

## Varianta S2

**Teoretické otázky:**

- 1) Když zamítnete hypotézu  $\mu = \mu_0$  při jednostranném testu, zamítnete ji při stejné hladině významnosti také při oboustranném testu? Proč?
- 2) Jaký je vztah mezi binomickým, hypergeometrickým a Poissonovým rozdělením?
- 3) K čemu slouží variační koeficient? Jaká je jeho přednost?
- 4) Co měří dílčí korelační koeficient a co vícenásobný korelační koeficient?
- 5) Co si představujete pod pojmem „dekompozice časové řady“?

**Příklady:**

- 1) Určitá linka městské autobusové dopravy jezdí v době dopravní špičky v centru města průměrnou rychlostí 8 km/h. Vedení dopravního podniku uvažovalo o tom, zda by změna trasy dané linky vedla ke zvýšení průměrné rychlosti. Nová trasa proto byla projeta v deseti náhodně vybraných dnech v době dopravní špičky a byly zjištěny tyto průměrné rychlosti (v km/h):

8,5   9,5   7,8   8,2   9,0   7,5   8,2   7,8   9,0   8,5

Rozhodněte na 5 %-ní hladině významnosti, zda změna trasy vede ke zvýšení průměrné rychlosti, přičemž předpokládejte normální rozdělení rychlosti autobusu v centru v době dopravní špičky. 2 BODY

- 2) Při silniční kontrole byly u náhodně vybraných 200 vozidel zjišťovány závady na osvětlení a pneumatikách. Posuďte na hladině významnosti 1 %, zda existuje závislost mezi závadami na pneumatikách a osvětlení, případně změřte sílu a směr závislosti vhodnou charakteristikou. 2 BODY

Závady na pneumatikách	Závady na osvětlení	
	ANO	NE
ANO	32	12
NE	16	140

- 3) V následující tabulce máte údaje o vývozu osobních automobilů do určité země v letech 1990 – 1997. Posuďte, jakou trendovou funkci je vhodné použít k popisu trendu tohoto ukazatele (omezte svůj výběr na přímku, parabolu a exponenciálu). Své rozhodnutí zdůvodněte. Odhadněte vývoz automobilů (v tis. Kč) na rok 2000 na základě funkce, kterou jste vybrali jako nejužitečnější. Uvažujte  $\alpha = 0,05$ . 3 BODY

Rok	1990	1991	1992	1993	1994	1995	1996	1997
Vývoz v tis. Kč	60	58	55	53	51	48	46	44

Celkový počet bodů: 12

Minimální počet bodů pro úspěšné složení zkoušky: 7,25

Minimální počet bodů z teorie: 1,75

Minimální počet bodů z příkladů: 2,5

Každá teoretická otázka je za 1 bod.

## Teoretické otázky – řešení:

- 1) Tato hypotéza by zamítnuta být nemusela, a to z důvodu „nepřekrývání“ se kritického oboru pro jednostranný a oboustranný test. Např. když  $H_1: \mu \neq \mu_0$ , potom může být kritický obor při zvolené hladině významnosti 0,05 následující:  $W \equiv \left\{U; U \leq u_{\frac{\alpha}{2}} \cup U \geq u_{1-\frac{\alpha}{2}}\right\}$  a konkrétně  $W \equiv \{U; U \leq u_{0,025} \cup U \geq u_{0,975}\}$ , tj.  $W \equiv \{U; U \leq -1,96 \cup U \geq 1,96\}$ .  
U jednostranného testu, kdy je např.  $H_1: \mu > \mu_0$ , je kritický obor  $W \equiv \{U; U \geq u_{1-\alpha}\}$ , konkrétně tedy:  $W \equiv \{U; U \geq u_{0,95}\}$ , tj.  $W \equiv \{U; U \geq 1,645\}$ .  
Pokud hodnota testového kritéria bude např.  $U = 1,75$ , pak u oboustranného testu nevedla k zamítnutí  $H_0$ , ale u jednostranného ano.
- 2) Všechno to jsou rozdělení nespojitých náhodných veličin. Hypergeometrické rozdělení můžeme za určitých podmínek aproximovat buď Binomickým, nebo Poissonovým rozdělením. Binomické rozdělení lze za určitých podmínek aproximovat Poissonovým rozdělením.
- 3) Slouží k měření relativní variability číselných proměnných. Jeho výhodou je, že jde o bezrozměrné číslo, můžeme tak porovnávat variabilitu souborů, kde hodnoty jsou v různých měrných jednotkách.
- 4) Dílčí korelační koeficient měří sílu lineární závislosti závisle proměnné  $y$  na proměnné  $x_1$  za předpokladu, že všechny ostatní vysvětlující proměnné (uvedené za tečkou) jsou konstantní. Vícenásobný korelační koeficient měří těsnost lineární závislosti závisle proměnné  $y$  na všech vysvětlujících proměnných dohromady.
- 5) Dekompozici časové řady rozumíme rozklad časové řady na složky, které charakterizují různé druhy pohybu v čase. Rozlišujeme složku trendovou, sezónní, cyklickou a náhodnou.

## Příklady – řešení:

- 1)  $H_0: \mu = 8$   
 $H_1: \mu > 8$

$$t = \frac{\bar{x} - \mu}{\frac{s'_x}{\sqrt{n}}}$$

$$W \equiv \{t; t \geq t_{1-\alpha}(n-1)\}$$

$$W \equiv \{t; t \geq t_{0,95}(9)\}$$

$$W \equiv \{t; t \geq 1,833\}$$

Z dat vypočítáme výběrové charakteristiky:

$$\bar{x} = 8,4$$

$$s'_x = 0,629$$

$$t = \frac{\bar{x} - \mu}{\frac{s'_x}{\sqrt{n}}} = \frac{8,4 - 8}{\frac{0,629}{\sqrt{10}}} = 2,011$$

$t \in W$ , proto zamítáme  $H_0$  a přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že změna trasy autobusu MHD vede ke zvýšení průměrné rychlosti.

Poznámka: Lze řešit i ve statistickém programu. Rozhodnutí provádíme podle tzv. significance level, někde uváděné také jako P-Value. Zde je P-Value = 0,037591. Protože P-Value <  $\alpha$ , zamítáme  $H_0$  a přijímáme  $H_1$ .

- 2) Jde o kategoriální (nominální) znaky, proto je vhodnou metodou zkoumání závislostí mezi nimi test nezávislosti kategoriálních znaků. Zde obě proměnné nabývají pouze 2 obměn, jsou to tedy alternativní proměnné. Lze použít zjednodušenou verzi testu nezávislosti kategoriálních znaků.

$H_0$ : Závady na pneumatikách a na osvětlení na sobě nezávisí

$H_1$ : non  $H_0$

$$G = n \cdot \frac{(n_{11}n_{22} - n_{12}n_{21})^2}{n_{1.}n_{2.}n_{.1}n_{.2}}$$

$$W \equiv \{G; G \geq \chi_{1-\alpha}^2[(r-1)(s-1)]\}$$

$$W \equiv \{G; G \geq \chi_{0,99}^2(1)\}$$

$$W \equiv \{G; G \geq 6,639\}$$

$$G = 200 \cdot \frac{(32 \cdot 140 - 16 \cdot 12)^2}{48 \cdot 152 \cdot 44 \cdot 156} = 73,43$$

$G \in W$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 1 % jsme prokázali, že mezi závadami na pneumatikách a na osvětlení existuje závislost.

Pozn.: Pokud řešíme ve statistickém programu, posuzujeme výsledek testu podle tzv. P-Value. Zde je P-Value = 0,0000, což je méně než  $\alpha$ , proto zamítáme  $H_0$  a přijímáme  $H_1$ .

Těsnost závislosti změříme pomocí koeficientu asociace:

$$r_{AB} = \frac{n_{11}n_{22} - n_{12}n_{21}}{\sqrt{n_{1.}n_{2.}n_{.1}n_{.2}}}$$

$$r_{AB} = \frac{32 \cdot 140 - 16 \cdot 12}{\sqrt{48 \cdot 152 \cdot 44 \cdot 156}} = 0,606$$

Závislost mezi závadami je středně vysoká a přímá, tj. závady na pneumatikách se vyskytují častěji, když se zároveň vyskytnou závady na osvětlení.

- 3) Doporučeno řešit ve statistickém programu.

### Přímka

#### Simple Regression - vyvoz vs. t

Dependent variable: vyvoz

Independent variable: t

Linear model:  $Y = a + b \cdot X$

#### Coefficients

	<i>Least Squares</i>	<i>Standard</i>	<i>T</i>	
<i>Parameter</i>	<i>Estimate</i>	<i>Error</i>	<i>Statistic</i>	<i>P-Value</i>
Intercept	62,3214	0,232829	267,671	0,0000
Slope	-2,32143	0,0461069	-50,3488	0,0000

### Analysis of Variance

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Model	226,339	1	226,339	2535,00	0,0000
Residual	0,535714	6	0,0892857		
Total (Corr.)	226,875	7			

Correlation Coefficient = -0,998819

R-squared = 99,7639 percent

R-squared (adjusted for d.f.) = 99,7245 percent

Rovnice:  $\hat{T}_t = 62,3214 - 2,3214t$

Celkový F-test (posouzení vhodnosti přímky k vyrovnání daných hodnot):

$H_0: \alpha_0 = c, \alpha_1 = 0$  (přímka není vhodná k vyrovnání daných hodnot)

$H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že přímka je vhodným modelem k vyrovnání daných hodnot.

Individuální t-testy o nulové hodnotě parametrů trendové funkce (posouzení vhodnosti jednotlivých parametrů):

$H_0: \alpha_0 = 0$  (parametr  $\alpha_0$  není pro funkci přínosný)

$H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že parametr  $\alpha_0$  je statisticky významný.

$H_0: \alpha_1 = 0$  (parametr  $\alpha_1$  není pro funkci přínosný)

$H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že parametr  $\alpha_1$  je statisticky významný.

Závěr: Vzhledem k tomu, že celkový F-test je významný a oba t-testy také, je možné přímku použít k vyrovnání uvedených hodnot.

### Parabola

#### Polynomial Regression - vyvoz versus t

Dependent variable: vyvoz

Independent variable: t

Order of polynomial = 2

		Standard	T	
Parameter	Estimate	Error	Statistic	P-Value
CONSTANT	62,5893	0,433234	144,47	0,0000
t	-2,48214	0,220881	-11,2375	0,0001
t <sup>2</sup>	0,0178571	0,0239579	0,745356	0,4896

### Analysis of Variance

Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Model	226,393	2	113,196	1173,89	0,0000
Residual	0,482143	5	0,0964286		
Total (Corr.)	226,875	7			

R-squared = 99,7875 percent

R-squared (adjusted for d.f.) = 99,7025 percent

Rovnice:  $\hat{T}_t = 62,5893 - 2,48214t + 0,0178571t^2$

*Celkový F-test* (posouzení vhodnosti paraboly k vyrovnání daných hodnot):

$H_0: \alpha_0 = c, \alpha_1 = \alpha_2 = 0$  (parabola není vhodná k vyrovnání daných hodnot)  
 $H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že parabola je vhodným modelem k vyrovnání daných hodnot.

*Individuální t-testy o nulové hodnotě parametrů trendové funkce* (posouzení vhodnosti jednotlivých parametrů):

$H_0: \alpha_0 = 0$  (parametr  $\alpha_0$  není pro funkci přínosný)  
 $H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že parametr  $\alpha_0$  je statisticky významný.

$H_0: \alpha_1 = 0$  (parametr  $\alpha_1$  není pro funkci přínosný)  
 $H_1: \text{non } H_0$

P-Value = 0,0001 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že parametr  $\alpha_1$  je statisticky významný.

$H_0: \alpha_2 = 0$  (parametr  $\alpha_2$  není pro funkci přínosný)  
 $H_1: \text{non } H_0$

P-Value = 0,4896 >  $\alpha$ , tj. nezamítáme  $H_0$ , nepřijímáme  $H_1$ .

Na hladině významnosti 5 % jsme neprokázali, že parametr  $\alpha_2$  je statisticky významný. To naznačuje, že počet parametrů je příliš velký a stačily by pravděpodobně dva.

Závěr: Vzhledem k tomu, že celkový F-test je významný a většina t-testů také, je možné parabolu použít k vyrovnání uvedených hodnot.

## Exponenciála

### Simple Regression - vyvoz vs. t

Dependent variable: vyvoz

Independent variable: t

Exponential model:  $Y = \exp(a + b \cdot X)$

#### Coefficients

	<i>Least Squares</i>	<i>Standard</i>	<i>T</i>	
<i>Parameter</i>	<i>Estimate</i>	<i>Error</i>	<i>Statistic</i>	<i>P-Value</i>
Intercept	4,14587	0,00497813	832,817	0,0000
Slope	-0,0449638	0,000985816	-45,6107	0,0000

NOTE: intercept = ln(a)

#### Analysis of Variance

<i>Source</i>	<i>Sum of Squares</i>	<i>Df</i>	<i>Mean Square</i>	<i>F-Ratio</i>	<i>P-Value</i>
Model	0,084913	1	0,084913	2080,34	0,0000
Residual	0,000244902	6	0,000040817		
Total (Corr.)	0,0851579	7			

Correlation Coefficient = -0,998561

R-squared = 99,7124 percent

R-squared (adjusted for d.f.) = 99,6645 percent

Rovnice:  $\hat{T}_t = e^{4,14587-0,0449638t}$

Celkový F-test (posouzení vhodnosti exponenciály k vyrovnání daných hodnot):

$H_0: \alpha_0 = c, \alpha_1 = 0$  (exponenciála není vhodná k vyrovnání daných hodnot)

$H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že exponenciála je vhodným modelem k vyrovnání daných hodnot.

Individuální t-testy o nulové hodnotě parametrů trendové funkce (posouzení vhodnosti jednotlivých parametrů):

$H_0: \alpha_0 = 0$  (parametr  $\alpha_0$  není pro funkci přínosný)

$H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že parametr  $\alpha_0$  je statisticky významný.

$H_0: \alpha_1 = 0$  (parametr  $\alpha_1$  není pro funkci přínosný)

$H_1: \text{non } H_0$

P-Value = 0,0000 <  $\alpha$ , tj. zamítáme  $H_0$ , přijímáme  $H_1$ .

Na hladině významnosti 5 % jsme prokázali, že parametr  $\alpha_1$  je statisticky významný.

Závěr: Vzhledem k tomu, že celkový F-test je významný a oba t-testy také, je možné exponenciálu použít k vyrovnání uvedených hodnot.

**Z výše uvedeného vyplývá, že všechny uvedené funkce jsou použitelné k vyrovnání daných hodnot. Otázkou je, která z těchto funkcí je nejlépejší. K řešení použijeme vybraná matematicko-statistická kritéria:**

Kritérium	Přímka	Parabola	Exponenciála
F	2535	1173,89	2080,335
$S_R^2$	0,08929	0,09643	0,00004
$I_{adj}^2$	0,997	0,997	0,997

Podle hodnoty testového kritéria F se jako nejlepší jeví trendová přímka.

Podle hodnoty reziduálního rozptylu bychom jako nejlépejší funkci vybrali trendovou exponenciálu. Podle hodnoty upraveného indexu determinace bychom se mohli přiklonit k jakékoli z těchto tří funkcí. Záleží na tom, které kritérium si vybereme. Tu funkci pak zvolíme. Zde bychom pravděpodobně vybrali přímku, protože má nejvyšší hodnotu F a je zároveň ze všech tří uvedených funkcí nejjednodušší.

Předpověď vývozu automobilů na rok 2000 na základě trendové přímky:

$$\hat{T}_t = 62,3214 - 2,3214t$$

$$\hat{T}_{11} = 62,3214 - 2,3214 \cdot 11$$

$$\hat{T}_{11} = 36,786$$

Za předpokladu, že se trend vývoje nezmění, lze v roce 2000 očekávat vývoz automobilů v hodnotě 36,786 tis. Kč.