

## Cvičení 6.: Výpočet střední hodnoty a rozptylu

**Příklad 1.:** Postupně se zkouší spolehlivost čtyř přístrojů. Další se zkouší jen tehdy, když předchozí je spolehlivý. Každý z přístrojů vydrží zkoušku s pravděpodobností 0,8. Náhodná veličina  $X$  udává počet zkoušených přístrojů. Vypočtěte střední hodnotu a rozptyl náhodné veličiny  $X$ .

**Řešení:**

$X$  nabývá hodnot 1, 2, 3, 4 a její pravděpodobnostní funkce je:

$$\pi(1) = 0,2,$$

$$\pi(2) = 0,8 \cdot 0,2 = 0,16,$$

$$\pi(3) = 0,8^2 \cdot 0,2 = 0,128,$$

$$\pi(4) = 0,8^3 \cdot 0,2 + 0,84 = 0,512,$$

$\pi(0) = 0$  jinak

$$E(X) = 1 \cdot 0,2 + 2 \cdot 0,16 + 3 \cdot 0,128 + 4 \cdot 0,512 = 2,952$$

$$D(X) = 1^2 \cdot 0,2 + 2^2 \cdot 0,16 + 3^2 \cdot 0,128 + 4^2 \cdot 0,512 - 2,952^2 = 1,4697$$

**Postup ve STATISTICE:**

Otevřeme nový datový soubor o dvou proměnných  $X$  a cetnost a čtyřech případech. Do proměnné  $X$  napíšeme 1, 2, 3, 4, do proměnné cetnost napíšeme 200, 160, 128, 512.

Statistiky – Základní statistiky/tabulky – Popisné statistiky – OK – zavedeme proměnnou vah cetnost – OK - Proměnné  $X$  – OK – Detailní výsledky - zaškrtneme Průměr, Rozptyl – Výpočet.

Proměnná	Popisné statistiky (Tabulka1)		
	N platných	Průměr	Rozptyl
X	1000	2,952000	1,471167

Rozptyl však musíme upravit, musíme ho přenásobit číslem 999/1000. Do výstupní tabulky tedy přidáme za proměnnou Rozptyl novou proměnnou a do jejího Dlouhého jména napíšeme =v3\*999/1000

Proměnná	Popisné statistiky (Tabulka1)			
	N platných	Průměr	Rozptyl	NProm
X	1000	2,952000	1,471167	1,469696

**Příklad 2. (k samostatnému řešení):** Náhodná veličina  $X$  udává počet ok při hodu kostkou. Pomocí systému STATISTICA vypočtěte její střední hodnotu a rozptyl.

**Výsledek:**  $E(X) = 3,5$ ,  $D(X) = 2,9167$

**Příklad 3.:** Ve 12 náhodně vybraných prodejnách ve městě byly zjištěny následující ceny určitého výrobku (v Kč): 102, 99, 106, 103, 96, 98, 100, 105, 103, 98, 104, 107. Těchto 12 hodnot považujeme za realizace náhodného výběru  $X_1, \dots, X_{12}$  z rozložení, které má střední hodnotu  $\mu$  a rozptyl  $\sigma^2$ . Určete nestranné bodové odhady neznámé střední hodnoty  $\mu$  a neznámého rozptylu  $\sigma^2$ .

**Výpočet pomocí systému STATISTICA:**

Otevřeme nový datový soubor o jedné proměnné (nazveme ji  $X$ ) a 12 případech. Do proměnné  $X$  napíšeme zjištěné ceny.

Výpočet realizace výběrového průměru a výběrového rozptylu:

Statistiky – Základní statistiky/tabulky – Popisné statistiky – OK – Proměnné X – OK – Detailní výsledky – vybereme Průměr a Rozptyl – Výpočet. Dostaneme tabulku:

Popisné statistiky (Tabulka15)		
Proměnná	Průměr	Rozptyl
X	101,7500	12,38636

**Příklad 4.:** Bylo zkoumáno 9 vzorků půdy s různým obsahem fosforu (veličina X). Hodnoty veličiny Y označují obsah fosforu v obilných klíčích (po 38 dnech), jež vyrostly na těchto vzorcích půdy.

číslo vzorku	1	2	3	4	5	6	7	8	9
X	1	4	5	9	11	13	23	23	28
Y	64	71	54	81	76	93	77	95	109

Těchto 9 dvojic hodnot považujeme za realizace náhodného výběru  $(X_1, Y_1), \dots, (X_9, Y_9)$  z dvourozměrného rozložení s kovariancí  $\sigma_{12}$  a koeficientem korelace  $\rho$ . Najděte bodové odhadu výběrové kovariance  $\sigma_{12}$  a výběrového koeficientu korelace  $\rho$ .

#### Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o dvou proměnných X a Y 9 případech. Do proměnných X a Y zapíšeme zjištěné hodnoty obsahu fosforu v půdě a v obilných klíčích.

Výpočet výběrové kovariance: Statistiky – Vícerozměrná regrese – Proměnné – Závisle proměnná Y, nezávisle proměnná X – OK – OK – Residua/předpoklady/předpovědi – Popisné statistiky – Další statistiky – Kovariance. Dostaneme tabulku:

Kovariance (Tabulka18)		
Proměnná	X	Y
X	91,7500	130,0000
Y	130,0000	284,2500

Vidíme, že výběrová kovariance veličin X, Y se realizuje hodnotou 130. (Výběrový rozptyl proměnné X resp. Y nabyl hodnoty 91,75 resp. 284,25.)

Výpočet výběrového koeficientu korelace: V menu Další statistiky vybereme Korelace.

Korelace (Tabulka18)		
Proměnná	X	Y
X	1,000000	0,804989
Y	0,804989	1,000000

Výběrový koeficient korelace veličin X, Y nabyl hodnoty 0,805, tedy mezi veličinami x, Y existuje silná přímá lineární závislost.

Upozornění: Výběrový koeficient korelace lze pomocí systému STATISTICA vypočítat i jiným způsobem: Statistika – Základní statistiky/tabulky – Korelační matice – OK – 1 seznam proměnných – X, Y – OK – Výpočet. Ve výsledné tabulce máme též realizace výběrových průměrů a směrodatných odchylek.

Korelace (Tabulka18)			
Proměnná	Průměry	Sm.odch.	X
	13,00000	9,57862	1,000000
Y	80,00000	16,85972	0,804989
			1,000000

### Vzorce pro meze $100(1-\alpha)\%$ empirického intervalu spolehlivosti pro střední hodnotu $\mu$ normálního rozložení při známém rozptylu $\sigma^2$ :

$$\text{Oboustranný: } d = m - \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}, h = m + \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}.$$

$$\text{Levostranný: } d = m - \frac{\sigma}{\sqrt{n}} u_{1-\alpha}.$$

$$\text{Pravostranný: } h = m + \frac{\sigma}{\sqrt{n}} u_{1-\alpha}.$$

**Příklad 5.:** Při kontrolních zkouškách životnosti 16 žárovek byl stanoven odhad  $m = 3000$  h střední hodnoty jejich životnosti. Z dřívějších zkoušek je známo, že životnost žárovky se řídí normálním rozložením se směrodatnou odchylkou  $\sigma = 20$  h. Vypočtěte

- a) 99% empirický interval spolehlivosti pro střední hodnotu životnosti
- b) 90% levostranný empirický interval spolehlivosti pro střední hodnotu životnosti
- c) 95% pravostranný empirický interval spolehlivosti pro střední hodnotu životnosti.

**Upozornění:** Výsledek zaokrouhlete na jedno desetinné místo a vyjádřete v hodinách a minutách.

#### Řešení:

ad a)

$$d = m - \frac{\sigma}{\sqrt{n}} u_{0,995} = 3000 - \frac{20}{\sqrt{16}} 2,57583 = 2987,1,$$

$$h = m + \frac{\sigma}{\sqrt{n}} u_{0,995} = 3000 + \frac{20}{\sqrt{16}} 2,57583 = 3012,9$$

2987 h a 6 min <  $\mu$  < 3012 h a 54 min s pravděpodobností 0,99

#### Výpočet pomocí systému STATISTICA

Otevřeme nový datový soubor o dvou proměnných d, h a jednom případu.

Do Dlouhého jména proměnné d napíšeme vzorec =3000-20/sqrt(16)\*VNormal(0,995;0;1)

Do Dlouhého jména proměnné h napíšeme vzorec =3000+20/sqrt(16)\*VNormal(0,995;0;1)

ad b)

$$d = m - \frac{\sigma}{\sqrt{n}} u_{0,9} = 3000 - \frac{20}{\sqrt{16}} 1,28155 = 2993,6$$

2993 h a 36 min <  $\mu$  s pravděpodobností 0,9

#### Výpočet pomocí systému STATISTICA

Otevřeme nový datový soubor o jedné proměnné d a jednom případu.

Do Dlouhého jména proměnné d napíšeme vzorec =3000-20/sqrt(16)\*VNormal(0,9;0;1)

ad c)

$$h = m + \frac{\sigma}{\sqrt{n}} u_{0,975} = 3000 + \frac{20}{\sqrt{16}} 1,95996 = 3009,8$$

3009 h a 48 min >  $\mu$  s pravděpodobností 0,95

#### Výpočet pomocí systému STATISTICA

Otevřeme nový datový soubor o jedné proměnné h a jednom případu.

Do Dlouhého jména proměnné h napíšeme vzorec =3000+20/sqrt(16)\*VNormal(0,975;0;1)

**Užitečný odkaz:** na adrese <http://www.prevody-jednotek.cz> je program, s jehož pomocí lze převádět různé fyzikální jednotky, v našem případě hodiny na minuty.

### Základní poznatky o testování hypotéz

Předpokládáme, že testujeme nulovou hypotézu  $H_0: h(\vartheta) = c$ , kde  $c \in \mathbb{R}$  buď proti oboustranné alternativě  $H_1: h(\vartheta) \neq c$  nebo proti levostranné alternativě  $H_1: h(\vartheta) < c$  nebo proti pravostranné alternativě  $H_1: h(\vartheta) > c$ .

### Testování pomocí kritického oboru

Najdeme testovou statistiku  $T_0 = T_0(X_1, \dots, X_n)$ . Množina všech hodnot, jichž může testová statistika nabýt, se rozpadá na obor nezamítnutí nulové hypotézy (značí se  $V$ ) a obor zamítnutí nulové hypotézy (značí se  $W$  a nazývá se též kritický obor).  $V$  a  $W$  jsou odděleny kritickými hodnotami (pro danou hladinu významnosti  $\alpha$  je lze najít ve statistických tabulkách).

Jestliže číselná realizace  $t_0$  testové statistiky  $T_0$  padne do kritického oboru  $W$ , pak nulovou hypotézu zamítáme na hladině významnosti  $\alpha$  a znamená to skutečné vyvrácení testované hypotézy. Jestliže  $t_0$  padne do oboru nezamítnutí  $V$ , pak jde o pouhé mlčení, které platnost nulové hypotézy jenom připouští.

Stanovení kritického oboru pro danou hladinu významnosti  $\alpha$ :

Označme  $t_{\min}$  (resp.  $t_{\max}$ ) nejmenší (resp. největší) hodnotu testového kritéria.

Kritický obor v případě oboustranné alternativy má tvar

$W = \langle t_{\min}, K_{\alpha/2}(T) \rangle \cup \langle K_{1-\alpha/2}(T), t_{\max} \rangle$ , kde  $K_{\alpha/2}(T)$  a  $K_{1-\alpha/2}(T)$  jsou kvantily rozložení, jímž se řídí testové kritérium  $T_0$ , je-li nulová hypotéza pravdivá.

Kritický obor v případě levostranné alternativy má tvar:

$W = \langle t_{\min}, K_{\alpha}(T) \rangle$ .

Kritický obor v případě pravostranné alternativy má tvar:

$W = \langle K_{1-\alpha}(T), t_{\max} \rangle$ .

### Testování pomocí intervalu spolehlivosti

Sestrojíme  $100(1-\alpha)\%$  empirický interval spolehlivosti pro parametrickou funkci  $h(\vartheta)$ .

Pokryje-li tento interval hodnotu  $c$ , pak  $H_0$  nezamítáme na hladině významnosti  $\alpha$ , v opačném případě  $H_0$  zamítáme na hladině významnosti  $\alpha$ .

Pro test  $H_0$  proti oboustranné alternativě sestrojíme oboustranný interval spolehlivosti.

Pro test  $H_0$  proti levostranné alternativě sestrojíme pravostranný interval spolehlivosti.

Pro test  $H_0$  proti pravostranné alternativě sestrojíme levostranný interval spolehlivosti.

### Testování pomocí p-hodnoty

p-hodnota udává nejnižší možnou hladinu významnosti pro zamítnutí nulové hypotézy: je-li  $p \leq \alpha$ , pak  $H_0$  zamítáme na hladině významnosti  $\alpha$ , je-li  $p > \alpha$ , pak  $H_0$  nezamítáme na hladině významnosti  $\alpha$ .

Způsob výpočtu p-hodnoty:

Pro oboustrannou alternativu  $p = 2 \min \{P(T_0 \leq t_0), P(T_0 \geq t_0)\}$ .

Pro levostrannou alternativu  $p = P(T_0 \leq t_0)$ .

Pro pravostrannou alternativu  $p = P(T_0 \geq t_0)$ .

**Příklad 6.:** Víme, že výška hochů ve věku 9,5 až 10 let má normální rozložení s neznámou střední hodnotou  $\mu$  a známým rozptylem  $\sigma^2 = 39,112 \text{ cm}^2$ . Dětský lékař náhodně vybral 15 hochů uvedeného věku, změřil je a vypočítal realizaci výběrového průměru  $m = 139,13 \text{ cm}$ . Podle jeho názoru by výška hochů v tomto věku neměla přesáhnout 142 cm s pravděpodobností 0,95. Lze tvrzení lékaře akceptovat?

**Řešení:** Testujeme  $H_0: \mu = 142$  proti  $H_1: \mu < 142$  (to je tvrzení lékaře) na hladině významnosti 0,05.

a) Test provedeme pomocí kritického oboru.

Pro úlohy o střední hodnotě normálního rozložení při známém rozptylu používáme pivotovou statistiku  $U = \frac{M - \mu}{\sigma} \sim N(0, 1)$ . Testová statistika tedy bude  $T_0 = \frac{M - \mu}{\sigma/\sqrt{n}}$  a bude mít rozložení  $N(0, 1)$ , pokud je nulová hypotéza pravdivá. Vypočítáme realizaci testové statistiky:

$$t_0 = \frac{139,13 - 142}{\sqrt{39,112}} = -1,7773.$$

Stanovíme kritický obor:  $W = (-\infty, u_\alpha) = (-\infty, u_{0,05}) = (-\infty, -1,960) = (-\infty, -1,6449)$ .

Protože  $-1,7773 \in W$ ,  $H_0$  zamítáme na hladině významnosti 0,05. Tvrzení lékaře lze tedy akceptovat s rizikem omylu 5 %.

b) Test provedeme pomocí intervalu spolehlivosti.

Meze  $100(1-\alpha)\%$  empirického pravostranného intervalu spolehlivosti pro střední hodnotu  $\mu$  při známém rozptylu  $\sigma^2$  jsou:  $(-\infty, h) = (-\infty, m + \frac{\sigma}{\sqrt{n}} u_{1-\alpha})$ .

$$V našem případě dostáváme: h = 139,13 + \frac{\sqrt{39,112}}{\sqrt{15}} u_{0,95} = 139,13 + \frac{\sqrt{39,112}}{\sqrt{15}} 1,645 = 141,79.$$

Protože  $142 \notin (-\infty; 141,79)$ ,  $H_0$  zamítáme na hladině významnosti 0,05.

c) Test provedeme pomocí p-hodnoty

$$p = P(T_0 \leq t_0) = \Phi(-1,7773) = 0,0378$$

Jelikož  $0,0378 \leq 0,05$ , nulovou hypotézu zamítáme na hladině významnosti 0,05.

Při řešení tohoto příkladu použijeme systém STATISTICA pouze jako inteligentní kalkulátor.