

## Téma 8: Parametrické úlohy o jednom náhodném výběru z normálního rozložení a dvourozměrného rozložení a jednom náhodném výběru z alternativního rozložení

**Upozornění:** Pokud to povaha úlohy vyžaduje, proveďte test normality dat:

V menu vybereme Statistika – Základní statistiky/tabulky – Tabulky četností – OK, Proměnné X – OK. Na záložce zvolíme Normalita a zaškrtneme Lilieforsův test a Shapiro – Wilksův W test – Testy normality.

### Úkol 1.: Vlastnosti výběrového průměru z normálního rozložení

Předpokládejme, že velký ročník na vysoké škole má výsledky ze statistiky normálně rozloženy kolem střední hodnoty 72 bodů se směrodatnou odchylkou 9 bodů. Najděte pravděpodobnost, že průměr výsledků náhodného výběru 10 studentů bude větší než 80 bodů.

**Návod:**

$X_1, \dots, X_{10}$  je náhodný výběr z  $N(72, 81)$ . Počítáme  $P(M > 80)$ , přičemž výběrový průměr  $M$

má normální rozložení se střední hodnotou  $E(M) = \mu = 72$  a rozptylem  $D(M) = \frac{\sigma^2}{n} = \frac{81}{10} =$

8,1. Tedy  $P(M > 80) = 1 - P(M \leq 80) = 1 - \Phi(80)$ , kde  $\Phi(80)$  je hodnota distribuční funkce rozložení  $N(72; 8,1)$  v bodě 80.

Vytvoříme datový soubor o jedné proměnné a o jednom případě. Do Dlouhého jména této proměnné napíšeme  $=1 - \text{INormal}(80;72;\text{sqrt}(8,1))$ . Zjistíme, že  $1 - \Phi(80) = 0,00247005$ . Funkce  $\text{INormal}(x;\mu;\sigma)$  počítá hodnotu distribuční funkce rozložení  $N(\mu, \sigma^2)$  v bodě  $x$ .

	1
	Prom1
1	0,00247

**Úkol k samostatnému řešení:** Lze předpokládat, že hmotnost pomerančů dodávaných do obchodní sítě se řídí normálním rozložením se střední hodnotou 170 g a směrodatnou odchylkou 12 g. Jaká je pravděpodobnost, že celková hmotnost devíti náhodně vybraných pomerančů balených do sítě překročí 1,5 kg?

**Výsledek:** Hledaná pravděpodobnost je 0,797.

### Úkol 3.: Intervaly spolehlivosti pro parametry $\mu, \sigma^2$ normálního rozložení

Z populace stejně starých selat téhož plemene bylo vylosováno šest selat a po dobu půl roku jim byla podávána táž výkrmná dieta. Byly zaznamenávány průměrné denní přírůstky hmotnosti v Dg. Z dřívějších pokusů je známo, že v populaci mívají takové přírůstky normální rozložení, avšak střední hodnota i rozptyl se mění. Přírůstky v Dg: 62, 54, 55, 60, 53, 58.

- Najděte 95% empirický levostranný interval spolehlivosti pro neznámou střední hodnotu  $\mu$  při neznámé směrodatné odchylce  $\sigma$ .
- Najděte 95% empirický interval spolehlivosti pro směrodatnou odchylku  $\sigma$ .

**Návod:**

Vytvoříme datový soubor o 1 proměnné a 6 případech. Tuto proměnnou nazveme hmotnost a zapíšeme do ní zjištěné údaje.

Statistika – Základní statistiky/tabulky – Popisné statistiky – OK – Proměnná hmotnost – OK – na záložce Detailní výsledky zaškrtneme Meze spolehl. Prům., 95 % změním na 90 %, dále zaškrtneme Meze sp. směr. odch. a všechny ostatní volby odškrtneme – Výpočet.

Proměnná	Popisné statistiky (Tabulka4)			
	Int. spolehl. -90,000%	Int. spolehl. 90,000	Spolehlivost Sm.Odch. -95,000%	Spolehlivost Sm.Odch. +95,000%
hmotnost	54,05683	59,94317	2,233234	8,774739

ad a) Protože mez 95% levostranného intervalu spolehlivosti pro střední hodnotu je stejná jako dolní mez 90% oboustranného intervalu spolehlivosti pro střední hodnotu, vidíme, že  $\mu > 54,06$  Dg s pravděpodobností 0,95.

ad b) Dostáváme výsledek:  $2,23 \text{ g} < \sigma < 8,77 \text{ g}$  s pravděpodobností 0,95.

**Úkol k samostatnému řešení:** Uměle připravený vzorek minerálu byl 12 krát proměřen na obsah křemene. Výsledky měření (v procentech) byly: 8,7 10,2 10,07 9,75 9,65 10,37 10,14 10,5 9,48 11,22 9,49 9,86. Za předpokladu, že výsledky měření obsahu křemene se řídí rozložením  $N(\mu, \sigma^2)$ , vypočtěte 95% empirický interval spolehlivosti

a) pro střední hodnotu  $\mu$

b) pro směrodatnou odchylku  $\sigma$ .

**Výsledek:** Lilieforsův test ani S-W test nezamítají na hladině významnosti 0,05 normalitu dat.

ad a)  $9,55 \% < \mu < 10,35 \%$  s pravděpodobností 0,95.

ad b)  $0,44 \% < \sigma < 1,07 \%$  s pravděpodobností 0,95.

#### Úkol 4.: Testování hypotézy o střední hodnotě $\mu$

Systematická chyba měřicího přístroje se eliminuje nastavením přístroje a měřením etalonu, jehož správná hodnota je  $\mu = 10,00$ . Nezávislými měřeními za stejných podmínek byly získány hodnoty: 10,24 10,12 9,91 10,19 9,78 10,14 9,86 10,17 10,05, které považujeme za realizace náhodného výběru rozsahu 9 z rozložení  $N(\mu, \sigma^2)$ . Je možné při riziku 0,05 vysvětlit odchylky od hodnoty 10,00 působením náhodných vlivů?

#### Návod:

Na hladině významnosti 0,05 testujeme hypotézu  $H_0: \mu = 10$  proti oboustranné alternativě  $H_1: \mu \neq 10$ . Jde o úlohu na jednovýběrový t-test. Ten je ve STATISTICE implementován.

Načteme datový soubor mereni\_etalonu.sta.

**1. způsob:** V Základních statistikách a tabulkách vybereme t-test, samostatný vzorek. Do Referenční hodnoty zapíšeme 10. Ve výstupu se podíváme na hodnotu testového kritéria a na p-hodnotu. Pokud p-hodnota bude menší nebo rovna 0,05, zamítneme hypotézu  $H_0: \mu = 10$  ve prospěch oboustranné alternativní hypotézy  $H_1: \mu \neq 10$  na hladině významnosti 0,05.

V opačném případě  $H_0$  nezamítáme. V našem případě je

Proměnná	Test průměrů vůči referenční konstantě (hodnotě)							
	Průměr	Sm.odch.	N	Sm.chyba	Referenční konstanta	t	SV	p
Prom1	10,05111	0,162669	9	0,054223	10,00000	0,942611	8	0,373470

Protože p-hodnota  $0,373470 > 0,05$  nulovou hypotézu nezamítáme na hladině významnosti 0,05. S rizikem omylu nejvýše 5% lze tedy odchylky od hodnoty 10 vysvětlit působením náhodných vlivů.

Všimněme si ještě hodnoty testového kritéria:  $t_0 = 0,942611$ . Kritický obor

$$W = (-\infty, -t_{1-\alpha/2}(n-1)) \cup (t_{1-\alpha/2}(n-1), \infty) = (-\infty, -t_{0,975}(8)) \cup (t_{0,975}(8), \infty) = (-\infty, -2,306) \cup (2,306, \infty)$$

Protože  $t_0 \notin W$ , nezamítáme na hladině významnosti 0,05 hypotézu  $H_0$ .

**2. způsob:** V Základních statistikách a tabulkách vypočteme průměr a směrodatnou odchylku. Pak použijeme Testy rozdílů: r, %, průměry – OK – vybereme Rozdíl mezi dvěma průměry (normální rozdělení) – zaškrtneme Výběrový průměr vs. Střední hodnota – do políčka Pr1 napíšeme 10,05111, do políčka SmOd1 napíšeme 0,162669, do políčka N1 napíšeme 9, do políčka Pr2 napíšeme 10 - Výpočet. Dostaneme p-hodnotu 0,3735, tedy nezamítáme nulovou hypotézu na hladině významnosti 0,05.

**Úkol k samostatnému řešení:** Při kontrole balicího automatu, který má plnit cukrem balíčky o hmotnosti 1000 g, byly při přesném převážení 5 balíčků zjištěny tyto odchylky (v gramech) od požadované hodnoty: 3, -2, 2, 0, 1. Na hladině významnosti 0,05 testujte hypotézu, že automat nemá systematickou odchylku od požadované hodnoty.

**Výsledek:** Protože p-hodnota je 0,405023, nulovou hypotézu nezamítáme na hladině významnosti 0,05.

### Úkol 5.: Testování hypotézy o směrodatné odchylce $\sigma$

U 25 náhodně vybraných dvoulitrových lahví s nealkoholickým nápojem byl zjištěn přesný objem nápoje. Výběrový průměr činil  $m = 1,99$  l a výběrová směrodatná odchylka  $s = 0,1$  l. Předpokládejme, že objem nápoje v láhvi je náhodná veličina s normálním rozložením. Na hladině významnosti 0,05 ověřte tvrzení výrobce, že směrodatná odchylka je 0,08 l.

#### Návod:

Na hladině významnosti 0,05 testujeme hypotézu  $H_0: \sigma = 0,08$  proti oboustranné alternativě  $H_1: \sigma \neq 0,08$  neboli  $H_0: \sigma^2 = 0,0064$  proti oboustranné alternativě  $H_1: \sigma^2 \neq 0,0064$ . Jde o úlohu

na test o rozptylu. Vypočteme realizaci testového kritéria  $t_0 = \frac{(n-1)s^2}{c} = \frac{24 \cdot 0,1^2}{0,08^2} = 37,5$ .

Jelikož hodnota testového kritéria 37,5 neleží v kritickém oboru

$W = (0; \chi^2_{0,025}(24)) \cup (\chi^2_{0,975}(24); \infty) = (0; 12,4) \cup (39,4; \infty)$ , nejsme oprávněni na hladině významnosti 0,05 zamítnout tvrzení výrobce.)

V systému STATISTICA otevřeme datový soubor o třech proměnných a jednom případě. Do Dlouhého jména první proměnné napíšeme vzorec pro výpočet testového kritéria:

$$=24*0,1^2/0,08^2$$

Další dvě proměnné nám poslouží k výpočtu kvantilů Pearsonova  $\chi^2$  – rozložení.

Do Dlouhého jména druhé proměnné napíšeme

$$=VChi2(0,025;24)$$

a do Dlouhého jména třetí proměnné napíšeme

$$=VChi2(0,975;24)$$

### Úkol 6.: Interval spolehlivosti pro rozdíl parametrů $\mu_1 - \mu_2$ dvourozměrného rozložení

Bylo vylosováno 6 vrhů selat a z nich vždy dva sourozenci. Jeden z nich vždy dostal náhodně dietu č. 1 a druhý dietu č. 2. Přírůstky v Dg jsou následující: (62,52), (54,56), (55,49), (60,50), (53,51), (58,50). Za předpokladu, že uvedené dvojice tvoří náhodný výběr z dvourozměrného rozložení s vektorem středních hodnot  $(\mu_1, \mu_2)$  a jejich rozdíly se řídí normálním rozložením, sestrojte 95% interval spolehlivosti pro rozdíl středních hodnot.

#### Návod:

Vytvoříme datový soubor o třech proměnných a šesti případech. Do proměnných v1 a v2 zapíšeme naměřené přírůstky, do proměnné v3 uložíme rozdíly v1 - v2. Ve STATISTICE je implementován výpočet oboustranného intervalu spolehlivosti pro  $\mu$ , když  $\sigma^2$  neznáme. Pomocí Popisných statistik zjistíme meze 95% intervalu spolehlivosti pro střední hodnotu proměnné v3 tak, že zaškrtneme Meze spolehl. prům.

Proměnná	Popisné statistiky	
	Int. spolehl. -95,000%	Int. spolehl. +95,000%
Prom3	0,626461	10,70687

Dostaneme výsledek:  $0,63 \text{ Dg} < \mu < 10,71 \text{ Dg}$  s pravděpodobností 0,95.

### Úkol 7.: Testování hypotézy o rozdílu parametrů $\mu_1 - \mu_2$ dvourozměrného rozložení

Bylo vybráno šest nových vozů téže značky a po určité době bylo zjištěno, o kolik mm se sjely jejich levé a pravé přední pneumatiky. Výsledky: (1,8; 1,5), (1,0; 1,1), (2,2; 2,0), (0,9; 1,1), (1,5; 1,4), (1,6; 1,4). Za předpokladu, že uvedené dvojice tvoří náhodný výběr z dvourozměrného rozložení s vektorem středních hodnot  $(\mu_1, \mu_2)$  a jejich rozdíly se řídí normálním rozložením, testujte na hladině významnosti 0,05 hypotézu, že obě pneumatiky se sjíždějí stejně rychle.

#### Návod:

Označme  $\mu = \mu_1 - \mu_2$ . Na hladině významnosti 0,05 testujeme hypotézu  $H_0: \mu = 0$  proti oboustranné alternativě  $H_1: \mu \neq 0$ . Jde o úlohu na párový t-test. Ten je ve STATISTICE implementován. Vytvoříme datový soubor o dvou proměnných a šesti případech. Do proměnných v1 a v2 zapíšeme naměřené přírůstky. V Základních statistikách vybereme t-test, závislé vzorky. Zadáme názvy obou proměnných a ve výstupu se podíváme na hodnotu testového kritéria a na p-hodnotu.

Proměnná	t-test pro závislé vzorky (Tabulka1)							
	Průměr	Sm.odch.	N	Rozdíl	Sm.odch. rozdílů	t	sv	p
X	1,500000	0,489898						
Y	1,416667	0,331160	6	0,083333	0,194079	1,051758	5	0,341062

Protože p-hodnota  $0,341062 > 0,05$ , nezamítáme na hladině významnosti 0,05 hypotézu, že obě přední pneumatiky se sjíždějí stejně rychle.

Všimněme si ještě hodnoty testového kritéria:  $t_0 = 1,051758$ . Kritický obor

$$W = (-\infty, -t_{1-\alpha/2}(n-1)) \cup (t_{1-\alpha/2}(n-1), \infty) = (-\infty, -t_{0,975}(5)) \cup (t_{0,975}(5), \infty) = (-\infty, -2,5706) \cup (2,5706, \infty)$$

Protože  $t_0 \notin W$ , nezamítáme na hladině významnosti 0,05 hypotézu  $H_0$ .

**Úkol k samostatnému řešení:** Zkouška ze statistiky se skládá z písemné části, v níž je možno získat maximálně 20 bodů a z ústní části, kde je možno získat maximálně 10 bodů. Výsledky 20 náhodně vybraných studentů (X – počet bodů z písemné části, Y – počet bodů z ústní části):

č. st.	1	2	3	4	5	6	7	8	9	10
X	6	11	8	18	6	11	6	3	14	7
Y	4	7	6	8	3	5	6	4	9	8

č. st.	11	12	13	14	15	16	17	18	19	20
X	17	12	8	4	15	20	13	5	10	0
Y	10	9	6	5	7	10	8	6	7	3

Na hladině významnosti 0,05 testujte hypotézu, že rozdíl středních hodnot počtu bodů v písemné a ústní části se liší o 3 body proti oboustranné alternativě. Data jsou uložena v souboru body ze zkousky.sta

**Výsledek:** Lilieforsův test ani S-W test nezamítají na hladině významnosti 0,05 hypotézu o normalitě rozdílů.

Testujeme  $H_0: \mu_1 - \mu_2 = 3$  proti  $H_1: \mu_1 - \mu_2 \neq 3$ . Hodnota testové statistiky = 0,178431, p-hodnota = 0,806273, na hladině významnosti 0,05 tedy nezamítáme nulovou hypotézu.

### Úkol 8.: Asymptotický interval spolehlivosti pro parametr $\vartheta$ alternativního rozložení

Může politická strana, pro niž se v předvolebním průzkumu vyslovilo 60 z 1000 dotázaných osob, očekávat se spolehlivostí 0,95, že by v této době ve volbách překročila 5% hranici pro vstup do parlamentu?

**Návod:** Zavedeme náhodné veličiny  $X_1, \dots, X_{1000}$ , přičemž  $X_i = 1$ , když i-tá osoba se vysloví pro danou politickou stranu a  $X_i = 0$  jinak,  $i = 1, \dots, 1000$ . Tyto náhodné veličiny tvoří náhodný výběr z rozložení  $A(\vartheta)$ . V tomto případě  $n = 1000$ ,  $m = 60/1000 = 0,06$ ,  $\alpha = 0,05$ ,  $u_{1-\alpha} = u_{0,95} = 1,645$ .

Ověření podmínky  $n\vartheta(1-\vartheta) > 9$ : parametr  $\vartheta$  neznáme, musíme ho nahradit výběrovým průměrem. Pak  $1000 \cdot 0,06 \cdot 0,94 = 56,4 > 9$ .

95% levostranný interval spolehlivosti pro  $\vartheta$  je

$$\left( m - \sqrt{\frac{m(1-m)}{n}} u_{1-\alpha} ; \infty \right) = \left( 0,06 - \sqrt{\frac{0,06(1-0,06)}{1000}} u_{0,95} ; \infty \right). \text{ V našem případě}$$

$$d = 0,06 - \sqrt{\frac{0,06 \cdot 0,94}{1000}} \cdot 1,645 = 0,0476$$

S pravděpodobností přibližně 0,95 tedy  $\vartheta > 0,048$ . Protože tento interval zahrnuje i hodnoty nižší než 0,05, nelze vyloučit, že strana získá méně než 5% hlasů.

### Postup ve STATISTICE:

Asymptotický způsob: Vytvoříme datový soubor o jedné proměnné (nazveme ji d) a o jednom případě. Do Dlouhého jména proměnné d napíšeme

$$=0,06-\text{sqrt}(0,06*0,94/1000)*\text{VNormal}(0,95;0;1)$$

Vyjde 0,047647.

Přibližný způsob: Do nového datového souboru o jedné proměnné X a 1000 případech uložíme 60 jedniček (indikují volbu dané politické strany) a 940 nul (indikují volbu jiné politické strany).

Statistika – Základní statistiky a tabulky – Popisné statistiky – OK – Proměnné X – OK – Detailní výsledky – zaškrtneme Meze spolehl. prům. – Interval 90,00 – Výpočet.

Dostaneme tabulku:

Proměnná	Popisné statistiky (Tabulka1)			
	N platných	Průměr	Int. spolehl. -90,000%	Int. spolehl. 90,000
X	1000	0,060000	0,047630	0,072370

Protože dolní mez oboustranného 90% intervalu spolehlivosti pro střední hodnotu je shodná s dolní mezí 95% jednostranného intervalu spolehlivosti, můžeme konstatovat, že voliči budou volit danou politickou stranu s pravděpodobností aspoň 4,76%. Na základě uvedených dat strana tedy nemá zaručeno, že překročí 5% hranici pro vstup do parlamentu.

**Úkol k samostatnému řešení:** Přírůstky cen akcií na burze (v %) u 10 náhodně vybraných společností dosáhly těchto hodnot: 10, 16, 5, 10, 12, 8, 4, 6, 5, 4. Sestrojte 95% asymptotický empirický interval spolehlivosti pro pravděpodobnost, že přírůstek ceny akcie překročí 8,5%.  
**Výsledek:**  $0,096 < \vartheta < 0,704$  s pravděpodobností aspoň 0,95.

Znamená to, že pravděpodobnost, že přírůstek ceny akcie překročí 8,5%, je aspoň 9,6% a nanejvýš 70,4% (při spolehlivosti 95%).

### Úkol 9.: Testování hypotézy o parametru $\vartheta$ alternativního rozložení

Určitá cestovní kancelář organizuje zahraniční zájezdy podle individuálních přání zákazníků. Z několika minulých let ví, že 30% všech takto organizovaných zájezdů má za cíl zemi X. Po zhoršení politických podmínek v této zemi se cestovní kancelář obává, že se zájem o tuto zemi mezi zákazníky sníží. Ze 150 náhodně vybraných zákazníků v tomto roce má 38 za cíl právě zemi X. Potvrzují nejnovější data pokles zájmu o tuto zemi? Volte hladinu významnosti 0,05.

**Návod:** Máme náhodný výběr  $X_1, \dots, X_{150}$  z rozložení  $A(0,3)$ . Testujeme  $H_0: \vartheta = 0,3$  proti jednostranné alternativě  $H_1: \vartheta < 0,3$ . V tomto případě je testovým kritériem statistika

$$T_0 = \frac{M - c}{\sqrt{\frac{c(1-c)}{n}}}, \text{ která v případě platnosti nulové hypotézy má asymptoticky rozložení } N(0,1).$$

Musíme ověřit splnění podmínky  $n\vartheta(1-\vartheta) > 9$ :  $150 \cdot 0,3 \cdot 0,7 = 31,5 > 9$ . Vypočteme realizaci

$$\text{testového kritéria: } t_0 = \frac{m - c}{\sqrt{\frac{c(1-c)}{n}}} = \frac{\frac{38}{150} - 0,3}{\sqrt{\frac{0,3(1-0,3)}{150}}} = -1,24722. \text{ Kritický obor:}$$

$W = (-\infty, -u_{1-\alpha}) = (-\infty, -1,645)$ . Protože testové kritérium nepatří do kritického oboru,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

### Postup ve STATISTICE:

Asymptotický způsob: Vytvoříme datový soubor o dvou proměnných (nazveme je  $t_0$  a kvantil) a jednom případě. Vypočteme realizaci testového kritéria tak, že do Dlouhého jména proměnné  $t_0$  napíšeme

$$=(38/150-0,3)/\text{sqrt}(0,3*0,7/150)$$

Do Dlouhého jména proměnné kvantil napíšeme

$$=V\text{Normal}(0,95;0;1)$$

Tím získáme kvantil  $u_{0,95}$ .

	1	2
	t0	kvantil
1	-1,24721913	1,644854

Jelikož realizace testového kritéria  $t_0 = -1,24721913$  nepatří do kritického oboru  $W = (-\infty, -1,644854)$ ,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

Přibližný způsob: Do nového datového souboru o jedné proměnné X a 150 případech uložíme 38 jedniček (indikují zájem o danou zemi) a 112 nul (indikují nezájem o danou zemi).  
 Statistika – Základní statistiky a tabulky – t-test, samost. vzorek – OK – Proměnné X – OK,  
 Test všech průměrů vůči 0,3 – Výpočet.

Proměnná	Test průměrů vůči referenční konstantě (hodnotě) (Tabulka4)							
	Průměr	Sm.odch.	N	Sm.chyba	Referenční konstanta	t	SV	p
X	0,253333	0,436377	150	0,035630	0,300000	-1,30976	149	0,192294

Hodnota testové statistiky je při tomto přibližném způsobu -1,30976. Odpovídající p-hodnota je 0,1923, ovšem to je p-hodnota pro oboustranný test. Tuto p-hodnotu tedy musíme dělit dvěma a dostaneme 0,0961. Na asymptotické hladině významnosti 0,05 nelze zamítnout hypotézu, že zájem o danou zemi se nezměnil.