

# Jednoduchá lineární regrese II

## Model regresní přímky

Máme regresní model  $Y = \beta_0 + \beta_1 x + \varepsilon$ , kde

$y = \beta_0 + \beta_1 x$  - **teoretická regresní přímka** (deterministická složka modelu).

(Parametr  $\beta_0$  interpretujeme jako teoretickou hodnotu  $Y$  při  $x = 0$  a  $\beta_1$  udává změnu  $Y$ , když  $X$  se změní o jednotku.)

Složka  $\varepsilon$  - **náhodná složka** modelu.

## Předpoklady použití regresní přímky:

- Závislost  $Y$  na  $X$  má lineární charakter.
- Pro celý rozsah uvažovaných hodnot nezávisle proměnné  $X$  je reziduální rozptyl  $s^2$  konstantní (hovoříme o homoskedasticitě a znamená to, že variabilita hodnot závisle proměnné veličiny  $Y$  kolem regresní přímky je stejná pro všechny uvažované hodnoty nezávisle proměnné veličiny  $X$ ).
- Hodnoty závisle proměnné veličiny  $Y$  mají normální rozložení pro dané hodnoty  $x_i$  a jsou stochasticky nezávislé (to souvisí s uspořádáním experimentu).

**Poznámka:** Menší odchylky od normality a homoskedasticity je možno tolerovat.

## System normálních rovnic pro regresní přímku

Uvažujeme regresní model  $Y = \beta_0 + \beta_1 x + \varepsilon$ .

System normálních rovnic pro odhad regresních parametrů  $\beta_0$  a  $\beta_1$  získáme derivováním výrazu


$$q(\beta_0, \beta_1) = \frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \text{ parciálně podle } \beta_0 \text{ a } \beta_1:$$

$$\frac{\partial q(\beta_0, \beta_1)}{\partial \beta_0} = 2 \frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)(-1) = 0, \quad \frac{\partial q(\beta_0, \beta_1)}{\partial \beta_1} = 2 \frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)(-x_i) = 0$$

Řešením tohoto systému získáme odhady  $b_0 = \frac{\sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i\right)^2}$ ,  $b_1 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i\right)^2}$

Po jednoduchých úpravách dospějeme ke tvaru  $b_1 = \frac{s_{12}}{s_1^2}$ , kde  $s_{12}$  je kovariance hodnot  $(x_i, y_i)$ ,  $i = 1, \dots, n$  a  $s_1^2$  je rozptyl

hodnot  $x_1, \dots, x_n$ . Dále dostáváme  $b_0 = m_2 - b_1 m_1$ , tedy regresní přímku můžeme vyjádřit ve tvaru  $y = m_2 + \frac{s_{12}}{s_1^2} (x - m_1)$ .



## Index determinace regresní přímky

Kvalitu regresních modelů posuzujeme mj. pomocí indexu determinace:  $ID^2 = \frac{S_R}{S_T}$ , kde

$S_R = \sum_{i=1}^n (\hat{y}_i - m_2)^2$  je regresní součet čtverců a  $S_T = \sum_{i=1}^n (y_i - m_2)^2$  je celkový součet čtverců.

Pro regresní přímku má regresní součet čtverců tvar:

$$S_R = \sum_{i=1}^n (\hat{y}_i - m_2)^2 = \sum_{i=1}^n \left[ m_2 + \frac{s_{12}}{s_1} (x_i - m_1) - m_2 \right]^2 = \frac{s_{12}^2}{s_1^2} \sum_{i=1}^n (x_i - m_1)^2 = n \frac{s_{12}^2}{s_1^2}.$$

Celkový součet čtverců  $S_T = \sum_{i=1}^n (y_i - m_2)^2 = ns_2^2$ , tedy index determinace

$$ID^2 = \frac{S_R}{S_T} = \frac{n \frac{s_{12}^2}{s_1^2}}{ns_2^2} = \frac{s_{12}^2}{s_1^2 s_2^2} = r_{12}^2$$

Vidíme tedy, že v případě regresní přímky **index determinace je roven kvadrátu koeficientu korelace**.

Index determinace nabývá hodnot z intervalu  $\langle 0,1 \rangle$ . Často se vyjadřuje v procentech a informuje nás o tom, jakou část variability hodnot závisle proměnné veličiny Y vyčerpává regresní model.

## Sdružené regresní přímky

Předpokládáme, že obě veličiny  $Y$  a  $X$  jsou náhodné a veličina  $X$  nezávisí na náhodné složce  $\varepsilon$ . Pak jde o případ oboustranné závislosti.

Závislost  $Y$  na  $X$  vystihuje regresní model  $Y = \beta_0 + \beta_1 x + \varepsilon$ ,

závislost  $X$  na  $Y$  vystihuje regresní model  $X = \alpha_0 + \alpha_1 y + \delta$ .

Odhady  $a_0, a_1$  regresních parametrů  $\alpha_0, \alpha_1$  v modelu  $X_i = \alpha_0 + \alpha_1 y_i + \delta_i$  získáme opět MNČ ve tvaru

$$a_1 = \frac{s_{12}}{s_2}, a_0 = m_1 - a_1 m_2 = m_1 - \frac{s_{12}}{s_2} m_2.$$

Empirická regresní přímka závislosti  $X$  na  $Y$  má tedy rovnici:

$$x = m_1 + \frac{s_{12}}{s_2} (y - m_2).$$


Obě empirické regresní přímky  $y = b_0 + b_1 x$ ,  $x = a_0 + a_1 y$  se nazývají **sdružené regresní přímky** a odhady regresních parametrů  $b_1, a_1$  se nazývají **odhady párově sdružených regresních parametrů**.

Je zřejmé, že  $b_1 a_1 = r_{12}^2$ . Rovnice sdružených regresních přímek můžeme tedy psát ve tvaru:

$$y = m_2 + \frac{s_{12}}{s_1} (x - m_1), \quad y = m_1 + \frac{1}{r_{12}} \frac{s_2}{s_1} (x - m_2).$$

### Vlastnosti sdružených regresních přímek

a) Sdružené regresní přímky se protínají v bodě o souřadnicích  $[m_1, m_2]$  (tj. v těžišti dvourozměrného tečkového diagramu).



b) Je-li  $r_{12} = 0$  (tj. náhodné veličiny X, Y jsou nekorelované), pak sdružené regresní přímky mají rovnice  $y = m_2$ ,  $x = m_1$  (tj. jsou to kolmice rovnoběžné se souřadnými osami).

c) Je-li  $r_{12}^2 = 1$  (tj. mezi náhodnými veličinami X, Y existuje úplná lineární závislost), pak sdružené regresní přímky splynou

a  $a_1 = \frac{1}{b_1}$ .

d) Je-li  $0 < r_{12}^2 < 1$ , pak sdružené regresní přímky se liší a svírají úhel, který je tím menší, čím je těsnější lineární závislost veličin X, Y.

e) Označíme-li  $\varphi$  úhel, který svírají sdružené regresní přímky, pak z předešlých úvah plyne:

$\cos \varphi = 0 \Leftrightarrow$  mezi X a Y neexistuje žádná lineární závislost;

$\cos \varphi = 1 \Leftrightarrow$  mezi X a Y existuje úplná přímá lineární závislost;

$\cos \varphi = -1 \Leftrightarrow \Leftrightarrow$  mezi X a Y existuje úplná nepřímá lineární závislost.

### Příklad:

Z fiktivního základního souboru všech vzorků oceli odpovídajících „všem myslitelným tavbám“ bylo do laboratoře dodáno 60 vzorků a zjištěny a hodnoty proměnné  $X$  – mez plasticity a  $Y$  – mez pevnosti. Datový soubor má tvar:

|     |     |     |     |     |     |
|-----|-----|-----|-----|-----|-----|
| 154 | 178 | 83  | 98  | 73  | 76  |
| 133 | 164 | 106 | 111 | 77  | 85  |
| 58  | 75  | 92  | 104 | 47  | 61  |
| 145 | 161 | 85  | 103 | 68  | 85  |
| 94  | 107 | 112 | 118 | 137 | 142 |
| 113 | 141 | 98  | 102 | 44  | 68  |
| 86  | 97  | 103 | 108 | 92  | 116 |
| 121 | 127 | 99  | 119 | 141 | 157 |
| 119 | 138 | 104 | 128 | 155 | 189 |
| 112 | 125 | 107 | 118 | 136 | 155 |
| 85  | 97  | 98  | 140 | 82  | 81  |
| 41  | 72  | 97  | 115 | 136 | 163 |
| 96  | 113 | 105 | 101 | 72  | 79  |
| 45  | 89  | 71  | 93  | 66  | 81  |
| 99  | 109 | 39  | 69  | 42  | 61  |
| 51  | 95  | 122 | 147 | 113 | 123 |
| 101 | 114 | 33  | 52  | 42  | 85  |
| 160 | 169 | 78  | 117 | 133 | 147 |
| 87  | 101 | 114 | 137 | 153 | 179 |
| 88  | 139 | 125 | 149 | 85  | 91  |

- Určete regresní přímku meze pevnosti na mez plasticity.
- Zakreslete regresní přímku do dvourozměrného tečkového diagramu.
- Najděte regresní odhad meze pevnosti pro mez plasticity = 60.
- Vypočtete index determinace a interpretujte ho.
- Najděte reziduální součet čtverců a odhad rozptylu náhodných odchylek.
- Určete regresní přímku meze plasticity na mez pevnosti.
- Zakreslete regresní přímku do dvourozměrného tečkového diagramu.
- Obě regresní přímky zakreslete do téhož dvourozměrného tečkového diagramu.

## Řešení v systému STATISTICA:


Ad a) Odhad parametrů 1. regresní přímky:

Statistiky – Vícerozměrná regrese – Závisle proměnná Y, nezávisle proměnná X - OK – OK – Výpočet: Výsledky regrese.

|   |          |                  |          |               |          |          |
|---|----------|------------------|----------|---------------|----------|----------|
| Výsledky regrese se závislou proměnnou : Y (ocel.sta)<br>R= ,93454811 R2= ,87338017 Upravené R2= ,87119707<br>F(1,58)=400,06 p<0,0000 Směrod. chyba odhadu : 11,768 |          |                  |          |               |          |          |
| N=60  | Beta     | Sm.chyba<br>beta | B        | Sm.chyba<br>B | t(58)    | Úroveň p |
| Abs.člen  |          |                  | 24,58814 | 4,740272      | 5,18707  | 0,000003 |
| X   | 0,934548 | 0,046724         | 0,93668  | 0,046830      | 20,00160 | 0,000000 |

Ad b) Zakreslení regresních přímky do dvourozměrného tečkového diagramu:

Grafy – Bodové grafy – Proměnné X, Y – OK – OK.



Ad c) Výpočet predikované hodnoty: Pro výpočet predikované hodnoty zvolíme Rezidua/předpoklady/předpovědi - Předpovědi závisle proměnné X: 60 OK. Ve výstupní tabulce je hledaná hodnota označena jako Předpověď: 80,79

| Proměnná  | Předpovězené hodnoty (ocel.sta)<br>proměnné: Y |          |                     |
|-----------|--|----------|---------------------|
|           | b-váha   | Hodnota  | b-váha<br>* Hodnota |
| X         | 0,936679                                       | 60,00000 | 56,20071            |
| Abs. člen |  |          | 24,58814            |
| Předpověď |  |          | 80,78885            |
| -95,0%LS  |  |          | 76,25426            |
| +95,0%LS  |  |          | 85,32344            |

Regresní odhad meze pevnosti pro mez plasticity 60 je tedy 80,8.

Ad d) Index determinace najdeme ve výstupní tabulce regrese pod označením R2:

| N=60     | Výsledky regrese se závislou proměnnou : Y (ocel.sta)<br>R= ,93454811 R2= ,87338017 Upravené R2= ,87119707<br>F(1,58)=400,06 p<0,0000 Směrod. chyba odhadu : 11,768 |                  |          |               |          |          |
|----------|---|------------------|----------|---------------|----------|----------|
|          | Beta  | Sm.chyba<br>beta | B        | Sm.chyba<br>B | t(58)    | Úroveň p |
| Abs.člen |   |                  | 24,58814 | 4,740272      | 5,18707  | 0,000003 |
| X        | 0,934548  | 0,046724         | 0,93668  | 0,046830      | 20,00160 | 0,000000 |

Vidíme, že variabilita meze pevnosti je regresní přímkou vyčerpána z 87,3 %.

Ad e) Reziduální součet čtverců a odhad rozptylu najdeme v tabulce ANOVA: Vrátime se do Výsledky – Vícenásobná regrese – na záložce Detailní výsledky zvolíme ANOVA (Celk. vhodnost modelu)

| Efekt   | Analýza rozptylu (ocel.sta) |    |                   |          |          |
|---------|-----------------------------|----|-------------------|----------|----------|
|         | Součet<br>čtverců           | sv | Průměr<br>čtverců | F        | p-hodn.  |
| Regres. | 55400,60                    | 1  | 55400,60          | 400,0641 | 0,000000 |
| Rezid.  | 8031,80                     | 58 | 138,48            |          |          |
| Celk.   | 63432,40                    |    |                   |          |          |


Vidíme, že reziduální součet čtverců je 8031,8 a reziduální rozptyl nabývá hodnoty 138,48.

Ad f) Výsledky pro 2. regresní přímku:

|   |          |               |          |            |          |          |
|---|----------|---------------|----------|------------|----------|----------|
| Výsledky regrese se závislou proměnnou : X (ocel.sta) |          |               |          |            |          |          |
| R= ,93454811 R2= ,87338017 Upravené R2= ,87119707     |          |               |          |            |          |          |
| F(1,58)=400,06 p<0,0000 Směrod. chyba odhadu : 11,741 |          |               |          |            |          |          |
| N=60  | Beta     | Sm.chyba beta | B        | Sm.chyba B | t(58)    | Úroveň p |
| Abs.člen  |          |               | -10,7858 | 5,544250   | -1,94540 | 0,056579 |
| Y   | 0,934548 | 0,046724      | 0,9324   | 0,046617   | 20,00160 | 0,000000 |

Vidíme, že  $x = -10,7858 + 0,9324y$ .


Ad g) Dvourozměrný tečkový diagram se zakreslenou 2. regresní přímkou



Ad h) Nakreslení sdružených regresních přímků do jednoho diagramu:

K datovému souboru ocel.sta přidáme dvě nové proměnné y1 a y2. Do proměnné y1 uložíme predikované hodnoty meze pevnosti na mezi plasticity (do Dlouhého jména proměnné y1 napíšeme  $=24,58814 + 0,93668*x$  a do Dlouhého jména proměnné y2 napíšeme  $=(x+10,7858)/0,9324$

Grafy – Bodové grafy – zaškrtneme Vícenásobný – Proměnné X: X, Y: Y, y1, y2 – OK. Ve vytvořeném grafu pak vypneme zobrazování značek pro y1, y2 a naopak zapneme Spojnici.



## Test adekvátnosti regresního modelu

Hodnoty veličiny  $Y$  jsou roztrženy do  $r \geq 3$  skupin podle variant  $x_{[1]}, \dots, x_{[r]}$  veličiny  $X$ .

Označme  $n_i$  počet pozorování v  $i$ -té skupině,  $i = 1, \dots, r$ , přičemž aspoň jedna skupina má více než jedno pozorování. Budeme předpokládat, že každá skupina hodnot má normální rozložení a že všechny skupiny mají též rozptyl.

Všech pozorování je  $n$ .

Průměr hodnot v  $i$ -té skupině označme  $M_i$  a průměr všech hodnot označme  $M$ .

Charakter závislosti  $Y$  na  $X$  popíšeme regresní funkcí  $m(x; \beta_0, \beta_1, \dots, \beta_p)$ .

Budeme testovat hypotézu, zda je tato regresní funkce vhodným modelem pro naše data.

Při testování budeme potřebovat tyto součty čtverců:

$$\text{celkový součet čtverců } S_T = \sum_{i=1}^r \sum_{j=1}^{n_i} (Y_{ij} - M)^2,$$

$$\text{skupinový součet čtverců } S_A = \sum_{i=1}^r n_i (M_i - M)^2,$$

$$\text{regresní součet čtverců } S_R = \sum_{i=1}^r n_i (\hat{y}_i - M_i)^2.$$

Testová statistika:  $F = \frac{(S_A - S_R)/(r - p - 1)}{(S_T - S_A)/(n - r)}$  se řídí rozložením  $F(r-p-1, n-r)$ , jestliže  $H_0$  platí.

Kritický obor:  $W = \langle F_{1-\alpha}(r-p-1, n-r), \infty \rangle$

$F \in W \Rightarrow$  na hladině významnosti  $\alpha$  zamítáme hypotézu, že funkce  $m(x; \beta_0, \beta_1, \dots, \beta_p)$  je vhodným regresním modelem závislosti  $Y$  na  $X$ .

Těsnost závislosti  $Y$  na  $X$  vyjádřenou skupinovými průměry měří **poměr determinace**

$$P^2 = S_A/S_T.$$

Nabývá hodnot z intervalu  $\langle 0, 1 \rangle$ . Čím je poměr determinace bližší jedné, tím je závislost silnější, čím je bližší nule, tím je závislost slabší.

**Příklad:** Máme k dispozici údaje o cenách 23 náhodně vybraných domů (veličina  $Y$  – v tisících \$) a počtu jejich pokojů (veličina  $X$ ) v jednom americkém městě.

| počet pokojů | cena                    |
|--------------|-------------------------|
| 5            | 155,168,180             |
| 6            | 166,172,179,190,200     |
| 7            | 210,215,218,225,230,245 |
| 8            | 213,225,240,247,249     |
| 9            | 267,275,290,298         |

Závislost ceny domu na počtu pokojů popište regresní přímkou.

Na hladině významnosti 0,05 testujte hypotézu, že přímka je vhodným regresním modelem pro tato data.

Těsnost závislosti vyjádřete poměrem determinace.

Znázorněte data s proloženou regresní přímkou.

**Řešení:** MNČ odhadneme parametry regresní přímky. Má tvar  $y = 17,2885 + 28,5851 x$ .

Vypočítáme regresní součet čtverců:  $S_R = \sum_{i=1}^r n_i (\hat{y}_i - M_i)^2 = 30907,9041$ ,

celkový součet čtverců:  $S_T = \sum_{i=1}^r \sum_{j=1}^{n_i} (Y_{ij} - M)^2 = 35870,6087$ ,

skupinový součet čtverců:  $S_A = \sum_{i=1}^r n_i (M_i - M)^2 = 32474,1087$ .

Testová statistika:  $F = \frac{(S_A - S_R)/(r - p - 1)}{(S_T - S_A)/(n - r)} = \frac{(32474,1087 - 30907,9041)/(5 - 2)}{(35870,6087 - 32474,1087)/(23 - 5)} = 2,768$


Stanovíme kritický obor  $W = \langle F_{1-\alpha}(r-p-1, n-r), \infty \rangle = \langle F_{0,95}(3, 18), \infty \rangle = \langle 3,161, \infty \rangle$ .

Jelikož  $F \notin W$ , nezamítáme na hladině významnosti 0,05 hypotézu, že přímka je vhodným regresním modelem.

Poměr determinace:  $P^2 = S_A/S_T = 32474,1087/35870,6087 = 0,9053$ ,

tedy závislost ceny domu na počtu pokojů je v daném datovém souboru značně silná.

Znázorníme data s proloženou regresní přímkou.



## Řešení v systému STATISTICA:

Vytvoříme nový datový soubor se dvěma proměnnými X a Y a 23 případy:

|    | 1<br>X | 2<br>Y |
|----|--------|--------|
| 1  | 5      | 155    |
| 2  | 5      | 168    |
| 3  | 5      | 180    |
| 4  | 6      | 166    |
| 5  | 6      | 172    |
| 6  | 6      | 179    |
| 7  | 6      | 190    |
| 8  | 6      | 200    |
| 9  | 7      | 210    |
| 10 | 7      | 215    |
| 11 | 7      | 218    |
| 12 | 7      | 225    |
| 13 | 7      | 230    |
| 14 | 7      | 245    |
| 15 | 8      | 213    |
| 16 | 8      | 225    |
| 17 | 8      | 240    |
| 18 | 8      | 247    |
| 19 | 8      | 249    |
| 20 | 9      | 267    |
| 21 | 9      | 275    |
| 22 | 9      | 290    |
| 23 | 9      | 298    |

Odhadneme parametry regresní přímky:

| Výsledky regrese se závislou proměnnou : Y (ceny_bytu.sta)<br>R= ,92825096 R2= ,86164984 Upravené R2= ,85506173<br>F(1,21)=130,79 p<,00000 Směrod. chyba odhadu : 15,373 |          |                  |          |               |          |          |
|--|----------|------------------|----------|---------------|----------|----------|
| N=23   | Beta     | Sm.chyba<br>beta | B        | Sm.chyba<br>B | t(21)    | Úroveň p |
| Abs.člen   |          |                  | 17,28851 | 18,00156      | 0,96039  | 0,347788 |
| X  | 0,928251 | 0,081167         | 28,58506 | 2,49950       | 11,43629 | 0,000000 |

$$\text{Cena} = 17,28851 + 28,5806 \cdot \text{počet pokojů}$$

Sestavíme tabulku ANOVA:

Vrátíme se do Výsledky – vícenásobná regrese – Detailní výsledky – ANOVA.

| Efekt   | Analýza rozptylu (ceny_bytu.sta) |    |                |          |          |
|---------|----------------------------------|----|----------------|----------|----------|
|         | Součet čtverců                   | sv | Průměr čtverců | F        | Úroveň p |
| Regres. | 30907,90                         | 1  | 30907,90       | 130,7888 | 0,000000 |
| Rezid.  | 4962,70                          | 21 | 236,32         |          |          |
| Celk.   | 35870,61                         |    |                |          |          |

Vidíme, že  $S_R = 30907,9$ ,  $S_T = 35870,61$

Provedeme jednofaktorovou analýzu rozptylu, abychom získali skupinový součet čtverců:

Statistiky – Základní statistiky a tabulky – Rozklad & jednofakt. ANOVA – OK – Proměnné – Závislé – Y, Grupovací - X – OK – OK – Analýza rozptylu.

| Proměnná | Analýza rozptylu (ceny_bytu.sta)             |          |          |          |          |          |          |          |
|----------|--|----------|----------|----------|----------|----------|----------|----------|
|          | Označ. efekty jsou význ. na hlad. p < ,05000 |          |          |          |          |          |          |          |
|          | SČ efekt                                     | SV efekt | PČ efekt | SČ chyba | SV chyba | PČ chyba | F        | p        |
| Y        | 32474,11                                     | 4        | 8118,527 | 3396,500 | 18       | 188,6944 | 43,02473 | 0,000000 |

Zde najdeme  $S_A = 32474,11$ .

$$\text{Vypočteme testovou statistiku } F = \frac{(S_A - S_R)/(r - p - 1)}{(S_T - S_A)/(n - r)} = \frac{(32474,1087 - 30907,9041)/(5 - 2)}{(35870,6087 - 32474,1087)/(23 - 5)} = 2,768$$

a najdeme kritický obor  $W = <3,161, \infty$ ). Jelikož  $F \notin W$ , nezamítáme na hladině významnosti 0,05 hypotézu, že přímka je vhodným regresním modelem.

## Test adekvátnosti modelu pomocí Obecných regresních modelů

Zadáme data a použijeme cestu:

Statistiky – Pokročilé lineární/nelineární modely – Obecné regresní modely – Jednorozměrná regrese - OK – na záložce

Možnosti zaškrtneme Kvalita proložení – OK – Závislá Y, Spoj. nezáv. prom. X – OK – Více výsledků – Celkové R – ve stromové struktuře vlevo vybereme Test kvality modelu.

| Závislá<br>Proměnná | Test kvality modelu (ceny_bytu.sta) |               |               |             |             |             |                       |                       |                       |          |          |
|---------------------|-------------------------------------|---------------|---------------|-------------|-------------|-------------|-----------------------|-----------------------|-----------------------|----------|----------|
|                     | SČ<br>Rezidua                       | sv<br>Rezidua | PČ<br>Rezidua | SČ<br>Chyba | sv<br>Chyba | PČ<br>Chyba | SČ Kvali<br>proložení | SV Kvali<br>proložení | PČ Kvali<br>proložení | ta<br>F  | p        |
| Y                   | 4962,705                            | 21            | 236,3193      | 3396,500    | 18          | 188,6944    | 1566,205              | 3                     | 522,0682              | 2,766739 | 0,071737 |

Číselník testové statistiky F je roven 1566,205 a je uveden ve sloupci Kvalita proložení.

Jmenovatel testové statistiky F je roven 3396,5 a je uveden ve sloupci SČ Chyba.

Hodnota testové statistiky je 2,767 a odpovídající p-hodnota je 0,0717. Na hladině významnosti 0,05 tedy nemůžeme zamítnout hypotézu, že přímka je vhodným modelem k popisu závislosti ceny domu na počtu pokojů.

## Problém autokorelovaných reziduí a jeho odstranění

Předpokládejme, že náhodná odchylka  $\epsilon_i$  je lineárně závislá na předešlé náhodné odchylce  $\epsilon_{i-1}$ , tj. jde o autokorelaci

1. řádu (v praxi nejčastější případ):

$\epsilon_i = \rho\epsilon_{i-1} + u_i$ ,  $i = 2, \dots, n$  ( $u_i$  je náhodná odchylka od modelu lineární závislosti a  $\rho$  je koeficient korelace dvou sousedních náhodných odchylek  $\epsilon_i$ ,  $\epsilon_{i-1}$ ).

Předpoklad o existenci autokorelace 1. řádu můžeme ověřit pomocí Durbinova – Watsonova testu, který je založen na

Durbinově – Watsonově statistice: 
$$D = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=2}^n e_{i-1}^2}.$$

Tato statistika nabývá hodnot z intervalu  $\langle 0,4 \rangle$  a má střední hodnotu 2. Nízké hodnoty statistiky D znamenají, že sousední rezidua jsou spíše podobná, což svědčí ve prospěch kladné autokorelace. Naopak, vysoké hodnoty statistiky D jsou způsobeny negativní autokorelací, avšak s tou se v praxi příliš často neseťkáváme.


Pro dané  $\alpha$ , daný počet pozorování  $n$  a daný počet  $p$  regresních parametrů – bez konstanty (v případě regresní přímky  $p = 1$ ) jsou tabelovány kritické hodnoty  $d_L(\alpha)$ ,  $d_U(\alpha)$ .

Testujeme-li na hladině významnosti  $\alpha$  existenci pozitivní autokorelace, pak při  $D \in (d_U(\alpha), 2)$  se nezamítá  $H_0$  a při  $D \in (0, d_L(\alpha))$  se přijímá  $H_1$ .

Je-li  $d_L(\alpha) \leq D \leq d_U(\alpha)$ , pak nelze přijmout žádné rozhodnutí (říkáme, že test mlčí).

Testujeme-li na hladině významnosti  $\alpha$  existenci negativní autokorelace, pak při  $D \in (2, 4 - d_U(\alpha))$  se nezamítá  $H_0$  a při  $D \in (4 - d_L(\alpha), 4)$  se přijímá  $H_1$ .

Je-li  $4 - d_U(\alpha) \leq D \leq 4 - d_L(\alpha)$ , pak nelze učinit žádné rozhodnutí.



Prokážeme-li na dané hladině významnosti  $\alpha$  existenci autokorelace 1. řádu, měli bychom ji eliminovat.

Nejprve odhadneme koeficient korelace  $\rho$ : 
$$\hat{\rho} = \frac{\sum_{i=2}^n e_i e_{i-1}}{\sum_{i=2}^n e_{i-1}^2}.$$

Pak už můžeme vypočítat odhady náhodných odchylek (tj. rezidua) v autokorelaci:  $\hat{u}_i = e_i - \hat{\rho}e_{i-1}$ ,  $i = 2, \dots, n$ .

Získané odhady  $\hat{u}_i$  přičteme k predikovaným hodnotám  $\hat{y}_i$  získaným z regresního modelu a znovu provedeme regresní analýzu, kde roli závisle proměnné veličiny bude hrát součet  $\hat{y}_i + \hat{u}_i$ .

### Postup v systému STATISTICA

(Použijeme data z příkladu o závislosti tržeb na počtu zákazníků.)

Rezidua z modelu  $Y = \beta_0 + \beta_1 x + \beta_2 x^2 + \varepsilon$  jsou uložena v proměnné Rezidua. Pro tato rezidua je hodnota D-W statistiky  $D = 0,702506$  a kritické hodnoty pro  $\alpha = 0,05$ ,  $n = 20$ ,  $p = 2$  jsou:  $d_L = 1,1$ ,  $d_U = 1,54$ . Protože  $D < d_L$ , zamítáme na hladině významnosti 0,05 hypotézu o nekorelovanosti reziduí ve prospěch alternativy o pozitivní autokorelaci 1. řádu.

Získání odhadů reziduí v autokorelaci:  $\hat{u}_i = e_i - \hat{\rho}e_{i-1}$ ,  $i = 2, \dots, n$ :

Statistiky – Pokročilé lineární/nelineární modely – Časové řady/predikce – Proměnné Rezidua – ARIMA & autokorelační funkce – v Parametrech modelu ARIMA zvolíme p-Autoregresní 1 – OK (Zahájit odhady parametrů) – Souhrn: Odhady parametrů.

|          |   |                 |                   |          |                   |                   |
|----------|---|-----------------|-------------------|----------|-------------------|-------------------|
|          | Vstup: REZIDUA (Tabulka39)<br>Transformace: žádná<br>Model:(1,0,0) PČ Rezid. = ,64920 |                 |                   |          |                   |                   |
| Paramet. | Param.  | Asympt.<br>SmCh | Asympt.<br>t( 19) | p        | Dolní<br>95% spol | Horní<br>95% spol |
| p(1)     | 0,599248  | 0,189523        | 3,161883          | 0,005134 | 0,202573          | 0,995924          |

Uložíme rezidua z autokorelace: Přehled & rezidua – Přehled reziduí. Vzniklou proměnnou okopírujeme do původního datového souboru a k tomuto datovému souboru přidáme ještě proměnnou s predikovanými hodnotami z parabolického modelu. Do nové proměnné nazvané nove y uložíme součet reziduí a predikovaných hodnot. Pak znovu provedeme regresní analýzu:

| Výsledky regrese se závislou proměnnou : nove y (prodejna_software.sta) |          |               |          |              |          |          |
|---|----------|---------------|----------|--------------|----------|----------|
| R= ,96958525 R2= ,94009556 Upravené R2= ,93304798                       |          |               |          |              |          |          |
| F(2,17)=133,39 p<,00000 Směrod. chyba odhadu : ,84933                   |          |               |          |              |          |          |
| N=20  | b*       | Sm.chyba z b* | b        | Sm.chyba z b | t(17)    | p-hodn.  |
| Abs.člen  |          |               | -20,1238 | 2,696857     | -7,46194 | 0,000001 |
| x   | 4,58359  | 0,453331      | 1,5323   | 0,151549     | 10,11091 | 0,000000 |
| xkv   | -3,78264 | 0,453331      | -0,0169  | 0,002027     | -8,34410 | 0,000000 |

Nová regresní parabola má tvar:  $y = -20,1238 + 1,5323x - 0,0169x^2$ .

Porovnáme výslednou tabulku regrese s původní tabulkou:

| Výsledky regrese se závislou proměnnou : y (prodejna_software.sta) |          |               |          |              |          |          |
|--|----------|---------------|----------|--------------|----------|----------|
| R= ,95519276 R2= ,91239322 Upravené R2= ,90208653                  |          |               |          |              |          |          |
| F(2,17)=88,524 p<,00000 Směrod. chyba odhadu : 1,0623              |          |               |          |              |          |          |
| N=20   | b*       | Sm.chyba z b* | b        | Sm.chyba z b | t(17)    | p-hodn.  |
| Abs.člen   |          |               | -20,7723 | 3,373256     | -6,15792 | 0,000011 |
| x  | 4,52641  | 0,548220      | 1,5651   | 0,189559     | 8,25655  | 0,000000 |
| xkv  | -3,73838 | 0,548220      | -0,0173  | 0,002535     | -6,81912 | 0,000003 |

Získali jsme vyšší hodnotu testové statistiky F (a tedy i vyšší adjustovaný index determinace) a menší směrodatné chyby odhadů regresních parametrů (tudíž také vyšší hodnoty testových statistik pro dílčí t-testy).

Nyní prozkoumáme chování reziduí v novém regresním modelu pomocí Durbinovy – Watsonovy statistiky:

|       |                 |                  |
|-------|-----------------|------------------|
|       | Durbin-Watson.d | Sériové korelace |
| Odhad | 1,356630        | 0,256281         |

Hodnota D-W statistiky  $D = 1,35663$  a kritické hodnoty pro  $\alpha = 0,05$ ,  $n = 20$ ,  $p = 2$  jsou:  $d_L = 1,1$ ,  $d_U = 1,54$ . Protože  $d_L \leq D \leq d_U$ , nelze přijmout žádné rozhodnutí.

Pokud celý postup zopakujeme ještě jednou, dostaneme hodnotu D-W statistiky 1,6885. Nyní je  $D > d_U$ , tudíž nelze zamítnout hypotézu, že rezidua nejsou kladně korelovaná.

Parametry výsledného modelu jsou:

|  |          |               |          |              |          |          |
|--|----------|---------------|----------|--------------|----------|----------|
| Výsledky regrese se závislou proměnnou : nove y2 (Tabulka12)<br>R= ,97136268 R2= ,94354546 Upravené R2= ,93690375<br>F(2,17)=142,06 p<,00000 Směrod. chyba odhadu : ,82061 |          |               |          |              |          |          |
| N=20   | b*       | Sm.chyba z b* | b        | Sm.chyba z b | t(17)    | p-hodn.  |
| Abs.člen   |          |               | -19,7523 | 2,605683     | -7,58046 | 0,000001 |
| x  | 4,53932  | 0,440084      | 1,5103   | 0,146425     | 10,31467 | 0,000000 |
| xkv  | -3,73197 | 0,440084      | -0,0166  | 0,001958     | -8,48013 | 0,000000 |

Regresní parabola má tedy rovnici:  $y = -19,7523 + 1,5103x - 0,0166x^2$ .

## Linearizující transformace

Odhad parametrů regresních funkcí, které nejsou lineární z hlediska parametrů, se neprovádí metodou nejmenších čtverců přímo, protože její použití vede k soustavě nelineárních rovnic. V některých speciálních případech však nelineární regresní funkci můžeme vhodnou transformací převést na lineární.

Např. máme exponenciální regresní funkci  $y = \beta_0 \beta_1^x$ . Provedeme logaritmickou transformaci  $\ln y = \ln \beta_0 + x \ln \beta_1$ , čímž získáme regresní funkci lineární v parametrech. Parametry  $\ln \beta_0$  a  $\ln \beta_1$  odhadneme metodou nejmenších čtverců a odlogaritmováním získáme odhady původních regresních koeficientů  $\beta_0, \beta_1$ .

### Přehled linearizujících transformací

| Funkce | Linearizující transformace |
|--------|----------------------------|
|--------|----------------------------|

|                         |                                       |
|-------------------------|---------------------------------------|
| $y = \beta_0 \beta_1^x$ | $\ln y = \ln \beta_0 + x \ln \beta_1$ |
|-------------------------|---------------------------------------|

|                           |                                       |
|---------------------------|---------------------------------------|
| $y = \beta_0 x^{\beta_1}$ | $\ln y = \ln \beta_0 + \beta_1 \ln x$ |
|---------------------------|---------------------------------------|

|                                   |                                       |
|-----------------------------------|---------------------------------------|
| $y = \frac{\beta_0}{x^{\beta_1}}$ | $\ln y = \ln \beta_0 - \beta_1 \ln x$ |
|-----------------------------------|---------------------------------------|

|                                     |                                     |
|-------------------------------------|-------------------------------------|
| $y = \frac{1}{\beta_0 + \beta_1 x}$ | $\frac{1}{y} = \beta_0 + \beta_1 x$ |
|-------------------------------------|-------------------------------------|

**Příklad:** Hotelová společnost vlastní 12 hotelů analyzuje vztah mezi celkovými měsíčními tržbami (veličina Y) a tržbami vyprodukovanými stravovacími úseky (veličina X).

|       |      |     |      |      |      |      |      |      |      |      |      |      |
|-------|------|-----|------|------|------|------|------|------|------|------|------|------|
| č. h. | 1    | 2   | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | 12   |
| x     | 2,0  | 1,2 | 14,8 | 8,3  | 8,4  | 3,0  | 4,8  | 15,6 | 16,1 | 11,5 | 14,2 | 14,0 |
| y     | 12,0 | 8,0 | 76,4 | 17,0 | 21,3 | 10,0 | 12,5 | 97,3 | 88,0 | 25,0 | 38,6 | 47,3 |

Popište tuto závislost exponenciální regresní funkcí  $y = \beta_0 \beta_1^x$ . Najděte odhady parametrů  $\beta_0$ ,  $\beta_1$  a vypočtěte predikovanou hodnotu celkových měsíčních tržeb pro  $x = 10$ .

**Řešení:** Provedeme logaritmickou transformaci  $\ln y = \ln \beta_0 + x \ln \beta_1$ . Metodou nejmenších čtverců získáme odhady  $\ln b_0 = 1,8559$ ,  $\ln b_1 = 0,1504$ .

Odlogaritmováním dostaneme  $b_0 = 6,3973$ ,  $b_1 = 1,1623$ . Predikovaná hodnota  $y$  pro  $x = 10$  je  $6,3973 \cdot 1,1623^{10} = 28,7859$ .

### Řešení v systému STATISTICA:

Vytvoříme datový soubor se dvěma proměnnými a 12 případy:

|    | 1<br>Y | 2<br>X |
|----|--------|--------|
| 1  | 12     | 2      |
| 2  | 8      | 1,2    |
| 3  | 76,4   | 14,8   |
| 4  | 17     | 8,3    |
| 5  | 21,3   | 8,4    |
| 6  | 10     | 3      |
| 7  | 12,5   | 4,8    |
| 8  | 97,3   | 15,6   |
| 9  | 88     | 16,1   |
| 10 | 25     | 11,5   |
| 11 | 38,6   | 14,2   |
| 12 | 47,3   | 14     |

Přidáme novou proměnnou ln y. Do jejího Dlouhého jména napíšeme =log(y).

Pak provedeme regresní analýzu se závisle proměnnou ln y a nezávisle proměnnou X:

| Výsledky regrese se závislou proměnnou : ln y (hotely.sta) |          |               |          |            |          |          |
|--|----------|---------------|----------|------------|----------|----------|
| R= ,95851605 R2= ,91875303 Upravené R2= ,91062833          |          |               |          |            |          |          |
| F(1,10)=113,08 p<,00000 Směrod. chyba odhadu : ,26364      |          |               |          |            |          |          |
| N=12   | Beta     | Sm.chyba beta | B        | Sm.chyba B | t(10)    | Úroveň p |
| Abs.člen   |          |               | 1,855881 | 0,154338   | 12,02480 | 0,000000 |
| X  | 0,958516 | 0,090137      | 0,150428 | 0,014146   | 10,63398 | 0,000001 |

K výsledné tabulce přidáme novou proměnnou b, do jejíhož Dlouhého jména napíšeme =exp(B).

| Výsledky regrese se závislou proměnnou : ln y (hotely.sta) |          |               |          |            |          |          |           |
|--|----------|---------------|----------|------------|----------|----------|-----------|
| R= ,95851605 R2= ,91875303 Upravené R2= ,91062833          |          |               |          |            |          |          |           |
| F(1,10)=113,08 p<,00000 Směrod. chyba odhadu : ,26364      |          |               |          |            |          |          |           |
| N=12   | Beta     | Sm.chyba beta | B        | Sm.chyba B | t(10)    | Úroveň p | b =exp(B) |
| Abs.člen   |          |               | 1,855881 | 0,154338   | 12,02480 | 0,000000 | 6,397333  |
| X  | 0,958516 | 0,090137      | 0,150428 | 0,014146   | 10,63398 | 0,000001 | 1,162332  |

Model má tedy tvar:  $y = 6,397333 \cdot 1,162332^x$ .

Získání predikované hodnoty pro  $x = 10$ :

Vrátíme se do Výsledky – vícenásobná regrese – na záložce Rezidua/předpoklady/předpovědi vybereme Předpověď závisle proměnné –  $X = 10$  – OK. K výsledné tabulce přidáme proměnnou predikce a do jejího Dlouhého jména napíšeme =exp(v3).

| Předpovězené hodnoty (hotely.sta) |          |          |                  |                   |
|-----------------------------------|----------|----------|------------------|-------------------|
| proměnné: ln y                    |          |          |                  |                   |
| Proměnná                          | b-váha   | Hodnota  | b-váha * Hodnota | predikce =exp(v3) |
| X                                 | 0,150428 | 10,00000 | 1,504281         | 4,500918          |
| Abs. člen                         |          |          | 1,855881         | 6,397333          |
| Předpověď                         |          |          | 3,360163         | 28,79387          |
| -95,0%LS                          |          |          | 3,189835         | 24,28441          |
| +95,0%LS                          |          |          | 3,530490         | 34,14071          |

Vidíme, že predikovaná hodnota je 28,79.

Vytvoříme ještě dvourozměrný tečkový diagram s proloženou exponenciálou. Na záložce Rezidua/předpoklady/předpovědi vybereme reziduální analýza – Uložit – Uložit rezidua & předpovědi – vybereme X, Y – OK.


Ve vzniklé tabulce odstraníme proměnné č. 5 až 10 a proměnnou rezidua přejmenujeme na Predikce. Do Dlouhého jména této proměnné napíšeme =exp(v3).

Tento datový soubor uspořádáme podle velikosti hodnot proměnné X: Data - Setřídít – Proměnná X – OK.

| hotely.sta |      |      |            |          |
|------------|------|------|------------|----------|
|            | 1    | 2    | 3          | 4        |
|            | Y    | X    | Předpovědi | Predikce |
| 1          | 8    | 1,2  | 2,04       | 7,66     |
| 1          | 12   | 2    | 2,16       | 8,64     |
| 3          | 10   | 3    | 2,31       | 10,05    |
| 4          | 12,5 | 4,8  | 2,58       | 13,17    |
| 5          | 17   | 8,3  | 3,10       | 22,30    |
| 6          | 21,3 | 8,4  | 3,12       | 22,63    |
| 7          | 25   | 11,5 | 3,59       | 36,08    |
| 8          | 47,3 | 14   | 3,96       | 52,56    |
| 9          | 38,6 | 14,2 | 3,99       | 54,16    |
| 10         | 76,4 | 14,8 | 4,08       | 59,28    |
| 11         | 97,3 | 15,6 | 4,20       | 66,86    |
| 12         | 88   | 16,1 | 4,28       | 72,08    |

Vytvoření grafu:

Grafy – Bodové grafy – zaškrtneme Vícenásobný – Proměnné X: X, Y: Y, Predikce – OK. Ve vytvořeném grafu pak vypneme zobrazování značek pro Predikce a naopak zapneme Spojnici.




## Provedení regresní analýzy pomocí modulu Jednoduchá nelineární regrese

Pro data z předešlého příkladu najdeme odhady parametrů modelu  $y = \beta_0 \beta_1^x$  pomocí modulu Jednoduchá nelineární regrese.

Statistiky - Pokročilé lineární/nelineární odhady - Jednoduchá nelineární regrese – Proměnné X, Y – OK – OK – zaškrtneme LN(X) – OK – Proměnné – Závislé LN-V1, Nezávislé X – OK. Dostaneme stejnou tabulku jako předešlým postupem a výsledné hodnoty odhadů regresních parametrů získáme exponenciální transformací.

## Získání odhadů parametrů modelu $y = \beta_0 \beta_1^x$ pomocí Bodových grafů

Grafy – Bodové grafy – Proměnné X, Y – OK – na záložce Detaily zaškrtneme Proložení Exponenciální – OK.



V záhlaví grafu je uvedena regresní rovnice  $y = 6,3973 * \exp(0,1504 * x)$ , tedy  $b_0 = 6,3973$ ,  $b_1 = e^{0,1504} = 1,1623$ .

Kritické hodnoty Durbinova-Watsonova testu pro autokorelaci 1. řádu pro  $\alpha = 0,05$ , rozsah výběru  $n$  a počet regresorů  $p$  (bez konstant)

| n   | p=1   |       | p=2   |       | p=3   |       | p=4   |       | p=5   |       |
|-----|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|     | $d_L$ | $d_U$ |
| 15  | 1,08  | 1,36  | 0,95  | 1,54  | 0,82  | 1,75  | 0,69  | 1,97  | 0,56  | 2,21  |
| 20  | 1,20  | 1,41  | 1,10  | 1,54  | 1,00  | 1,68  | 0,90  | 1,83  | 0,79  | 1,99  |
| 30  | 1,35  | 1,49  | 1,28  | 1,57  | 1,21  | 1,65  | 1,14  | 1,74  | 1,07  | 1,83  |
| 40  | 1,44  | 1,54  | 1,39  | 1,60  | 1,34  | 1,66  | 1,29  | 1,72  | 1,23  | 1,79  |
| 60  | 1,55  | 1,62  | 1,51  | 1,65  | 1,48  | 1,69  | 1,44  | 1,73  | 1,41  | 1,77  |
| 80  | 1,61  | 1,66  | 1,59  | 1,69  | 1,56  | 1,72  | 1,53  | 1,74  | 1,51  | 1,77  |
| 100 | 1,65  | 1,69  | 1,63  | 1,72  | 1,61  | 1,74  | 1,59  | 1,76  | 1,57  | 1,78  |