

# PODSTATNÉ TESTY VÝZNAMNOSTI V KORELAČNÍ A REGRESNÍ ANALÝZE

- ◆ test významnosti korelačního koeficientu
- ◆ test významnosti modelu jako celku
- ◆ test významnosti jednotlivých regresních parametrů
- ◆ test shody lineárních regresních modelů
- a mnoho dalších testů.....

## TEST VÝZNAMNOSTI $R$

Test významnosti odpovídá, zda je korelace  $R$  mezi výběrovými proměnnými natolik silná, abychom ji mohli považovat za prokázanou i pro základní soubor  $\rho$ .

Pro párový  $R$ :  $t_R = \frac{R \cdot \sqrt{n - 2}}{\sqrt{1 - R^2}}$   $t_{\alpha, n-2}$   $n$  je počet hodnot výběru

Pro násobný  $R$ :  $F_R = \frac{R^2(n - m)}{(1 - R^2)(m - 1)}$   $t_{\alpha, n-m}$   $m$  je počet proměnných

Pro parciální  $R$ :  $t_R = \frac{R \cdot \sqrt{n - k - 2}}{\sqrt{1 - R^2}}$   $t_{\alpha, n-k-2}$   $k$  je počet „vyloučených“ proměnných

## TEST VÝZNAMNOSTI REGRESNÍHO MODELU

### Co vlastně testujeme?

$$Y = b_0 + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_mx_m$$

**Testujeme významost odhadů jednotlivých parametrů:** když je testovaný odhad parametru statisticky nevýznamný, pak jeho příslušná proměnná  $x_j$  **nepřispívá** ke zpřesnění odhadu závisle proměnné  $y$  a tato proměnná  $x_j$  je pak v modelu zbytečná.

**Testujeme model jako celek:** tj. zda příslušná kombinace všech nezávisle proměnných statisticky významně zpřesní odhad závisle proměnné  $y$  oproti použití pouhého průměru hodnot  $y$ .

## TEST VÝZNAMNOSTI REGRESNÍCH PARAMETRŮ

$H_0: \beta_j = 0$ , tj.  $j$ -tý regresní parametr je nevýznamný

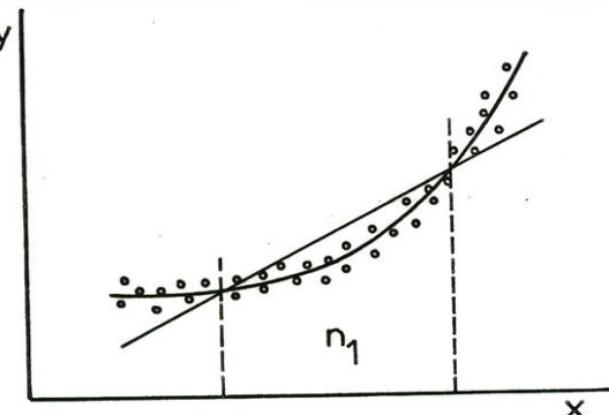
$$t = \frac{b_j - \beta_j}{s_b} \quad \text{pro } \beta_j = 0 \quad \rightarrow \quad t = \frac{b_j}{s_b}$$

Pokud platí, že  $|t| > t_{\alpha/2, n-m}$ , potom je  $j$ -tý regresní parametr statisticky významný a příslušná proměnná musí zůstat v modelu.

## Testy vhodnosti lineárního modelu

### 1. Test správnosti lineárního modelu $f(x, \beta) = X\beta$ dle Uttsové:

$H_0$ : lineární model vs.  $H_A$ : nelineární model



### 2. Test kvadratického členu

$H_0: \beta_2 = 0$  (test významnosti  $\beta_2$ )

$$E(y/x) = \beta_1 x + \beta_2 x^2 + \beta_3$$

RSC<sub>K</sub> pro kvadratický model

RSC<sub>L</sub> pro lineární model

Testační kritérium linearity

$$F_L = \frac{(RSC_L - RSC_K)(n - 3)}{RSC_K(1)}$$

Test: Je-li  $F_L < F_{1-\alpha}(1, n - 3)$ , je  $H_0$  přijata.

RSC<sub>1</sub> regresí s využitím  $n_1$  bodů,  
RSC regresí s využitím všech  $n$  bodů.

Testační kritérium

$$F_U = \frac{(RSC - RSC_1)(n_1 - m)}{RSC_1(n - n_1)}$$

Uttsová: volit  $n_1 \approx n/2$  a body co nejblíže k těžišti

Test: Je-li  $F_U < F_{1-\alpha}(n - n_1, n_1 - m)$ , je  $H_0$  přijata.

### 3. Linearita testem všech charakteristik

#### a) Střední kvadratická chyba predikce

$$MEP = \frac{1}{n} \sum_{i=1}^n (y_i - x_i^T b_{(i)})^2$$

kde  $b_{(i)}$  je odhad, určený ze všech bodů kromě i-tého  
Platí vztah

$$MEP = \frac{1}{n} \sum_{i=1}^n \frac{\hat{e}_i^2}{(1 - H_{ii})^2}$$

pro velké  $n$  jsou prvky  $H_{ii} \approx 0$  a  $MEP = RSC/n$ .

## b) Predikovaný koeficient determinace

$$\hat{R}_P^2 = 1 - \frac{n \text{ MEP}}{\sum_{i=1}^n y_i^2 - n\bar{y}}$$

## c) Akaikovo informační kritérium

$$AIC = n \cdot \ln\left(\frac{RSC}{n}\right) + 2m$$

nejvhodnější model má AIC minimální

**Příklad 6.16** Výběr ze tří polynomických regresních modelů  
Regresní analýzou dat vyšetřete, zda místo kvadratického modelu by lépe vyhovoval polynom třetího nebo pátého stupně.

Řešení:

### a) Polynom 3. stupně:

MEP,  $\hat{R}_P^2$  a AIC indikují polynom třetího stupně jako nejhodnější  
 $\hat{y}_P = 860.2 (\pm 85.17) - 5.057 (\pm 0.485) x + 9.77 \cdot 10^{-3} (\pm 9.19 \cdot 10^{-4}) x^2 - 6.146 \cdot 10^{-6} (\pm 5.78 \cdot 10^{-7}) x^3$

přičemž odhadové všechny tři parametry vycházejí statisticky významné.

## HODNOCENÍ KVALITY REGRESNÍHO MODELU

### Střední kvadratická chyba predikce (MEP)

$$MEP = \frac{1}{n} \sum_{i=1}^n \frac{e_i^2}{(1 - H_{ii})^2}$$

$e_i^2$  čtverec reziduí modelu  
 $H_{ii}$   $i$ -tý diagonální prvek  
projekční matici  $H$

### Akaikovo informační kritérium (AIC)

$$AIC = n \cdot \ln\left(\frac{RSC}{n}\right) + 2m$$

RSC reziduální součet čtverců  
 m počet parametrů

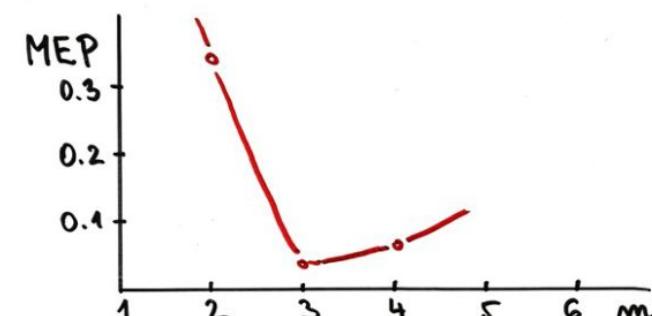
Čím je AIC (MEP) menší, tím je model vhodnější.

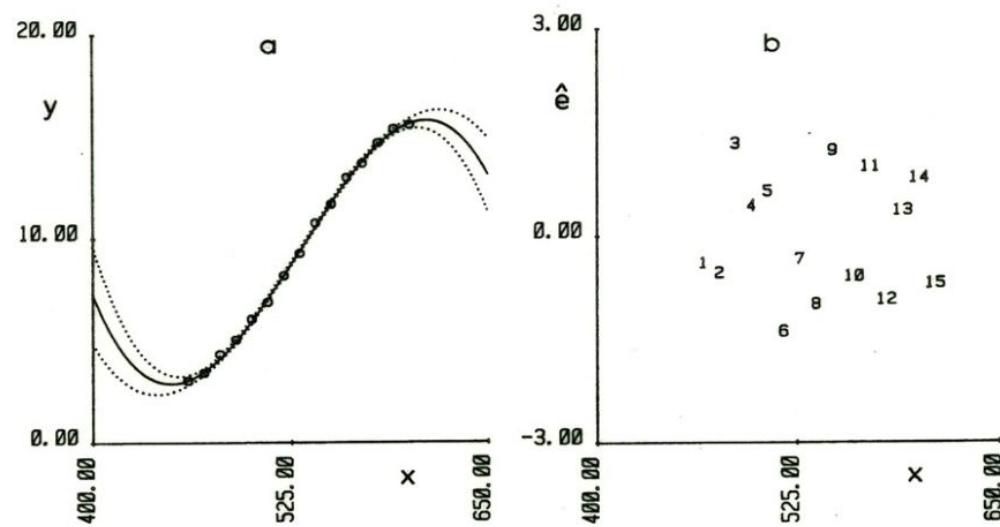
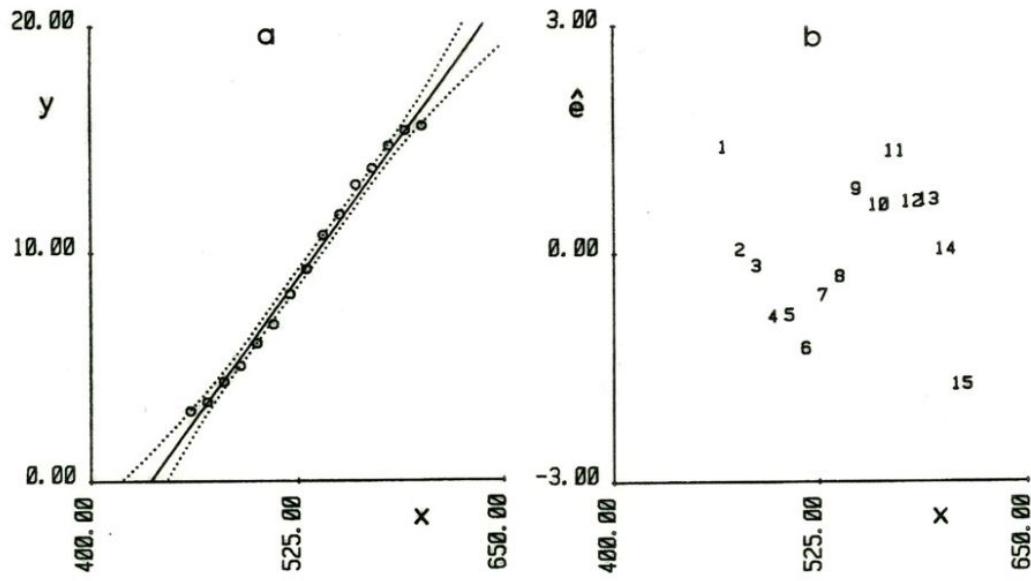
### b) Polynom 5. stupně:

všechny parametry  $\beta$  kromě  $\beta_3$  vycházejí statisticky nevýznamné, protože se zde projevuje multikolinearita.

**Tabulka 6.3** Rozlišení stupně regresního polynomu statistikami MEP,  $\hat{R}_P^2$ ,  $\hat{R}^2$  a AIC

Stupeň polynomu	MEP	$\hat{R}_P^2$	$\hat{R}^2$	AIC
2	0.3502	0.9905	0.9915	-21.65
3	0.0283	0.9992	0.9992	-56.02
5	0.0613	0.9983	0.9997	-55.04





**Závěr:** Je patrné, že některé statistiky pro vystížení linearity modelu nebo vhodnosti specifikace modelu selhávají.

#### Úloha L6.02 Závislost výšky píku kyseliny kyanurové na koncentraci želatiny

Při stanovení kyseliny kyanurové metodou diferenční pulsní polarografie byl sledován vliv přítomnosti povrchově aktivních látek. (1) Určete stupeň polynomu  $m$  závislosti výšky píku kyseliny kyanurové  $y$  na koncentraci želatiny  $x$ . (2) Které z kritérií,  $MEP$  nebo  $AIC$ , má lepší rozlišovací schopnost při určení stupně polynomu? (3) Pokuste se snížit multikolinearitu. Jak se indikuje multikolinearita v datech a jakou modifikaci MNČ je potom nutno použít k získání nejlepších odhadů neznámých parametrů  $\beta$  a výstavby regresního modelu?

Data: Koncentrace  $x$  [mg/l], výška píku  $y$  [mm]:

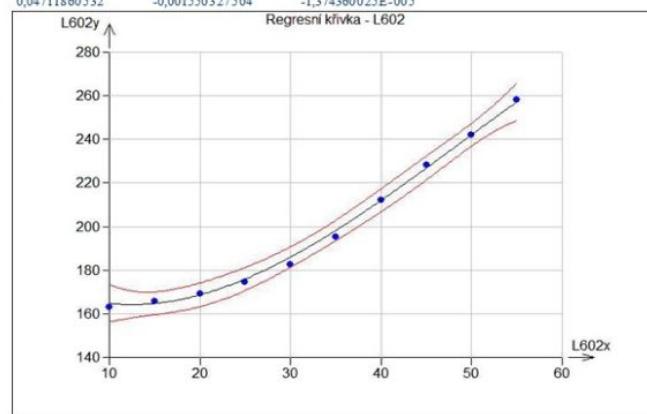
$x$	$y$
10	163.2

#### Odhady parametrů

Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost	Spodní mez	Hornímez
Abs	179,0372815	7,930198308	Významný	4,943150438E-007	159,6327853	198,4417778
L602x	-2,488912	0,915025471	Významný	0,0346416754	-4,727877869	-0,249904531
L602x^2	0,1141248515	0,03084462348	Významný	0,0100847791	0,03865077678	0,1895989262
L602x^3	-0,000782035	0,00031398431	Významný	0,04711860532	-0,001550327504	-1,374360025E-005

#### Statistické charakteristiky regrese

Vícenásobný korelační koeficient R :	0,9986434468
Koeficient determinace R^2 :	0,9972887328
Predikovaný korelační koeficient Rp :	0,9707849726
Střední kvadratická chyba predikce MEP :	15,49028891
Akaikeho informační kritérium :	18,48707943



#### Úloha L6.10 Závislost teploty tuhnutí nitrobenzenu na obsahu vody

Byla změřena závislost bodu tuhnutí nitrobenzenu  $y$  na obsahu vody  $x$ . (1) Rozhodněte, zda je daná závislost lépe vystížena lineárním nebo kvadratickým modelem. (2) Užijte testu kvadratického člena. (3) Mají nalezené odhady parametrů statistický význam?

Data: Obsah vody  $x$  [hm. %], bod tuhnutí  $y$  [EC]:

$x$	$y$
0.041	5.57
...	...
0.38	5.25

#### Odhady parametrů

Proměnná	Odhad	Směr.Odch.	Závěr	Pravděpodobnost	Spodní mez	Hornímez
Abs	5,727095246	0,04398713614	Významný	9,989698224E-007	5,587108547	5,867081945
L610x	-4,246051891	1,009151765	Významný	0,02451525638	-7,457623196	-1,034480585
L610x^2	17,52172931	5,680999542	Nevýznamný	0,05395516144	-0,5577466946	35,60120531
L610x^3	-26,02187677	9,073748545	Nevýznamný	0,0641646745	-54,8985943	2,854840765

#### Statistické charakteristiky regrese

Vícenásobný korelační koeficient R :	0,9951621992
Koeficient determinace R^2 :	0,9903478027
Predikovaný korelační koeficient Rp :	0,8534457695
Střední kvadratická chyba predikce MEP :	0,0013830323
Akaikeho informační kritérium :	-52,5456134

