

# 6. Lineární regresní modely

## 6.1 Jednoduchá regrese a validace

## 6.2 Testy hypotéz v lineární regresi

## 6.3 Kritika dat v regresním tripletu

## 6.4 Multikolarita a polynomy

## 6.5 Kritika modelu v regresním tripletu


## 6.6 Kritika metody v regresním tripletu

## 6.7 Lineární a nelineární kalibrace

## 7. Korelační modely

1

### Grafické vysvětlení regresního modelu:



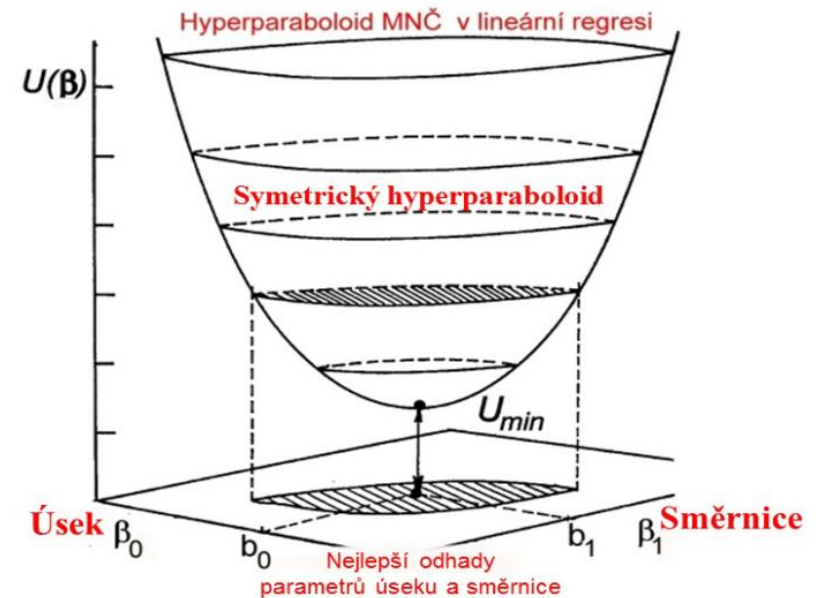
# Cíl regresní analýzy

Cílem regresní analýzy je nalezení vhodného modelu studované závislosti tak, že se **snažíme nahradit**

každou měřenou (experimentální) hodnotu závisle proměnné  $y_{exp}$

**hodnotou vypočtenou (predikovanou)  $y_{vyp}$**

čili hodnotou ležící na spojitě funkci (modelu) **nezávisle proměnné  $x$** .



Účelová funkce  $U$  dosáhne minima pro nejlepší odhady parametrů úseku a směrnice

## Formulace lineárního regresního modelu

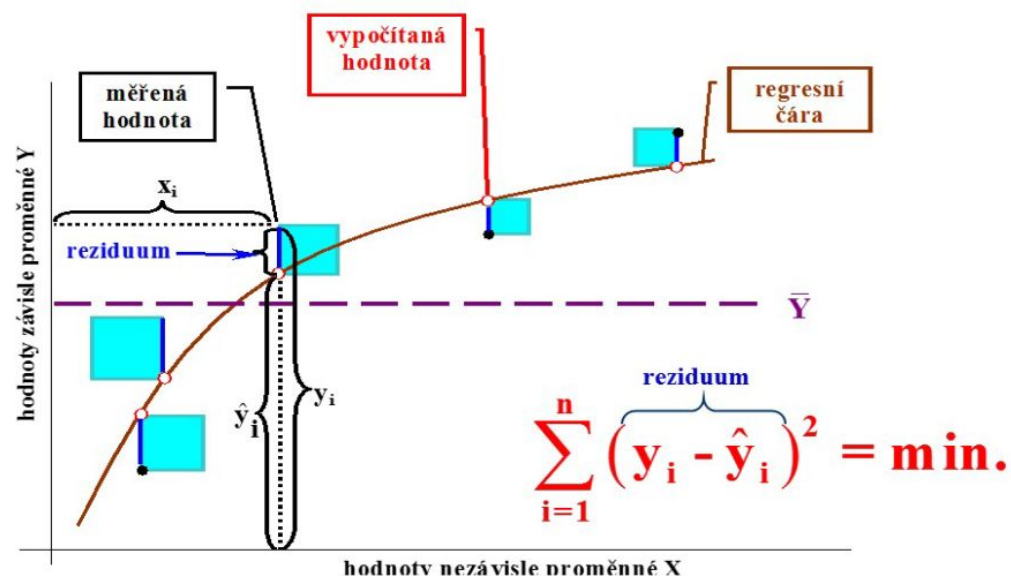
$$\begin{array}{c}
 \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1j} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2j} & \cdots & x_{2m} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{i1} & x_{i2} & \cdots & x_{ij} & \cdots & x_{im} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nj} & \cdots & x_{nm} \end{bmatrix} \cdot \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_j \\ \vdots \\ \beta_m \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{bmatrix} \\
 \underbrace{\hspace{10em}}_{\text{závisle proměnná}} \quad \underbrace{\hspace{10em}}_{\text{nezávisle proměnná}} \quad \underbrace{\hspace{10em}}_{\text{regresní parametry}} \quad \underbrace{\hspace{10em}}_{\text{náhodná chyba}}
 \end{array}$$

Maticový zápis  $y = X\beta + \varepsilon$

## Předpoklady metody nejmenších čtverců

1. Parametry  $\beta$  mohou nabývat libovolných hodnot. Omezení jsou pouze fyzikálního smyslu.
2. Model je lineární v parametrech  $\beta$ ; platí přitom additivní model měření  $y = X\beta + \varepsilon$ .
3. Matice  $X$  je nenáhodná, nastavitelných hodnot nezávisle proměnných. Má hodnost  $m$ :
  - (a) Žádné dva sloupce  $x_j$  a  $x_k$  nejsou kolineární (čili paralelní).
  - (b)  $X^T X$  je pak symetrická regulární matice.
  - (c) Rovina  $L$  je  $m$  rozměrná a vektory  $X$  a  $b$  jsou jednoznačné.

## Vyčíslení odhadů parametrů lineárního regresního modelu metodou nejmenších čtverců (MNČ)



4. Náhodné chyby  $\varepsilon_i$  mají nulovou střední hodnotu  $E(\varepsilon_i) = 0$ .  
Je-li  $E(\varepsilon_i) = K$ , je nutno zavést absolutní člen a pak bude  $E(\varepsilon_i) = 0$ .
5. Náhodné chyby  $\varepsilon_i$  mají konstantní rozptyl, homoskedasticita,  $E(\varepsilon_i^2) = \sigma^2$ .
6. Náhodné chyby  $\varepsilon_i$  jsou vzájemně nekorelované,  $\text{cov}(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \cdot \varepsilon_j) = 0$ .
7. Náhodné chyby mají normální rozdělení  $\varepsilon \approx N(0, \sigma^2)$ .

**Koeficient determinace  $R^2$  ( $\times 100\%$ ):**

je čtverec vícenásobného korelačního koeficientu. Vyjadřuje procento bodů, popsaných regresním modelem.

**Testování:**  $H_0: \beta_c = 0$  nebo  $H_0: R^2 = 0$

**Testační kritérium F-testu**

$$F_R = \frac{(CSC - RSC)(n - m)}{RSC(m - 1)} = \frac{\hat{R}^2(n - m)}{(1 - \hat{R}^2)(m - 1)}$$

Je-li  $F_R < F_{1-\alpha}(m - 1, n - m)$ , je  $H_0$  přijata.

Významnost korelačního koeficientu je shodná s testem významnosti všech regresních koeficientů vyjma absolutního členu.

Statistika	P608a	P608b	P608c	P608d
Úsek, $b_0, s_0$				
Směrnice $b_1, s_1$				
Test významnosti úseku, $t_0$				
Test významnosti směrnice, $t_1$				
Test celkové regrese, $F_R$				
Korelační koeficient, $R$				
Koeficient determinace, $D$				
Směrodatná odchylka, $s(y)$				
Trend v reziduích				
Závěr: model je				

**Příklad 6.8 Omezení klasické analýzy lineárního modelu**

Anscomb<sup>5</sup> uvádí testační data pro čtyři simulované výběry. Testujte statistickou významnost obou parametrů  $\beta_1$  a  $\beta_2$  a proveďte grafickou analýzu reziduí.

**Data:** čtyři simulované výběry vykazují stejné charakteristiky  
 $b_1 = 0.5, b_2 = 3.0, D(b_1) = 0.0139$  a  $D(b_2) = 1.2656$ .

Výběr	A		B	C	D		
	Proměnná	x	y	y	y	x	y
1		10	8.04	9.14	7.46	8	6.58
2		8	6.95	8.14	6.77	8	5.76
3		13	7.58	8.74	12.74	8	7.71
4		9	8.81	8.77	7.11	8	8.84
5		11	8.33	9.26	7.81	8	8.47
6		14	9.96	8.10	8.84	8	7.04
7		6	7.24	6.13	6.08	8	5.25
8		4	4.26	3.10	5.39	19	12.50
9		12	10.84	9.13	8.15	8	5.56
10		7	4.82	7.26	6.42	8	7.91
11		5	5.68	4.74	5.73	8	6.89

**Řešení:**

Lineární regresní model  $E(y/x) = \beta_1 x + \beta_2$  má pro všechny výběry

a) **Stejně odhady parametrů:**

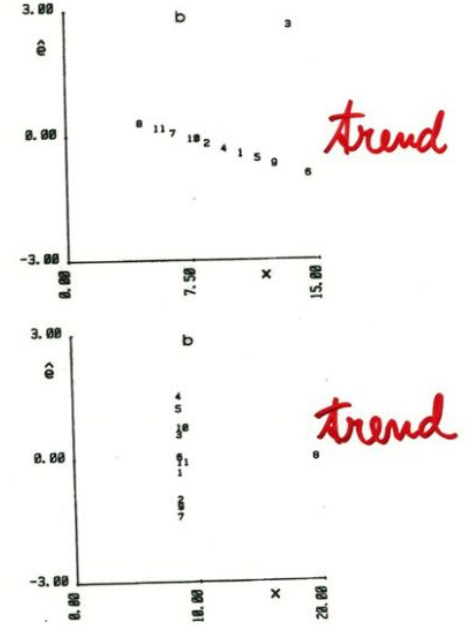
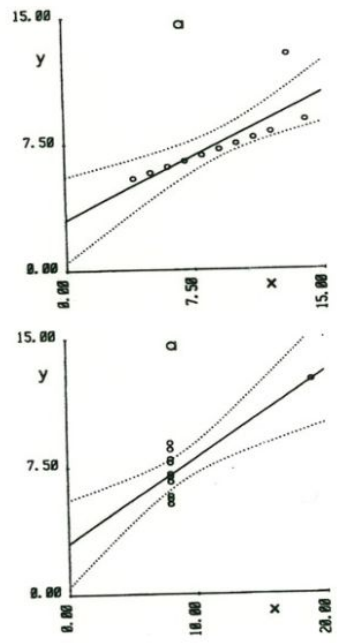
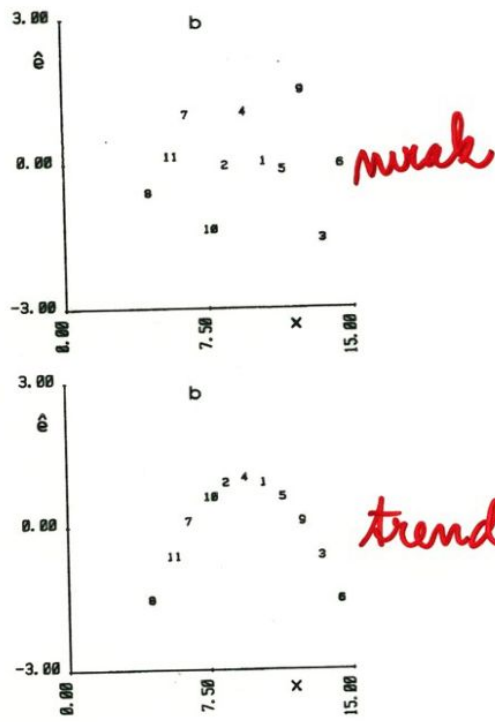
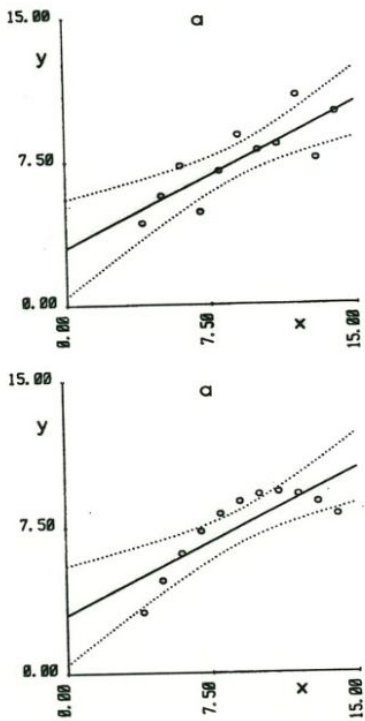
$$b_1 = 0.5, b_2 = 3.0, D(b_1) = 0.0139, D(b_2) = 1.2656.$$

b) **Stejně testační statistiky významnosti parametrů:**

$$T_1 = 2.667 \text{ a } T_2 = 4.241.$$

c) **Stejně testační statistiky:**  $F_R = 17.97, \hat{R}^2 = 0.66, \hat{\sigma} = 1.237$  ukazují,

že  $\beta_1$  a  $\beta_2$  jsou významně odlišné od nuly.



**Závěr:** Neshodu modelu s daty indikuje grafická analýza reziduí

## IS modelových hodnot přímky

Pro model přímky:

$$\mu_{y'} = y'_i \pm t_{\frac{\alpha}{2}, n-2} \cdot \frac{\sigma}{\sqrt{n-2}} \cdot \sqrt{1 + \frac{n(x_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

Směrodatná odchylka reziduí

Modelová hodnota

Polovina IS modelu přímky

## Intervalové odhady parametrů

Pro různý počet pozorování se mohou odhadnuté regresní parametry  $b_0$  a  $b_1$  lišit.

Vedle bodových odhadů regresních parametrů lze vyčíslit i jejich *intervalové odhady*:

$$b_i - t_{1-\alpha/2}(n-m) \cdot s(b_i) < \beta_i < b_i + t_{1-\alpha/2}(n-m) \cdot s(b_i)$$

kde  $b_i$  je bodový odhad regresního parametru,  
 $t_{1-\alpha/2}(n-p)$  je kvantil Studentova t rozdělení,  
 $m$  je počet parametrů modelu,  
 $s(b_i)$  je směrodatná chyba odhadu parametru.

## IS $y$ -hodnot – Working-Hotellingův pás spolehlivosti

udává rozpětí, ve kterém se budou nacházet hodnoty závisle proměnné se zvolenou pravděpodobností

$$1 - \alpha$$

$$Y_{i(\min, \max)} = y'_i \pm t_{\frac{\alpha}{2}; n-m} \cdot \sigma$$

### Příklad 6.7 Validizace nové analytické metody

Proveďte validizaci nové analytické metody porovnáním jejich výsledků  $y$  vůči standardům  $x$ .

- Určete odhady  $b_1$  a  $b_2$ ,
- zkonstruujte 95 %ní interval spolehlivosti úseku a směrnice,
- 95%ní elipsoid spolehlivosti,
- 95%ní interval spolehlivosti predikce v těžišti.

Data:  $n = 24$ ,  $m = 2$

Obsah látky určený standardní metodou ( $x$ ) a novou metodou ( $y$ ) v g:


$x$	40.2	43.8	47.6	50.7	56.8	81.3	83.3	97.1	102.5	118.7
$y$	48.9	39.1	42.6	56.9	70.3	71.5	97.6	99.9	105.2	102.3
$x$	129.4	184.8	287.5	295.4	420.3	421.3	427.9	566.1	608.5	640.7
$y$	106.8	162.9	234.0	303.4	388.8	391.1	369.3	611.6	580.2	643.3
$x$			692.8		705.2		714.4		881.4	
$y$			596.6		612.6		633.5		669.8	

Řešení:

- (a) Odhady  $b_1$  a  $b_2$ :
- odhad úseku  $b_2 = 14.73 (\pm 12.61)$ ,
  - odhad směrnice  $b_1 = 0.868 (\pm 0.0302)$ ,
  - koeficient determinace  $\hat{R}^2 = 0.974$ ,
  - odhad směrodatné odchylky reziduí  $\hat{\sigma} = 39.54$ .

## Validace nové analytické metody

$$y(\text{nalezeno}) = \beta_0 + \beta_1 \cdot x(\text{dáno})$$



18

- (b) Interval spolehlivosti úseku:  $H_0: \beta_2 = 0$  vs.  $H_A: \beta_2 \neq 0$

$$b_2 - t_{1-\alpha/2}(22) \sqrt{D(b_2)} \leq \beta_2 \leq b_2 + t_{1-\alpha/2}(22) \sqrt{D(b_2)}$$

a dosazením

$$14.73 - 2.08 \times 12.61 \leq \beta_2 \leq 14.73 + 2.08 \times 12.61$$

vyjde

$$-11.499 \leq \beta_2 \leq 40.959$$

**Závěr testování:** interval spolehlivosti úseku zahrnuje nulu, takže  $H_0$  je přijata a úsek  $\beta_2$  lze považovat za nulový.



Interval spolehlivosti směrnice:  $H_0: \beta_1 = 1$  vs.  $H_A: \beta_1 \neq 1$

$$0.868 - 2.08 \times 0.0302 \leq \beta_1 \leq 0.868 + 2.08 \times 0.0302$$

a vyčíslením

$$0.805 \leq \beta_1 \leq 0.93$$

**Závěr testování:** interval spolehlivosti neobsahuje jedničku, takže  $H_0$  je zamítnuta a směrnici  $\beta_1$  nelze považovat za jednotkovou.



**Závěr:** intervaly spolehlivosti indikují, že úsek regresní přímky lze považovat za nulový  $\beta_2 = 0$ , zatímco směrnice  $\beta_1$  je významně odlišná od jedničky.

**Nová analytická metoda vede k odlišným výsledkům od standardní.**

## 6.2.1 Úlohy na validaci nové analytické metody

### Úloha V6.01 Validace stanovení molybdenu rentg.-fluoresc. metodou

**Zadání:** U stanovení obsahu molybdenu porovnejte výsledky z rentg.-fluorescenční metody  $y$  s deklarovaným obsahem standardů ocelí  $x$ .

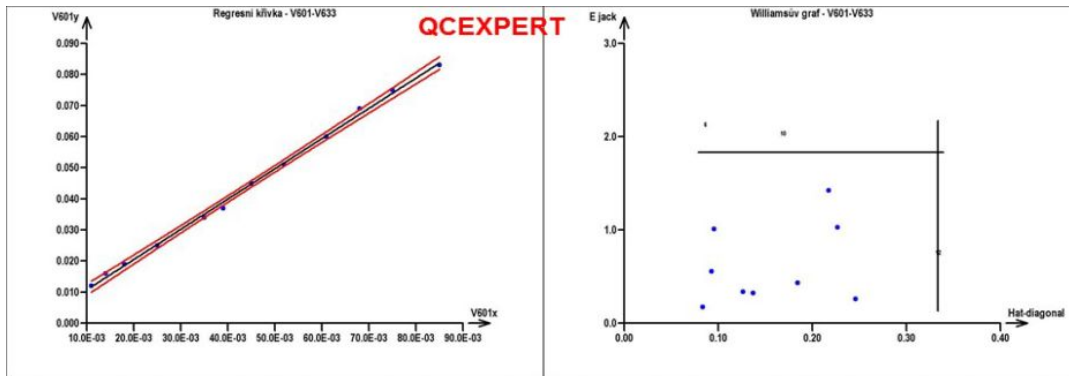
**Úkoly:**

- (1) Určete velikost systematické chyby metody (= velikost úseku  $\beta_0$ ).
- (2) Správnost metody (= směrnice měla být 1).
- (3) Pokuste se vyjádřit i přesnost metody.
- (4) Jsou v datech vlivné a vybočující body?
- (5) Tabulkové indikace vlivných bodů a pět nejdůležitějších grafů identifikace vlivných bodů.

**Data:** Obsah molybdenu, dáno  $x$  [%], stanoveno  $y$  [%]:

Dáno $x$	Stanoveno $y$
0.011	0.012
...	...
0.085	0.083

22



Odhady parametrů

Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost	Spodní mez	Horní mez
Abs	0.001034	0.000686	Nevýznamný	0.163	-0.00049559	0.0025644
V601x	0.972702	0.013748	Významný	7.77E-015	0.9420701358	1.003335592

Statistické charakteristiky regrese

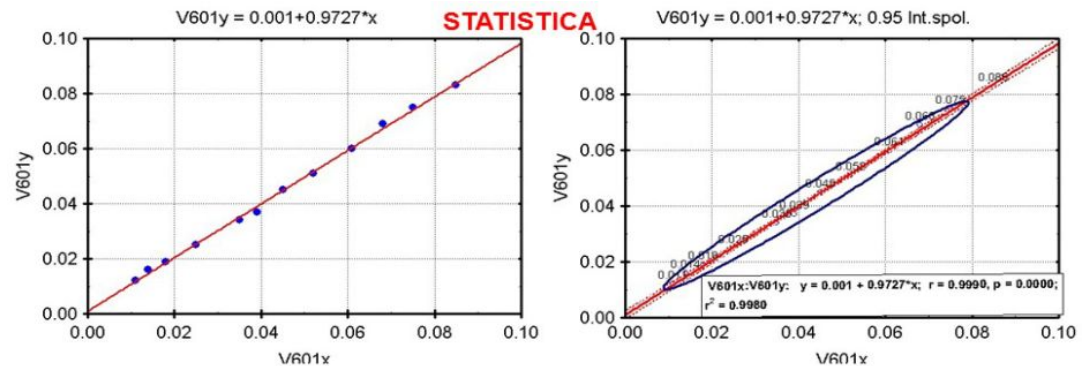
Vícenásobný korelační koeficient R:	0.99900
Koeficient determinace R <sup>2</sup> :	0.99800
Předikovaný korelační koeficient Rp:	0.99434

**Střední kvadratická chyba predikce MEP: 1.50063E-006**

**Akaikeho informační kritérium: -161.13**

Fisher-Snedecorův test významnosti modelu

Hodnota kritéria F:	5005.80
Kvantil F (1-alfa, m-1, n-m):	4.96460
Pravděpodobnost:	7.75E-015
Závěr:	Model je významný



Efekt	Odhady parametrů (V6.sta) Sigma-omezená parametrizace							
	V601y Param.	V601y Sm.Ch.	V601y t	V601y p	-95.00% LmtSpol.	+95.00% LmtSpol.	V601y Beta (β)	V601y Sm.Ch. β
Abs. člen	0.001034	0.000687	1.50641	0.162882	-0.000496	0.002564		
"V601x"	<b>0.972703</b>	<b>0.013748</b>	<b>70.75168</b>	<b>0.000000</b>	<b>0.942070</b>	<b>1.003336</b>	<b>0.999003</b>	<b>0.014120</b>

24

**Linear Regression Plot Section**

**Run Summary Section**

Parameter	Value	Parameter	Value
Dependent Variable	V601y	Rows Processed	81
Independent Variable	V601x	Rows Used in Estimation	12
Frequency Variable	None	Rows with X Missing	69
Weight Variable	None	Rows with Freq Missing	0
Intercept	0.0010	Rows Prediction Only	0
Slope	0.9727	Sum of Frequencies	12
R-Squared	0.9980	Sum of Weights	12.0000
Correlation	0.9990	Coefficient of Variation	0.0257
Mean Square Error	1.267129E-06	Square Root of MSE	1.125668E-03

**Summary Statement**

The equation of the straight line relating V601y and V601x is estimated as:  $V601y = (0.0010) + (0.9727) V601x$  using the 12 observations in this dataset. The y-intercept, the estimated value of V601y when V601x is zero, is 0.0010 with a standard error of 0.0007. The slope, the estimated change in V601y per unit change in V601x, is 0.9727 with a standard error of 0.0137. The value of R-Squared, the proportion of the variation in V601y that can be accounted for by variation in V601x, is 0.9980. The correlation between V601y and V601x is 0.9990. A significance test that the slope is zero resulted in a t-value of 70.7517. The significance level of this t-test is 0.0000. Since  $0.0000 < 0.0500$ , the hypothesis that the slope is zero is rejected. The estimated slope is 0.9727. The lower limit of the 95% confidence interval for the slope is 0.9421 and the upper limit is 1.0033. The estimated intercept is 0.0010. The lower limit of the 95% confidence interval for the intercept is -0.0005 and the upper limit is 0.0026.

**Descriptive Statistics Section**

Parameter Variable	Dependent V601y	Independent V601x
Count	12	12
Mean	0.0438	0.0440
Standard Deviation	0.0240	0.0247
Minimum	0.0120	0.0110
Maximum	0.0830	0.0850

**Correlation and R-Squared Section**

Parameter	Pearson Correlation Coefficient	R-Squared	Spearman Rank Correlation Coefficient
Estimated Value	0.9990	0.9980	1.0000
Lower 95% Conf. Limit (r dist'n)	0.9960		
Upper 95% Conf. Limit (r dist'n)	0.9995		
Lower 95% Conf. Limit (Fisher's z)	0.9963		1.0000
Upper 95% Conf. Limit (Fisher's z)	0.9997		1.0000
Adjusted (Rbar)	0.9978		
T-Value for H0: Rho = 0	70.7517	70.7517	
Prob Level for H0: Rho = 0	0.0000	0.0000	0.0000

**Notes:**  
The confidence interval for the Pearson correlation assumes that X and Y follow the bivariate normal distribution. This is a different assumption from linear regression which assumes that X is fixed and Y is normally distributed. Two confidence intervals are given. The first is based on the exact distribution of Pearson's correlation. The second is based on Fisher's z transformation which approximates the exact distribution using the normal distribution. Why are both provided? Because most books only mention Fisher's approximate method, it will often be needed to do homework. However, the exact methods should be used whenever possible. The confidence limits can be used to test hypotheses about the correlation. To test the hypothesis that rho is a specific value, say r0, check to see if r0 is between the confidence limits. If it is, the null hypothesis that rho = r0 is not rejected. If r0 is outside the limits, the null hypothesis is rejected. Spearman's Rank correlation is calculated by replacing the original data with their ranks.

This correlation is used when some of the assumptions may be invalid.

**Regression Estimation Section**

Parameter	Intercept B(0)	Slope B(1)
Regression Coefficients	0.0010	0.9727
Lower 95% Confidence Limit	-0.0005	0.9421
Upper 95% Confidence Limit	0.0026	1.0033
Standard Error	0.0007	0.0137
Standardized Coefficient	0.0000	0.9990
T Value	1.5064	70.7517
Prob Level (T Test)	0.1629	0.0000
Reject H0 (Alpha = 0.0500)	No	Yes
Power (Alpha = 0.0500)	0.2759	1.0000
Regression of Y on X	0.0010	0.9727
Inverse Regression from X on Y	0.0009	0.9746
Orthogonal Regression of Y and X	0.0010	0.9736

**Notes:**

The above report shows the least-squares estimates of the intercept and slope followed by the corresponding standard errors, confidence intervals, and hypothesis tests. Note that these results are based on several assumptions that should be validated before they are used.

**Estimated Model:**  $(1.03440731901351E-03) + (.972702863961814) * (V601x)$

**Tests of Assumptions Section**

Assumption/Test	Test Value	Prob Level	Is the Assumption Reasonable at the 0.2000 Level of Significance?
<b>Residuals follow Normal Distribution?</b>			
Shapiro Wilk	0.9853	0.996849	Yes
Anderson Darling	0.1507	0.962228	Yes
D'Agostino Skewness	0.0094	0.992478	Yes
D'Agostino Kurtosis	0.0319	0.974562	Yes
D'Agostino Omnibus	0.0011	0.999447	Yes

**Constant Residual Variance?**

Modified Levene Test	0.1117	0.745133	Yes
----------------------	--------	----------	-----

**Relationship is a Straight Line?**

Lack of Linear Fit F(0, 0) Test	0.0000	0.000000	No
---------------------------------	--------	----------	----

**No Serial Correlation?**

Evaluate the Serial-Correlation report and the Durbin-Watson test if you have equal-spaced, time series data.

**Notes:**

A 'Yes' means there is not enough evidence to make this assumption seem unreasonable. This lack of evidence may be because the sample size is too small, the assumptions of the test itself are not met, or the assumption is valid. A 'No' means the that the assumption is not reasonable. However, since these tests are related to sample size, you should assess the role of sample size in the tests by also evaluating the appropriate plots and graphs. A large dataset (say N > 500) will often fail at least one of the normality tests because it is hard to find a large dataset that is perfectly normal.

**Normality and Constant Residual Variance:**

Possible remedies for the failure of these assumptions include using a transformation of Y such as the log or square root, correcting data-recording errors found by looking into outliers, adding additional independent variables, using robust regression, or using bootstrap methods.

Straight-Line: Possible remedies for the failure of this assumption include using nonlinear regression or polynomial regression.

## Úloha V6.02 Bichromátometrická metoda stanovení železitých iontů

**Zadání:** Kraft a Dosch<sup>60</sup> navrhli titrační stanovení železa ve vodách. Železité ionty  $\text{Fe}^{3+}$  v  $\text{Fe}_2\text{O}_3$  se redukuje titanitou solí v přebytku a vzniklé ionty  $\text{Fe}^{2+}$  se pak stanoví bichromátometricky.

### Úkoly:

- (1) Vede titrační stanovení ke správným výsledkům?
- (2) Proved'te Studentův  $t$ -test významnosti úseku  $b_0$  (má být  $\beta_0 = 0$ ).
- (3) Proved'te Studentův  $t$ -test jednotkové směrnice  $b_1$  (má být  $\beta_1 = 1$ ).
- (4) Proved'te kombinovaný test obou parametrů v modelu přímky.
- (5) Popište test významnosti absolutního členu.
- (6) Popište test vhodnosti lineárního modelu dle Uttsově.

**Data:** Obsah  $\text{Fe}_2\text{O}_3$  [mg], dáno  $x$ , nalezeno  $y$ :

Dáno $x$	Stanoveno $y$
52.0	52.50
...	...
543.61	543.78

29

## Úloha V6.04 Stanovení kyseliny ftalové tenkovrstvou chromatografií

**Zadání:** Obsah kyseliny ftalové byl stanoven tenkovrstvou chromatografií a chromatogram byl vyhodnocován remisním fotometrem.

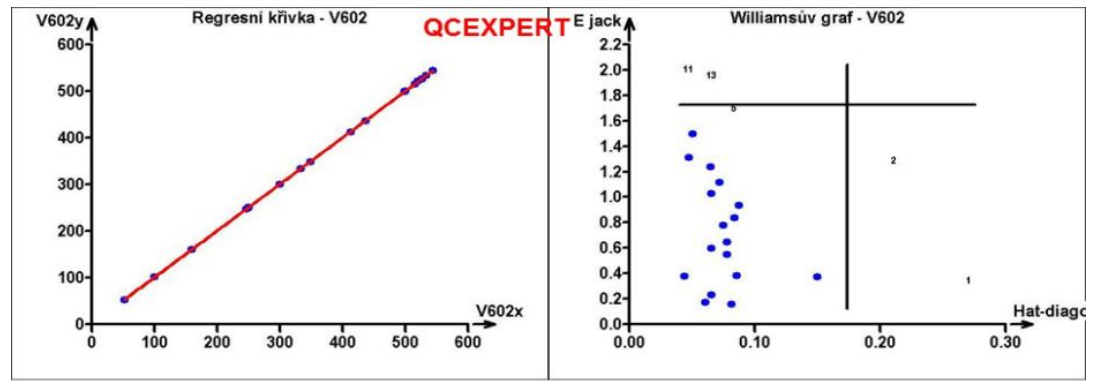
### Úkoly:

- (1) Stanovte oba parametry lineárního regresního modelu a vyšetřete, zda je úsek nulový a směrnice jednotková.
- (2) Vyšetřete, zda jsou v datech vybočující hodnoty?
- (3) Je stanovení je správné?
- (4) Jaký je nutno zvolit postup při porušení předpokladů MNČ?

**Data:** Obsah kyseliny ftalové [ $\mu\text{g}$ ], dáno  $x$ , nalezeno  $y$  (opakovaně).

Dáno $x$	Stanoveno $y$
0.50	0.48
...	...
5.23	65.02

31

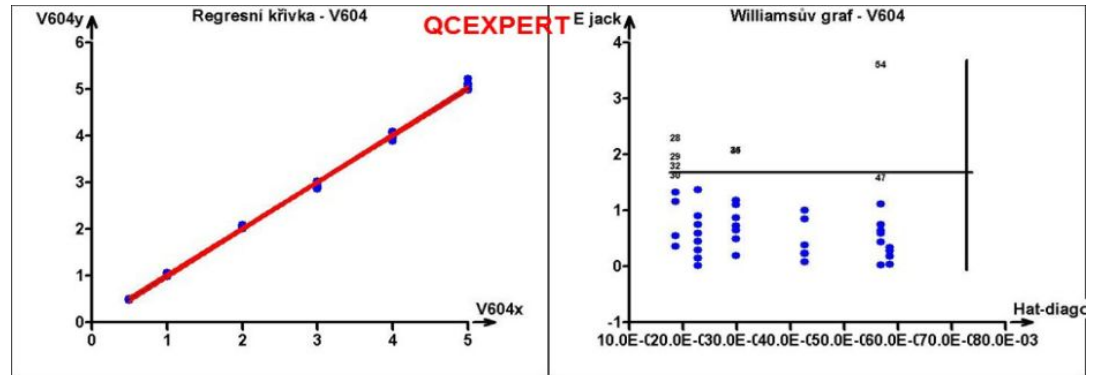


Odhady parametrů				
Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost
Abs	0.70845	0.23872	Významný	0.007343
V602x	0.99834	0.00056	Významný	0

Statistické charakteristiky regrese	
Vicenasobný korelační koeficient R :	0.99999
Koeficient determinace $R^2$ :	0.99999
Predikovaný korelační koeficient $R_p$ :	0.99998
Sředni kvadratická chyba predikce MEP :	0.17699
Akaikeho informační kritérium :	-39.545

Spodní mez	Horní mez
0.21200	1.20490
0.99716	0.99951

30



Odhady parametrů				
Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost
Abs	-0.0110	0.0187	Nevýznamný	0.5565
V604x	1.00588	0.0059	Významný	0

Statistické charakteristiky regrese	
Vicenasobný korelační koeficient R :	0.9990902542
Koeficient determinace $R^2$ :	0.9981813361
Predikovaný korelační koeficient $R_p$ :	0.9961043053
Sředni kvadratická chyba predikce MEP :	0.004614241291
Akaikeho informační kritérium :	-295.6513242

Spodní mez	Horní mez
-0.048499	0.026400
0.9940574	1.017716

32



### Úloha V6.06 Ověření stanovení železa spektrofotometrickou metodou

**Zadání:** Ověřte stanovení obsahu železa  $y$  v  $\text{CoSO}_4$  spektrofotometricky SFM  $y$  porovnáním výsledků standardního stanovení obsahu  $x$  metodou AAS, u které je předpokládána zanedbatelná náhodná chyba.

#### Úkoly:

- (1) Vedou obě metody ke shodným výsledkům?
- (2) Jsou v datech odlehlé hodnoty? Užijte pět grafů indikace vlivných bodů.

**Data:** Obsah železa v  $\text{CoSO}_4$  [%], když je AAS  $x$  [%], SFM  $y$  [%]:

Dáno $x$	Stanoveno $y$
0.010	0.011
...	...
0.152	0.149

33

### Úloha V6.07 Ověření stanovení dusičnanů v pitné a povrchové vodě

**Zadání:** V chemických laboratořích geochemické firmy se zavedla nová metoda stanovení obsahu dusičnanů  $y$  v pitných ale také povrchových vodách pomocí iontově párové chromatografie.

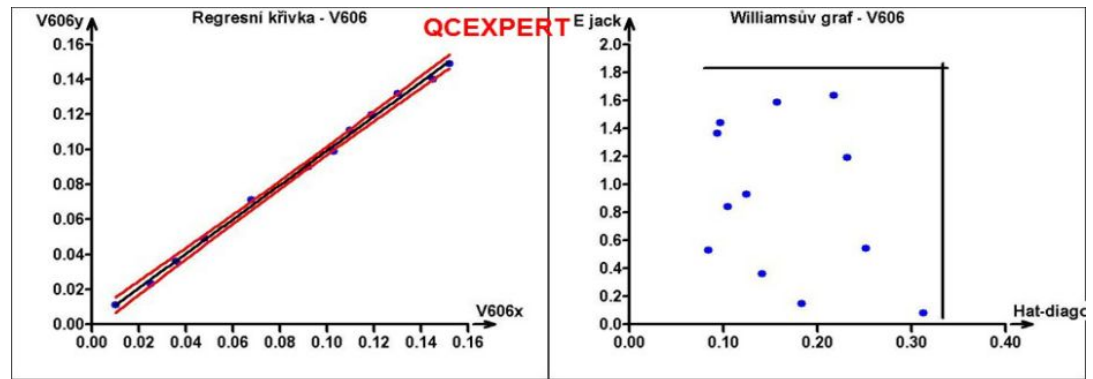
#### Úkoly:

- (1) Validujte novou metodu vůči deklarovaným obsahům  $\text{NO}_3^-$  [mg/l]  $x$ .
- (2) Odhadněte regresní parametry metodu ortogonální regrese.
- (3) Vede nová metoda ke správným výsledkům?
- (4) Proveďte simultánní test významnosti úseku a významnosti směrnice, zda je rovna jedné.

**Data:** Pro obsah dusičnanů  $\text{NO}_3^-$  [mg/l] je dáno  $x$ , nalezeno  $y$ .

Dáno $x$	Stanoveno $y$
2.10	2.20
...	...
200.00	195.00

35



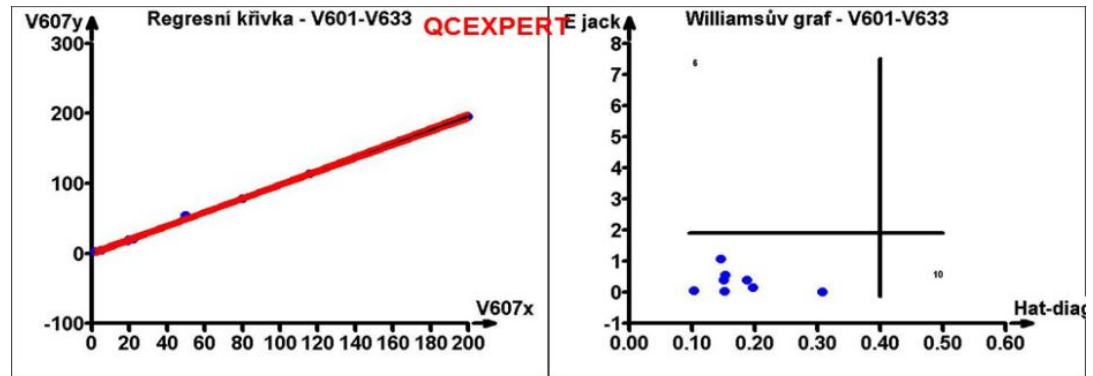
#### Odhady parametrů

Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost	Spodní mez	Horní mez
Abs	0.001011	0.001531	Nevýznamný	0.5238	-0.0023997	0.0044219
V606x	0.981567	0.015615	Významný	2.5313E-014	0.9467727	1.0163614

#### Statistické charakteristiky regrese

Vicenasobný korelační koeficient R:	0.9987368986
Koeficient determinace $R^2$ :	0.9974753927
Předikovaný korelační koeficient $R_p$ :	0.9929318535
Sředni kvadratická chyba predikce MEP:	7.273899498E-006
Akaikeho informační kritérium:	-142.032264

34



#### Odhady parametrů

Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost	Spodní mez	Horní mez
Abs	-0.14284	0.9389	Nevýznamný	0.88284	-2.3079	2.0222
V607x	0.9801479567	0.0098	Významný	1.179E-013	0.95739	1.0029

#### Statistické charakteristiky regrese

Vicenasobný korelační koeficient R:	0.9995948631
Koeficient determinace $R^2$ :	0.9991898903
Předikovaný korelační koeficient $R_p$ :	0.9978300448
Sředni kvadratická chyba predikce MEP:	4.643796689
Akaikeho informační kritérium:	16.4284433

36

### Úloha V6.20 Validace nové metody stanovení arsenu v odpadní vodě

**Zadání:** Je třeba validovat nové jednodušší stanovení arsenu v odpadní vodě. Mezi naměřenou koncentrací arsenu  $y$  a známou koncentrací  $x$  v  $\mu\text{g/ml}$  je předpokládán lineární regresní model  $y = \beta_0 + \beta_1 x$ .

#### Úkoly:

- (1) Užitím ortogonální regrese ověřte správnost nové metody.
- (2) K jakému výsledku dospěje nová metoda, když standard arsen vůbec neobsahuje čili absolutní člen je nulový,  $\beta_0 = 0$ ?
- (3) Vyšetřete, zda nová metoda nadhodnocuje či podhodnocuje?
- (4) Jakou modifikaci MNC je třeba použít, když jsou všechny proměnné zatíženy náhodnými chybami?

**Data:** Koncentrace arsenu daná  $x$  [ $\mu\text{g. cm}^{-3}$ ], nalezená  $y$  [ $\mu\text{g. cm}^{-3}$ ].

Dáno $x$	Stanoveno $y$
0	0.17
...	...
7.0	7.30

37

### Úloha V6.22 Validace navržené titrační metody ke stanovení modré báze MB H-3R

**Zadání:** Při výrobě modré báze MB H-3R byl stanovován její obsah v pastě z kalolisu titračně dusitanem v kyselém prostředí  $y$  a standardně spektrofotometricky  $x$ . Za základ byla vzata titrační metoda. Rozptyl této metody se považuje za zanedbatelný vůči rozptylu spektrofotometrické metody.

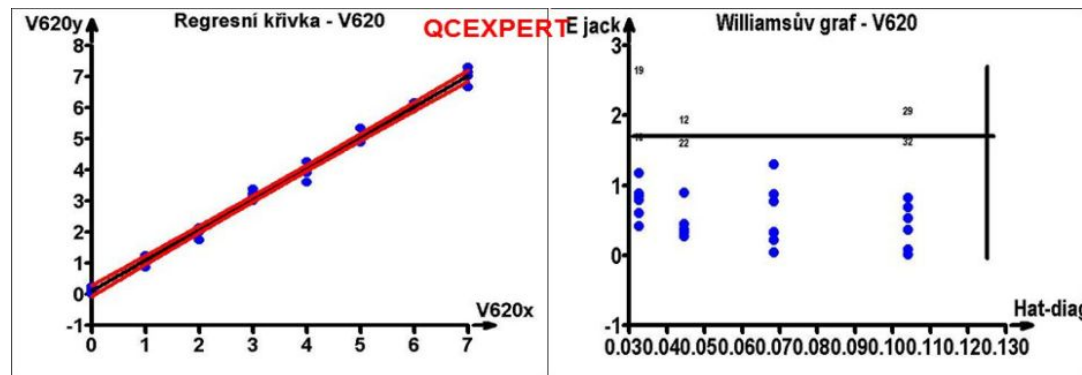
#### Úkoly:

- (1) Popište test významnosti absolutního členu.
- (2) Vysvětlete test shodnosti odhadu parametru  $\beta$  s předepsanou  $\beta_0$ .

**Data:** Koncentrace modré báze spektrofotometrickou metodou  $x$  a titrační metodou  $y$ .

Dáno $x$	Stanoveno $y$
52.0	50.3
...	...
69.2	60.1

39



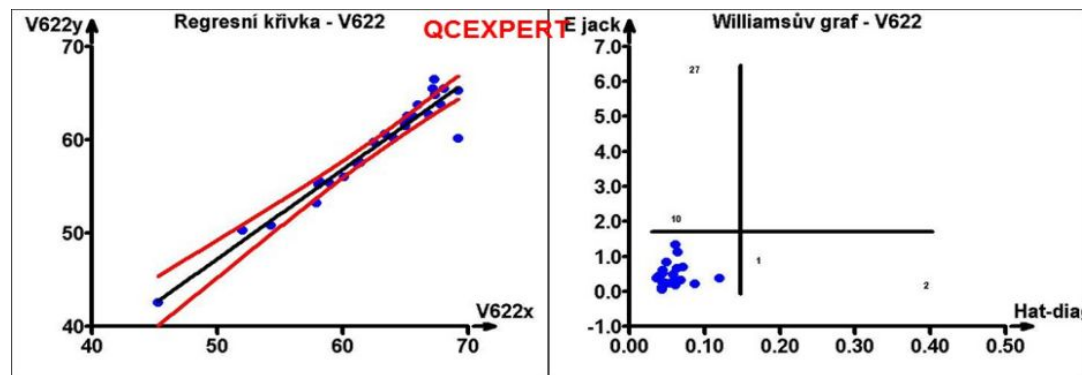
Odhady parametrů				
Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost
Abs	0.10458	0.06051	Nevýznamný	0.0942
V620x	0.98770	0.01446	Významný	0

Statistické charakteristiky regrese				
Vicenasobný korelační koeficient R :	0.99679			
Koeficient determinace R <sup>2</sup> :	0.99360			
Předikovaný korelační koeficient Rp :	0.98563			
Sřední kvadratická chyba predikce MEP :	0.03715			
Akaikeho informační kritérium :	-105.20			

Spodní mez	Horní mez
-0.01899	0.228167
0.958168	1.017248

38



Odhady parametrů				
Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost
Abs	-0.65650	3.14318	Nevýznamný	0.83624
V622x	0.957240	0.04994	Významný	2.220E-016

Statistické charakteristiky regrese				
Vicenasobný korelační koeficient R :	0.967619281			
Koeficient determinace R <sup>2</sup> :	0.936287073			
Předikovaný korelační koeficient Rp :	0.8551935541			
Sřední kvadratická chyba predikce MEP :	2.300430311			
Akaikeho informační kritérium :	22.00604283			

Spodní mez	Horní mez
-7.1300	5.8170
0.85438	1.0600

40

### Úloha V6.31 Validace stanovení chromu metodou AAS a ICP-AES

**Zadání:** Ve vzorcích půdy byl stanoven metodami AAS a ICP-AES obsah chromu.

#### Úkoly:

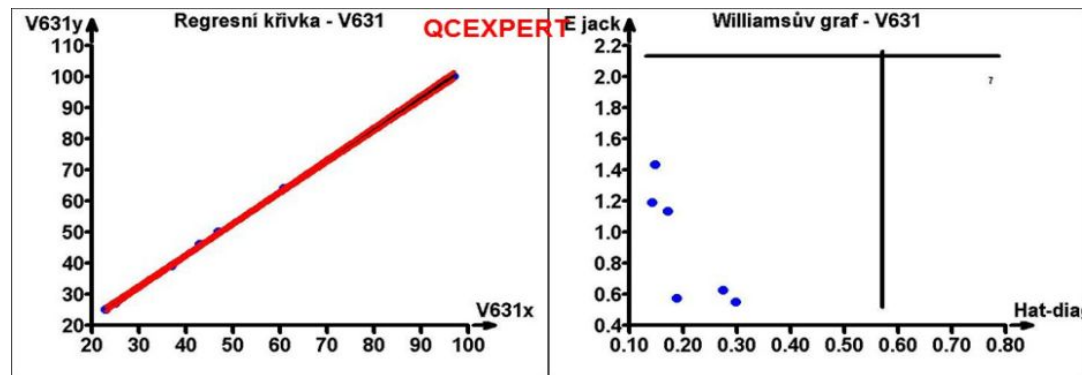
- (1) Porovnejte shodnost výsledků stanovení oběma metodami.
- (2) Vysvětlete 7 předpokladů MNČ a řešení regresního tripletu.
- (3) Ukažte postup validace nové analytické metody testování nulovosti úseku a jednotkovosti směrnice.
- (4) Jak se bude řešit tato úloha v případě porušení předpokladů MNČ?

**Data:**  $x$  značí AAS [mg/kg],  $y$  značí ICP-AES [mg/kg]:

Dáno $x$	Stanoveno $y$
25	27
...	...
97	100

41

43



#### Odhady parametrů

Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost	Spodní mez	Horní mez
Abs	1.86193	0.35244	Významný	0.00323	0.95595	2.76791
V631x	1.01491	0.00664	Významný	2.27699E-10	0.99784	1.03198

#### Statistické charakteristiky regrese

Vicenasobný korelační koeficient R :	0.9998929533
Koeficient determinace $R^2$ :	0.999785918
Předikovaný korelační koeficient $R_p$ :	0.9985017625
Sředni kvadratická chyba predikce MEP :	0.4268212711
Akaikeho informační kritérium :	-10.73012051

42