


IV.

Jednoduchá lineární regrese

- Lineární závislost

$$y = \alpha + \beta x$$



koeficienty lineární regrese

$$b = \frac{(\sum x)(\sum y) - n \sum xy}{(\sum x)^2 - n \sum x^2}$$

$$a = \frac{\sum y - b \sum x}{n}$$

a, b = odhady koeficientů pomocí
MNČ

Regressní rezidua


Reziduální hodnota predikce (chyba predikce) – e : $e_i = y_i - a - bx = y_i - \hat{y}_i$

MNČ: minimalizace reziduální sumy čtverců (RSC)

$$RSC = s_r^2 = \sum e_i^2 = \sum (y_i - a - bx_i)^2$$

Reziduální rozptyl

$$s_{yx}^2 = \frac{s_r^2}{n-2} = \frac{\sum (y_i - \hat{y}_i)^2}{n-2}$$



Předpoklady použití metody nejmenších čtverců

- Mezi proměnnými x a y je lineární vztah.
- Náhodné chyby e mají normální rozdělení, nulovou střední hodnotu a konstantní rozptyl (homoskedasticita). Náhodné chyby e jsou vzájemně nekorelované:
$$\text{cov}(e_i, e_j) = 0.$$
- Hodnoty y_i mají pro dané hodnoty přesně určených x_i normální rozdělení. Hodnoty y jsou vzájemně nekorelované: $\text{cov}(y_i, y_j) = 0.$

Ověřování předpokladů regresní analýzy

- Grafická analýza reziduí
- Normalita reziduí: histogram, QQplot, PPplot
- Vhodnost modelu (znaménkový test)

Testování regresních koeficientů analýzy

testy významnosti regresních koeficientů

testy shody regresních koeficientů (srovnání dvou přímek)






Regresní rezidua

Grafická analýza

Osa x: hodnoty x

Osa y: rezidua (e)

- a) Splněn předpoklad lineárního vztahu
- b) Heteroskedasticita
- c) Nelinearita
- d) Časová závislost
- e) Odlehlé hodnoty



Testování významnosti regresních koeficientů

Pomocí t-testu

$$L_a = a \pm t_{\alpha} s_a$$

$$L_b = b \pm t_{\alpha} s_b$$

$$s_a = s_{yx} \sqrt{\left[\frac{1}{n} + \frac{\bar{x}^2}{\sum x^2 - (\sum x)^2 / n} \right]}$$

$$s_b = \frac{s_{yx}}{\sqrt{\sum x^2 - (\sum x)^2 / n}}$$

Test shody regresních přímek


- RSC_c reziduální suma čtverců všech M skupin dat

$$RSC_c = \sum_{j=1}^M RSC_j$$
$$F_A = \frac{\frac{RSC_k - RSC_c}{2M - 2}}{\frac{RSC_c}{n - 2M}}$$

F rozdělení s $2M-2$ a $n-2M$ stupni volnosti.


Interval spolehlivosti predikovaných hodnot

$$L_{12} = \hat{y}_i \pm s_{yx} \sqrt{\left[\frac{1}{n} + \frac{(\hat{x}_i - \bar{x})^2}{\sum x^2 - (\sum x)^2 / n} \right]}$$



Fiktivní proměnné



- používají se v případě nespojitostí; jsou zpravidla celočíselné, nejčastěji 0/1



Lineární lomená regrese

Neparametrická regrese

Chyby u „závisle“ i „nezávisle“ proměnné




Odhad regresních přímek závislosti c_1 na c_2 a c_2 na c_1

$$r = \sqrt{b_{xy} b_{yx}}$$

Neparametrická regrese

Ortogonalní regrese



- a) vzdálenost pro regresi, kde y je závisle proměnná
- b) vzdálenost pro regresi, kde x je závisle proměnná
- c) vzdálenost pro ortogonální regresi

Neparametrická regrese

Demingova regrese

Vztah mezi dvěma metodami pomocí vážené regrese

$$\min S = \sum w_i (y_i - \hat{y}_i)^2 + v_i (x_i - \hat{x}_i)^2$$

$$x_i = \hat{x}_i + \varepsilon_i$$

$$y_i = \hat{y}_i + \delta_i$$

$$b = G + \sqrt{G^2 + 1/\lambda}$$

$$G = \frac{s_y^2 - (1/\lambda)s_x^2}{2rs_x s_y}$$

$$a = \bar{y} - b\bar{x}$$

Neparametrická regrese

- Pasing-Bablokova regrese

medián částečných odhadů regresního koeficientu ($j < i$)



$$b_{ij} = \frac{y_i - y_j}{x_i - x_j}$$

$$a = \bar{y} - b\bar{x}$$


Srovnání dvou metod

Youdenova metoda

Obr. 9a. Youdenova metoda
Výsledky x_A , získané standardní
metodou, vynášíme proti x_B , vý-
sledkům získaným na stejných
vzorcích testovanou metodou.
Správné výsledky leží na úhlo-
příčce



Obr. 9b. Youdenova metoda
Výsledky jsou zatíženy soustavnou
proporcionální chybou



Obr. 9c. Youdenova metoda
Výsledky jsou zatíženy
konstantní soustavnou chybou

Srovnání dvou metod

- Bland-Altmanův graf


Osa y: $x_{1i} - x_{2i}$

Osa x: x_{1i} , x_{2i} nebo $(x_{1i} + x_{2i})/2$

- Poměrový graf

Osa y: x_{1i} / x_{2i}

Osa x: x_{1i} nebo x_{2i}



Regulační diagramy

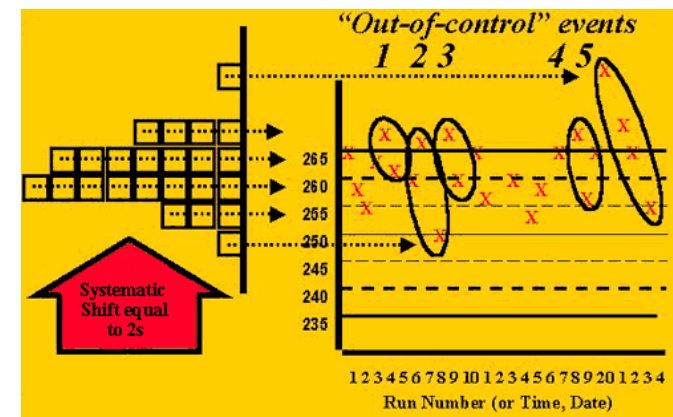
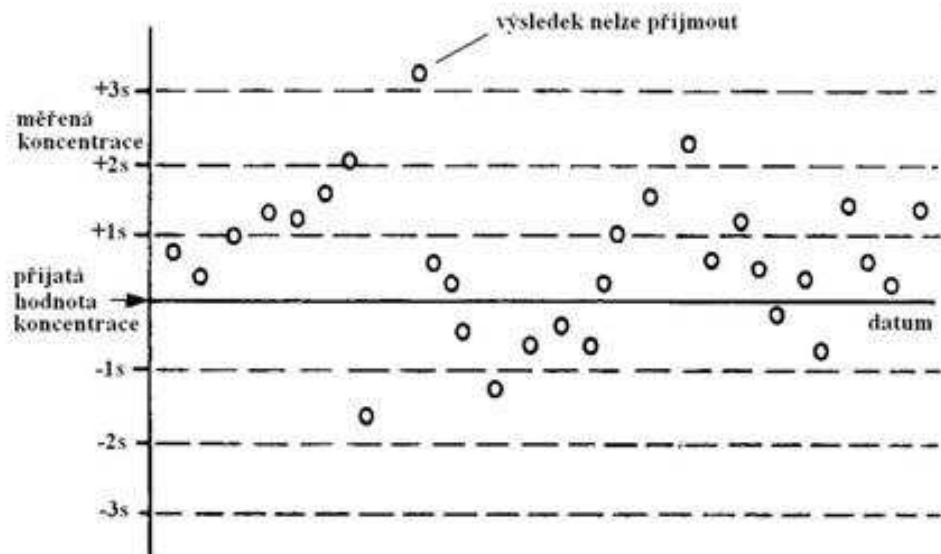
- Diagramy pro posouzení střední hodnoty (správnost): průměr, medián (Shewhart)
- Diagramy pro posouzení variability (přesnost): směr. odchylka, var. rozpětí
- Diagramy kumulativních součtů (CUSUM)
- Diagramy na bázi lokálního vyhlazování: pohyblivý geometrický průměr (EWMA).

Regulační diagramy - Shewhart

Slouží k dlouhodobému sledování správnosti produkováných výsledků

Po dlouhou dobu jsou zaznamenávány opakované výsledky analýzy jednoho parametru referenčního materiálu

Regulační diagram ukazuje, zda je celý analytický systém ve statistické rovnováze

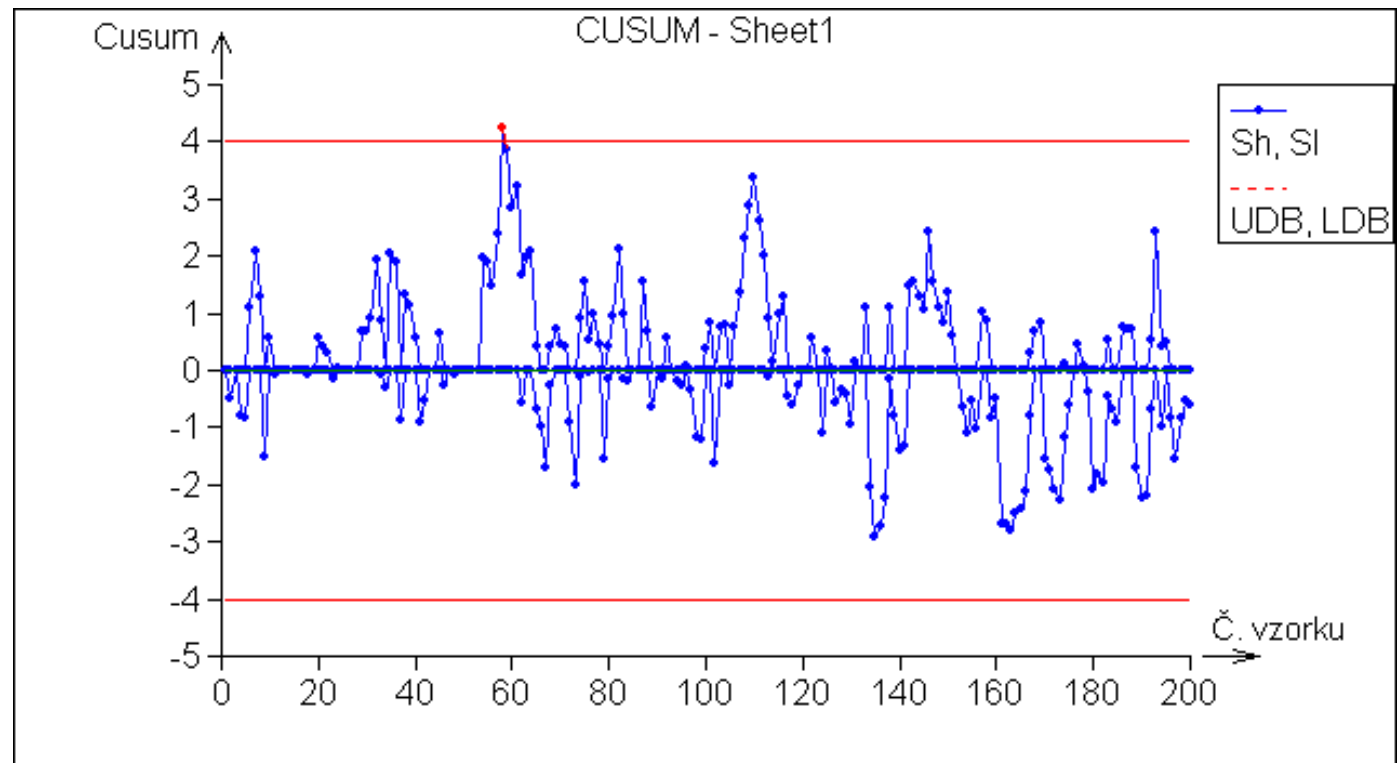


Shewhartův diagram

- **Nenormalita:** transformace dat, empirická distribuční funkce/hustota pravděpodobnosti.
- **Nestejně velikosti výběru:** úprava mezí.
- **Autokorelace:** roste počet případů překročení regulační meze, korekce – zvětšení mezí o $\frac{1}{\sqrt{1-\rho^2}}$
- **Vybočující měření:** využití kvantilových charakteristik.



Regulační diagramy - CUSUM

- Postupně se sčítají odchylky sledovaných hodnot od střední hodnoty.
- Citlivější než Shewhart x více ovlivněn odchylkami od normality a autokorelací.



Srovnání více metod pro dva vzorky

- Youdenova metoda




YOUDENOVA metoda
A - soustavná chyba jednotlivých laboratoří, *B* - absolutní soustavná chyba d_s , a náhodná chyba d_n

Vícenásobná lineární regrese

- Závislost na několika faktorech

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \dots + \beta_n x_n$$



Interakce mezi x_1 a x_2

Logistická regrese: y = dichotomická proměnná

Vícenásobná lineární regrese

- Předpoklady:
 - Homoskedasticita (konstantní rozptyl reziduí)
 - Nezávislost reziduí (autokorelace = korelace mezi rezidui)
 - Normalita reziduí

Multikolinearita = závislost mezi proměnnými x_i

Grafy: Parciální regresní
 Parciální reziduální

Nelineární regrese

- Mocninná funkce
- Exponenciální funkce
- Logaritmická funkce
- Logistická funkce


$$y = \frac{c}{1 + be^{-ax}}$$

Linearizace nelineárních závislostí


Nelineární vztah	Transformace proměnných		Transformace koeficientů	
	Y	X	\bar{a}	\bar{b}
$y = a + \frac{b}{x}$	y	$\frac{1}{x}$	a	b
$y = \frac{1}{a + bx}$ nebo $\frac{1}{y} = a + bx$	$\frac{1}{y}$	x	a	b
$y = \frac{x}{a + bx}$	$\frac{x}{y}$	x	a	b
$y = ab^x$	$\ln y$	x	$\ln a$	$\ln b$
$y = ae^{bx}$	$\ln y$	x	$\ln a$	b
$y = ax^b$	$\ln y$	$\ln x$	$\ln a$	b

Polynomická regrese

$$y = k_0 + k_1x + k_2x^2 + \dots + k_nx^n$$




Obr. 13a. Množina deseti bodů proložena přímkou $y = k_0 + k_1x$
Při extrapolaci na $x = 0$ je $y_0 = +2,75$




Obr. 13b. Tytéž body z obr. 13a proloženy křivkou, která odpovídá polynomu třetího stupně

$$y = k_0 + k_1x + k_2x^2 + k_3x^3$$

Při extrapolaci na $x = 0$ je $y_0 = +2,33$



Obr. 13c. Tytéž body z obr. 13a proloženy křivkou, která odpovídá polynomu čtvrtého stupně





Obr. 13d. Tytéž body z obr. 13a: proloženy křivkou, která odpovídá polynomu šestého stupně

Vyrovnávání dat (v histogramu)

Funkcí rozdělení

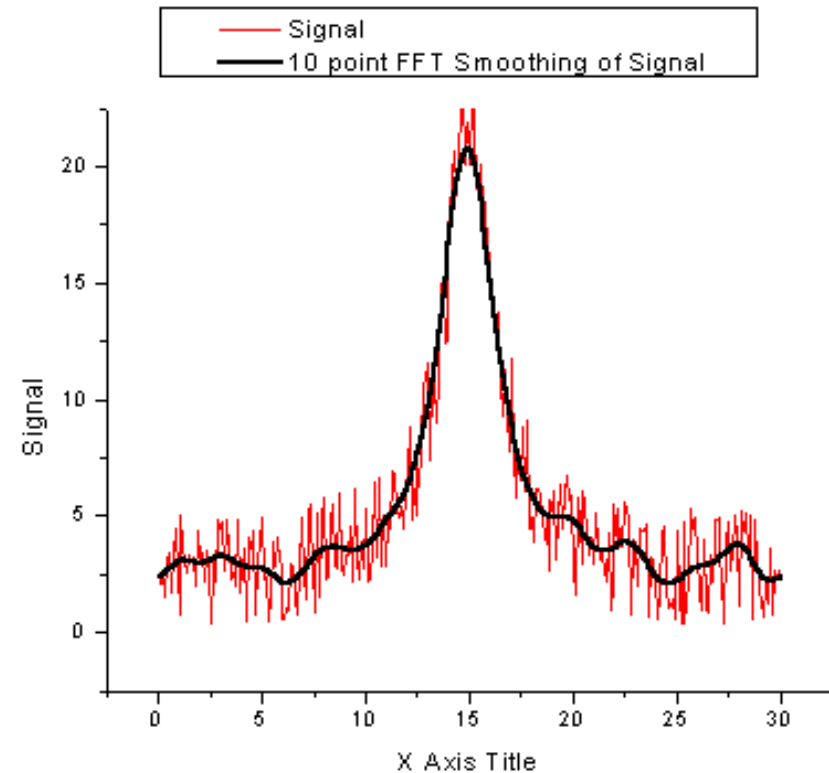
- binomické,
- Poissonovo,
- normální,
- lognormální).



Empirickou funkcí (KDE, ortogonálními polynomy, FFT, Savitzky – Golay)

Vyrovnávání časových závislostí

- Metoda klouzavých průměrů (moving averages)
- Metoda vážených klouzavých průměrů
- Metoda Savitzky - Golay
- Spliny
- Rychlá Fourierova transformace (FFT)
- Jádrové odhady



Klouzavé průměry

Hodnota závisle proměnné je nahrazena dílčím průměrem z dané hodnoty, n předchozích a n následujících hodnot.

