


## Příkladová data


### Výška otce    Výška syna

175	178
177	173
188	188
173	173
163	164
163	168
178	169
...	...



### Vodivost vody    Ca ionty

164	22.081
155	13.600
467	37.800
171	19.600
67	6.280
78	14.237




## Analýza vztahu dvou kvantitativních proměnných

Dva přístupy, pohledy: **korelace** a **regrese**.

**KORELACE** popisuje sílu vzájemné závislosti.


**REGRESE** pomocí jedné proměnné popisuje hodnoty druhé proměnné

Příklad: výšky otce a syna (data GaltonSyn)



# Regresie – původ názvu



Sir F. Galton (1886): dědičnost výšky postavy



## Regresy – vysvětlení variability Y pomocí X

- Opět spojité, kvantitativní data
- Hodnoty proměnné  $Y$  modelujeme pomocí hodnot proměnné  $X$
- Lineární regresní model:  $Y = \beta_0 + \beta_1 \cdot X + E$  ... rovnice přímky
- Modelem vysvětlujeme variabilitu v hodnotách  $Y$ , prokazujeme závislost  $Y$  na  $X$  nebo předpovídáme střední hodnotu  $Y$  pro nové hodnoty  $X$ .
- V interpretaci zohledňujeme logickou závislost proměnných, „co ovlivňuje co“.

Příklad: váha mozku vysvětlovaná váhou celého těla u 54 vybraných savců



## Lineární regresní model [simple linear regression, bivariate regression]

$$Y_i = \underbrace{\beta_0 + \beta_1 \cdot X_i}_{\text{systematická složka}} + \underbrace{E_i}_{\text{náhodná složka modelu}} \quad E_i \sim N(0, \sigma^2)$$

systematická složka + náhodná složka modelu [deterministic + stochastic component]

- $Y$  nazýváme vysvětlovaná proměnná, závislá proměnná, odpověď, odezva [explained variable, dependent variable, response]
- $X$  nazýváme vysvětlující proměnná, nezávislá proměnná, prediktor, regresor [explanatory variable, independent variable, predictor]
- $E_i \sim N(0, \sigma^2)$  náhodná chyba, přirozená variabilita
- $\beta_0$  a  $\beta_1$  jsou parametry platné pro celou populaci, tedy neznámé  
→ hledáme odhady  $b_0$  a  $b_1$  a testujeme jejich nenulovost
- Parametry  $\beta_0$  a  $\beta_1$  určují přímku závislosti:  
 $\beta_0$  je průsečík s osou  $y$  [intercept],  
 když  $X = 0$ , potom  $Y = \beta_0$   
 $\beta_1$  je sklon přímky [slope];  
 když  $X$  zvětším o 1 jednotku  
 potom  $Y$  naroste (v průměru) o  $\beta_1$ .

## Odhad regresních koeficientů: $\beta_0, \beta_1, \sigma^2$

$$Y_i = \beta_0 + \beta_1 \cdot X_i + E_i \quad E_i \sim N(0, \sigma^2)$$

1) Odhady  $b_0$  a  $b_1$  hledáme **metodou nejmenších čtverců**

[method of the least squares]

→ „nafitovaná“ hodnota:

$$\hat{Y}_i = b_0 + b_1 \cdot X_i$$

[fitted value], česky lépe  
modelovaná, vyhlazená hodnota

→ Reziduum  $U_i$ :


$$U_i = Y_i - \hat{Y}_i = Y_i - b_0 + b_1 \cdot X_i$$

→ Součet čtverců (reziduální):

$$SS_E = \sum_{i=1}^n U_i^2 = \sum(Y_i - \hat{Y}_i)^2 = \sum(Y_i - b_0 + \beta_1 \cdot X_i)^2 \dots \text{aby byl minimální}$$

$$\rightarrow b_1 = \frac{S_{XY}}{S_X^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

$$\rightarrow b_0 = \bar{Y} - b_1 \cdot \bar{X}$$



## Odhad regresních koeficientů: $\sigma^2$

$$Y_i = \beta_0 + \beta_1 \cdot X_i + E_i \quad E_i \sim N(0, \sigma^2)$$

2) Variabilitu náhodné odchylky  $\sigma^2$  odhadujeme jako reziduální rozptyl, tj.

$$S^2 = \frac{SS_E}{n - 2}$$

## Rozklad variability modelu (podobně jako v analýze rozptylu)

$$SS_{TOT} = \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad \dots \text{celková variabilita v datech}$$

$$DF_{TOT} = n - 1$$

$$SS_{REG} = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \quad \dots \text{regresní, modelová variabilita, variabilita vysvětlená modelem}$$

$$DF_{REG} = k \quad k \dots \text{počet vysvětlujících proměnných}$$

$$SS_E = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad \dots \text{reziduální variabilita, variabilita modelem nevysvětlená}$$

$$DF_E = n - k - 1$$

**Platí:**  $SS_{TOT} = SS_{REG} + SS_E$

## Předpoklady regresního lineárního modelu:

$$Y_i = \beta_0 + \beta_1 \cdot X_i + E_i \quad E_i \sim N(0, \sigma^2) \quad Y_i \sim N(\underline{\beta_0 + \beta_1 \cdot X_i}, \sigma^2)$$

- $Y_i$  jsou vzájemně nezávislé hodnoty, pozorování.
- $Y_i$  jsou zatíženy náhodnou variabilitou, pro kterou předpokládáme normální rozdělení: nelze ověřit předem, protože se střední hodnota  $EY$  mění a my teprve hledáme funkci, která tuto změnu popisuje. Proto nejprve modelujeme a potom ověřujeme. Normalitu zkонтrolujeme na reziduálech  $(Y_i - \hat{Y}_i)$ . Předobrazem reziduálů v modelu jsou členy  $E_i$ .
- Pro  $E_i$  předpokládáme  $N(0, \sigma^2)$  a že  $\sigma^2$  se nemění.
- $X_i$  naopak považujeme za přesné hodnoty bez náhodné chyby (variability). To splňují např. laboratorní teploty v různých pokusných boxech. Naopak váha těla savců z příkladu má jistě svoji variabilitu, předpoklad není dodržen.
- $EY$  je lineární funkcí hodnot  $X_i$  (viz dále)

## Předpoklady regresního lineárního modelu:

$$Y_i = \beta_0 + \beta_1 \cdot X_i + E_i \quad E_i \sim N(0, \sigma^2) \quad Y_i \sim N(\beta_0 + \beta_1 \cdot X_i, \sigma^2)$$

- $EY$  je lineární funkcí hodnot  $X_i$ . Nesplnění tohoto předpokladu znamená, že bud' závislost není čistě lineární nebo  $EY$  závisí ještě na další proměnné, např.  $V$ . Výrazně zakřivené vztahy vidím většinou hned na bodovém grafu. Potom mohu zvolit např. kvadratickou regresi (viz příklad „kořeny“) či proměnné transformovat (příklad „mozky“). Odhalení druhého případu je složitější, zvlášť když nemám další proměnné k dispozici. Popisuje ho příklad „tuk“.
- Špatně zvolený model dává vychýlený odhad středních hodnot  $EY$ . Projevilo by se to například v používání modelu v praxi, kdy by předpovídané průměry a naměřené průměry byly systematicky vzájemně posunuté, vychýlené.
- Předpokládaný lineární vztah dobře funguje, když  $X$  i  $Y$ , respektive jejich reziduály, mají normální rozdělení. Pokud normalita chybí, pomůžeme si transformací. Normalita  $X$  a  $Y$  ale není předpokladem regresního modelu.

## Testy regresních koeficientů, prokazování závislosti $Y$ na $X$

$$Y_i = \beta_0 + \beta_1 \cdot X_i + E_i \quad E_i \sim N(0, \sigma^2)$$

- Modelujeme závislost  $EY$  na  $X$  jako  $EY = \beta_0 + \beta_1 \cdot X$
- Hodnotu  $\beta_0$  testujeme zřídka, protože hypotéza většinou nemá biologicky rozumnou interpretaci.
- Nezávislost  $EY$  na  $X$  znamená, že  $\beta_1 = 0$ .
- Hypotézu  $H_0: \beta_1 = 0$  testujeme pomocí statistiky

$$T = \frac{\hat{\beta}_1 - 0}{S.E.(\hat{\beta}_1)} \sim_{H_0} t_{n-2}$$

Toto je jeden z hlavních výsledků regresní analýzy. Pokud  $p$ -hodnota <  $\alpha$ , zamítám hypotézu o nezávislosti, tedy závislost  $Y$  na  $X$  je průkazná.

Např.: > `summary(lm(syn~otec))`

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	88.01687	11.49887	7.654	1.36e-12	***
otec	0.50096	0.06548	7.651	1.39e-12	***

→ syn = 88.02 + 0.50\*otec

## Koeficient determinace $R^2$

$$R^2 = \frac{SS_{REG}}{SS_{TOT}} = 1 - \frac{SS_E}{SS_{TOT}}$$

- $R^2 \in \langle 0,1 \rangle$
- Interpretujeme jako podíl vysvětlené variability vzhledem k celkové variabilitě v datech  $Y$
- Bezrozměrný koeficient, často vyjádřený v procentech
- Koeficient ukazuje, jestli má model smysl, jestli vysvětlí nějaký podstatný díl variability.
- Pro lineární regresi platí  $R^2 = r_{XY}^2$  (Pearsonův korelační koeficient ^2)

Poznámka:  $R^2$  se může velmi měnit s množinou zahrnutých pozorování. Odlehlelé pozorování může hodnotu  $R^2$  i zdvojnásobit prostě proto, že má velký reziduální čtverec, kterým zvětší jak reziduální průměrný čtverec, tak regresní (modelový) průměrný čtverec. Naše radost nad množstvím vysvětlené variability pak může být vrátká a krátká ...

## Test celého modelu jednoduché lineární regrese

Např.: > **anova(lm(syn~otec))**

Analysis of Variance Table

Response: syn

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
otec	1	1800.7	1800.69	58.532	1.392e-12 ***
Residuals	171	5260.7	30.76		

Efekt	Analýza rozptylu (Galton v CV_10_data_KoreRegr)				
	Součet čtverců	sv	Průměr čtverců	F	p-hodn.
Regres.	1800,689	1	1800,689	58,53171	0,000000
Rezid.	5260,702	171	30,764		
Celk.	7061,391				

$H_0$ : model vysvětlí jen nevýznamný díl variability


$$F = \frac{\frac{SS_{REG}}{1}}{\frac{SS_E}{n-2}} \sim F_{1,n-2}$$

Porovnáváme s kvantilem

$$F_{1,n-2}^{-1} \left( 1 - \frac{\alpha}{2} \right), \text{ zde } \alpha = 5.11$$

- Tabulka analýzy rozptylu: porovnávám variabilitu vysvětlenou pomocí proměnné  $X$  (výška otce) s variabilitou reziduální, která zbyde po aplikaci modelu.
- F-statistika vypovídá o významnosti té části variability  $Y$ , kterou lze vysvětlit modelem (STAT) nebo přidáním další vysvětlující proměnné (R, rozdíl později).
- V případě jednoduché lineární regrese s jednou nezávislou proměnnou je  $p$ -hodnota F-testu analýzy rozptylu shodná s  $p$ -hodnotou t-testu nenulovosti koeficientu  $b_1$ . To je proto, že v tomto nejjednodušším případě platí  $F = T^2 \sim F_{1,n-2}$

## Konfidenční interval pro celou regresní přímku



## Model lineární regrese a příčinná závislost

Ideálně  $Y$  logicky závisí na  $X$ .

Je-li vztah závislosti nejasný a obě proměnné jsou zatíženy náhodnou chybou, studujeme spíše korelací proměnných.

V praxi používáme regresi i ve sporných případech, kdy kauzální vztah není jasný. Přesto nás zajímá rovnice, která vztah obou proměnných (v daném uspořádání) popisuje. Mluvíme pak spíše o vysvětlované a vysvětlující proměnné a signifikantní model považujeme jen za nepřímý „důkaz“ příčinné závislosti  $Y$  na  $X$ .

Statistickými prostředky nelze dokazovat příčinné závislosti (kauzalitu)! To umíme dělat jen manipulativními experimenty, kdy jsme schopni měnit hodnoty jen jedné proměnné, zatímco ostatní uvažované proměnné udržujeme na stálé úrovni.

Interpretace i predikce modelu je založena především na zkoumaném rozsahu hodnot vysvětlující proměnné. Se změnou rozsahu často narazíme na nelinearitu (v přírodě spíše běžnou) a náš model přestává platit.

# Ověřování předpokladů – regresní diagnostika [regression diagnostics]

STAT:

Výsledky - vícenásobná regrese: Galton v CV\_10\_data\_KoreRegr

?

X

Výsledky- vícerozm. regrese

Záv.prom. :syn                        vícenás. R = ,55683652                F = 38,20035  
     R2= ,31006691                    sv = 2,170  
     Poč. případů: 173                        upravené R2= ,30195006                p = ,000000  
     Směrodatná chyba odhadu : 5,353331739  
     Abs.člen: 52,120543012                Sm. chyba: 14,76977            t( 170) = 3,5289        p = ,0005

otec b\*=,478                        matka b\*=,236

(významná b\* jsou zvýrazněna červeně)

Alfa pro zvýraznění efektů: .05

Základní výsledky | Detailní výsledky | Residua/předpoklady/předpovědi | **Residua/předpoklady/předpovědi**

**Reziduální analýza**

Předpovědi

Předpověď závislé proměnné

Výpočet interv. spolehlivosti                Alfa: .05  
 Výpočet interv. předpovědi

OK

Storno

Možnosti ▾

Anal.Skup.

## Ověřování předpokladů – diagnostické grafy


STAT:

A screenshot of a statistical software window titled "STAT:". At the top, there is a text box containing statistical output: "Abs. člen: 52,120543012 Sm. chyba: 14,76977 t( 170) = 3,5289 p < ,0005". Below this is a navigation bar with tabs: "Základ" (highlighted with a red arrow), "Detailly", "Rezidua", "Předpovědi", "Bodové grafy", "Pravděp. grafy", "Odlehle hodnoty", and "Uložit". To the right of the tabs are buttons for "Výpočet" (with a dropdown menu), "Storno", and "Možnosti". In the center, there are two buttons: "Výpočet Rezidua & předpovědi" and "Normální p-graf reziduí".

- **Histogram reziduů (normalita):** záložka *Rezidua*
- **Q-Q plot reziduů (normalita):** Základ nebo *Pravděpodobnostní grafy*
- **Rezidua vs. Předpovědi (stejnost rozptylu):** *Bodové grafy*. Tento graf má odhalit závislost rozptylu  $\sigma^2$  na (předpovídáné) střední hodnotě  $Y$ . Správně mají být body rozložené stejnoměrně podle vodorovné osy.
- **Rezidua vs. Nezávislé proměnné (stejnost rozptylu):** *Rezidua*. V této kombinaci zkoumáme případnou závislost rozptylu  $\sigma^2$  na jednotlivých vysvětlujících proměnných. Správně jsou body rozložené stejnoměrně podle vodorovné osy.

## Ověřování předpokladů – diagnostické grafy


STAT:



- **Korelace mezi po sobě jdoucími reziduály [autocorrelation] (nezávislost mezi  $Y_i$ ):** *Detaily. Durbin-Watsonova statistika.* Výsledek nazvaný *Sériové korelace* udává korelací bodů daných souřadnicemi  $[U_i, U_{i+1}]$ . Vychází z úvahy, že závislá pozorování  $Y_i$  a  $Y_{i+1}$  budou mít podobnou odchylku od průměru. Například sourozenci budou mít podobně vychýlenou výšku. Nebo dotazník vyplněný stejným člověkem bude mít podobné odpovědi. To může fungovat za předpokladu, že pozorování v tabulce jsou zapsána tak, jak byla získána v „terénu“. Pokud by takto závislých pozorování bylo v datech hodně, byla by *Sériová korelace* výrazně odlišná od nuly.

## Ověřování předpokladů – diagnostické grafy a statistiky

STAT:



- **Mahalanobisova vzdálenost (odlehlá pozorování [outlier]):** *Odlehlé hodnoty.* *Typ odlehlých hodnot:* zvolit. Počítá prostorovou vzdálenost pozorování od centroidu (těžiště) vysvětlujících proměnných, upravenou pro korelované proměně. Výstupní tabulka je uspořádána od největších odchylek po nejmenší, takže potenciálně problematická, odlehlá pozorování jsou na prvních řádcích.
- **Cookova vzdálenost (příliš vlivná pozorování [leverage case]):** *Odlehlé hodnoty.* *Typ odlehlých hodnot:* zvolit. Pro každé pozorování spočte rozdíl v odhadu regresních koeficientů v modelu *s a bez* daného řádku (pozorování). Pokud je rozdíl velký, je jasné, že dané pozorování podstatně ovlivňuje směr regresní přímky, tedy celého modelu. Opět, nejvlivnější pozorování jsou na prvních řádcích.


## Ověřování předpokladů – regresní diagnostika

R: `model <- lm(Y~X)`


`model$residuals` ... s tímto vektorem pak tvořím histogramy a Q-Q diagramy  
`plot(model)` ... 6 předchystaných grafů, předvolba tiskne 1., 2., 3. a 5. graf.

### Rezidua vs. Předpovědi (stejnost rozptylu):

Tento graf má odhalit závislost rozptylu  $\sigma^2$  na (předpovídáné) střední hodnotě  $Y$ . Správně mají být body rozložené stejnomořně podle vodorovné osy.



### Q-Q plot reziduů (normalita):



## Ověřování předpokladů – regresní diagnostika

R: `plot(model)`

### Odmocněná Rezidua vs. Předpovědi

(stejnost rozptylu, normalita).



Při porušení předpokladu vykazují body

Nějaký druh závislosti (lineární či nelineární).

### Cookova vzdálenost (příliš vlivná pozorování)

Pro každé pozorování spočte rozdíl v odhadu regresních koeficientů v modelu **s** a **bez** daného řádku (pozorování). Pokud je rozdíl velký, je jasné, že dané pozorování podstatně ovlivňuje směr regresní přímky, tedy celého modelu.

[lever = páka; leverage = vliv páky, páčení]



## Ověřování předpokladů – regresní diagnostika

R: **Rezidua vs. Nezávislé proměnné:** ilustruje případnou závislost rozptylu na hodnotách vysvětlujících, nezávislých proměnných.

V Rku možnost **Breuschova-Paganova testu** (knihovna **lmtest**)

> **bptest**(model, varformula=~ ..., data = ...)

## Mnohonásobná lineární regrese [multiple linear regression]

Poznámka: Něco jiného je mnohorozměrná regrese [multidimensional regression], ve které modeluji více závislých proměnných pomocí více nezávislých proměnných.

Model:  $Y_i = \beta_0 + \beta_1 \cdot X_i + \beta_2 \cdot V_i + \beta_3 \cdot W_i + E_i \quad k = 3, \quad E_i \sim N(\mathbf{0}, \sigma^2)$

Jiný zápis:  $Y_i = \beta_0 + \beta_1 \cdot X_{1i} + \beta_2 \cdot X_{2i} + \beta_3 \cdot X_{3i} + E_i$

Hodnoty vysvětlujících  
proměnných se pak dají  
zapsat jako matice:  $X = \begin{pmatrix} X_{11} & X_{21} & X_{31} \\ X_{12} & X_{22} & X_{32} \\ \vdots & \vdots & \vdots \\ X_{1n} & X_{2n} & X_{3n} \end{pmatrix}$

Odhad rozptylu  $\sigma^2$ :  $S^2 = \frac{SS_E}{n-k-1}$  Počet pozorování – počet regresorů – 1

Výsledky: odhady regresních koeficientů  $b_0, b_1, b_2, b_3$ ;  $R^2, F$  – test modelu

Interpretace  $b_j$ : o kolik vzroste (klesne) hodnota  $Y$ , když  $X_j$  vzroste o jednotku a ostatní vysvětlující proměnné se nezmění.

## Mnohonásobná lineární regrese

Model:  $Y_i = \beta_0 + \beta_1 \cdot X_{1i} + \beta_2 \cdot X_{2i} + \beta_3 \cdot X_{3i} + E_i \quad k = 3, \quad E_i \sim N(\mathbf{0}, \sigma^2)$

Hodnocení regresních koeficientů:

Hypotéza  $H_0: \beta_j = 0 \rightarrow T = \frac{b_j - 0}{S.E.(b_j)} \sim_{H_0} t_{n-k-1}$  → znamená to, že proměnná  $X_j$

nepřidá do modelu novou informaci o střední hodnotě  $Y$ , nic významně nového nevysvětlí.

Konfidenční interval  $\beta_j$ :

$$(b_j - S.E.(b_j) \cdot t_{n-k-1}(1 - \alpha/2), b_j + S.E.(b_j) \cdot t_{n-k-1}(1 - \alpha/2))$$

Porovnání vlivu regresorů na  $Y$  mezi sebou

→ přepočítám na standardizovaný tvar:  $b_j^* = b_j \cdot \frac{sd(X_j)}{sd(Y)}$

Příklad: % tuku ~ výška + váha.  $b_{VYSKA}^* = -0.254, b_{VAHA}^* = 0.968$

Mohu říci, že váha má zhruba 4-krát větší vliv na výsledné % tuku než výška.

# Příklady