha = 0,05$  a  $0,01$ )

$N$	3	4	5	7	10	15	20	30	50	70	100	200
$T_{N,0,05}$	1,15	1,48	1,72	2,02	2,29	2,55	2,71	2,91	3,13	3,26	3,38	3,61
$T_{N,0,01}$	1,15	1,49	1,76	2,14	2,48	2,81	3,00	3,24	3,48	3,62	3,75	3,98

# Deanův-Dixonův Q-test odlehlých hodnot

$H_0$ : Nejmenší, resp. největší **hodnota** z výběru **není odlehlá**.

$H_1$ : Nejmenší, resp. největší hodnota z výběru je odlehlá.

**Testovací statistika:**

$$Q = \frac{x_2 - x_1}{x_N - x_1}$$

pro nejmenší hodnoty

$$Q = \frac{x_N - x_{N-1}}{x_N - x_1}$$

pro největší hodnoty

Kritický obor:  $|Q| > Q_{N,\alpha}$

**Kritické hodnoty** Deanova-Dixonova Q-rozdělení ( $\alpha = 0,05$  a  $0,01$ )  
(Verna, Suarez 2014)

$N$	5	10	15	20	25	30	40	50	60	70	100
$Q_{N,0.05}$	0,642	0,412	0,339	0,300	0,276	0,259	0,236	0,221	0,210	0,202	0,185
$Q_{N,0.01}$	0,781	0,526	0,438	0,392	0,363	0,342	0,314	0,296	0,282	0,272	0,250

# Pořadí

Pořadí  $R_i$  udává počet čísel  $x_1, x_2, \dots, x_N$ , která jsou **menší nebo rovna** číslu  $x_i$ .

- Jsou-li všechna čísla různá a seřazená podle velikosti, odpovídá pořadí indexu.  $R_i = i$ .
- Pokud je několik čísel  $x_1, x_2, \dots, x_N$  stejných přiřadíme jim průměrné pořadí.

(Meloun & Militký, 2013)

Vzestupně uspořádané hodnoty	-2	-2	1	8	8	8	22
Index	1	2	3	4	5	6	7
Pořadí $R_i$	1.5	1.5	3	5	5	5	7

# Mediánový test

**Mediánový test** je neparametrickou alternativou **testu střední hodnoty** (střední hodnota výběru se rovná nějaké konstantě).

$H_0$ : **Medián** souboru **je roven konstantě  $c$** .

Označíme-li  $N$  rozsah výběru a  $m$  počet hodnot menších než  $c$ , **testovací kritérium** vypočítané podle vztahu

$$Z = \frac{2m - N}{\sqrt{N}}$$

má normální rozdělení se střední hodnotou 0 a směrodatnou odchylkou 1, je-li počet hodnot větší než 30.

**Kritická hodnota:** `=NORM.S.INV(1 -  $\alpha$ /2)` {NORMSINV}

Je-li testovací kritérium větší než kritická hodnota, nulovou hypotézu zamítáme.

(Meloun & Militký, 2013)

# Znaménkový test

**Znaménkový test** je neparametrickou alternativou **párového testu** a **variantou mediánového testu**.

Testujeme u párových rozdílů jestli je medián nulový (tj. počet kladných a záporných hodnot stejný) →

$H_0$ : **Medián** souboru **je roven nule**.

resp. Počet kladných a záporných rozdílů je stejný.

Označíme-li  $N$  rozsah výběru a  $m$  počet hodnot menších než 0 je **testovací kritérium**

$$Z = \frac{2m - N}{\sqrt{N}}$$

**Kritickou hodnotu** počítáme stejně jako u mediánového testu.

Poznámky:

(Meloun & Militký, 2013)

- Pokud jsou některé rozdíly nulové, vyřadíme je.
- Je-li počet hodnot menší než 30, hledáme kritické hodnoty testu ve speciálních tabulkách.

# Mann-Whitneyův pořadový test

**Mann-Whitneyův pořadový test** je neparametrickou analogií **testu rovnosti dvou středních hodnot**. →

$H_0$ : **Dva soubory**, ze kterých jsou výběry, **mají stejný medián**.

Seřadíme spojená data obou výběrů podle velikosti a každé hodnotě přiřadíme pořadí. Sečteme pořadí obou výběrů - ozn.  $W_1$  a  $W_2$ .

**Testovací kritérium:**

$$Z = \frac{W_1 - N_1(N_1 + N_2 + 1)/2}{\sqrt{N_1 N_2 (N_1 + N_2 + 1)/12}}$$

(Meloun & Militký, 2013)

kde  $N_1$  je počet hodnot prvního výběru a  $N_2$  počet hodnot druhého výběru, má normální rozdělení se střední hodnotou 0 a směrodatnou odchylkou 1.

**Kritická hodnota:**

$$= \text{NORM.S.INV}(1 - \alpha/2)$$

{NORMSINV}

Je-li testovací kritérium větší než kritická hodnota, nulovou hypotézu zamítáme.



# Spearmanův (pořadový) korelační koeficient

V případě, že nejsou splněny podmínky pro **Pearsonův korelační koeficient** (např. když testované veličiny nemají normální rozdělení nebo obsahují odlehlé hodnoty, popř. když pracujeme s kvalitativními veličinami) používáme **Spearmanův korelační koeficient**.

Místo hodnot  $x$  a  $y$  použijeme pořadí každé  $i_x$  a  $i_y$ , kde  $i_x$  je pořadí dané hodnoty  $x$  mezi všemi hodnotami  $x$ , podobně  $i_y$ .

$$r_s = 1 - \frac{6 \sum_{i=1}^N (i_x - i_y)^2}{N(N^2 - 1)}$$

$$H_0: r_s = 0$$

Testuje stejně jako u Pearsonova korelačního koeficientu pomocí **testovacího kritéria**

$$t = \frac{|r|}{\sqrt{1 - r^2}} \sqrt{N - 2}$$

**Kritický obor:**  $|t| > t_{1-\alpha}(N-2)$ , kde  $t_{1-\alpha}(N-2)$  jsou kvantily Studentova rozdělení, které lze spočítat pomocí funkce

$$= T.INV.2T(\alpha, N-2).$$