

PSY252

Statistická analýza dat v psychologii II

**Seminář 3**

---

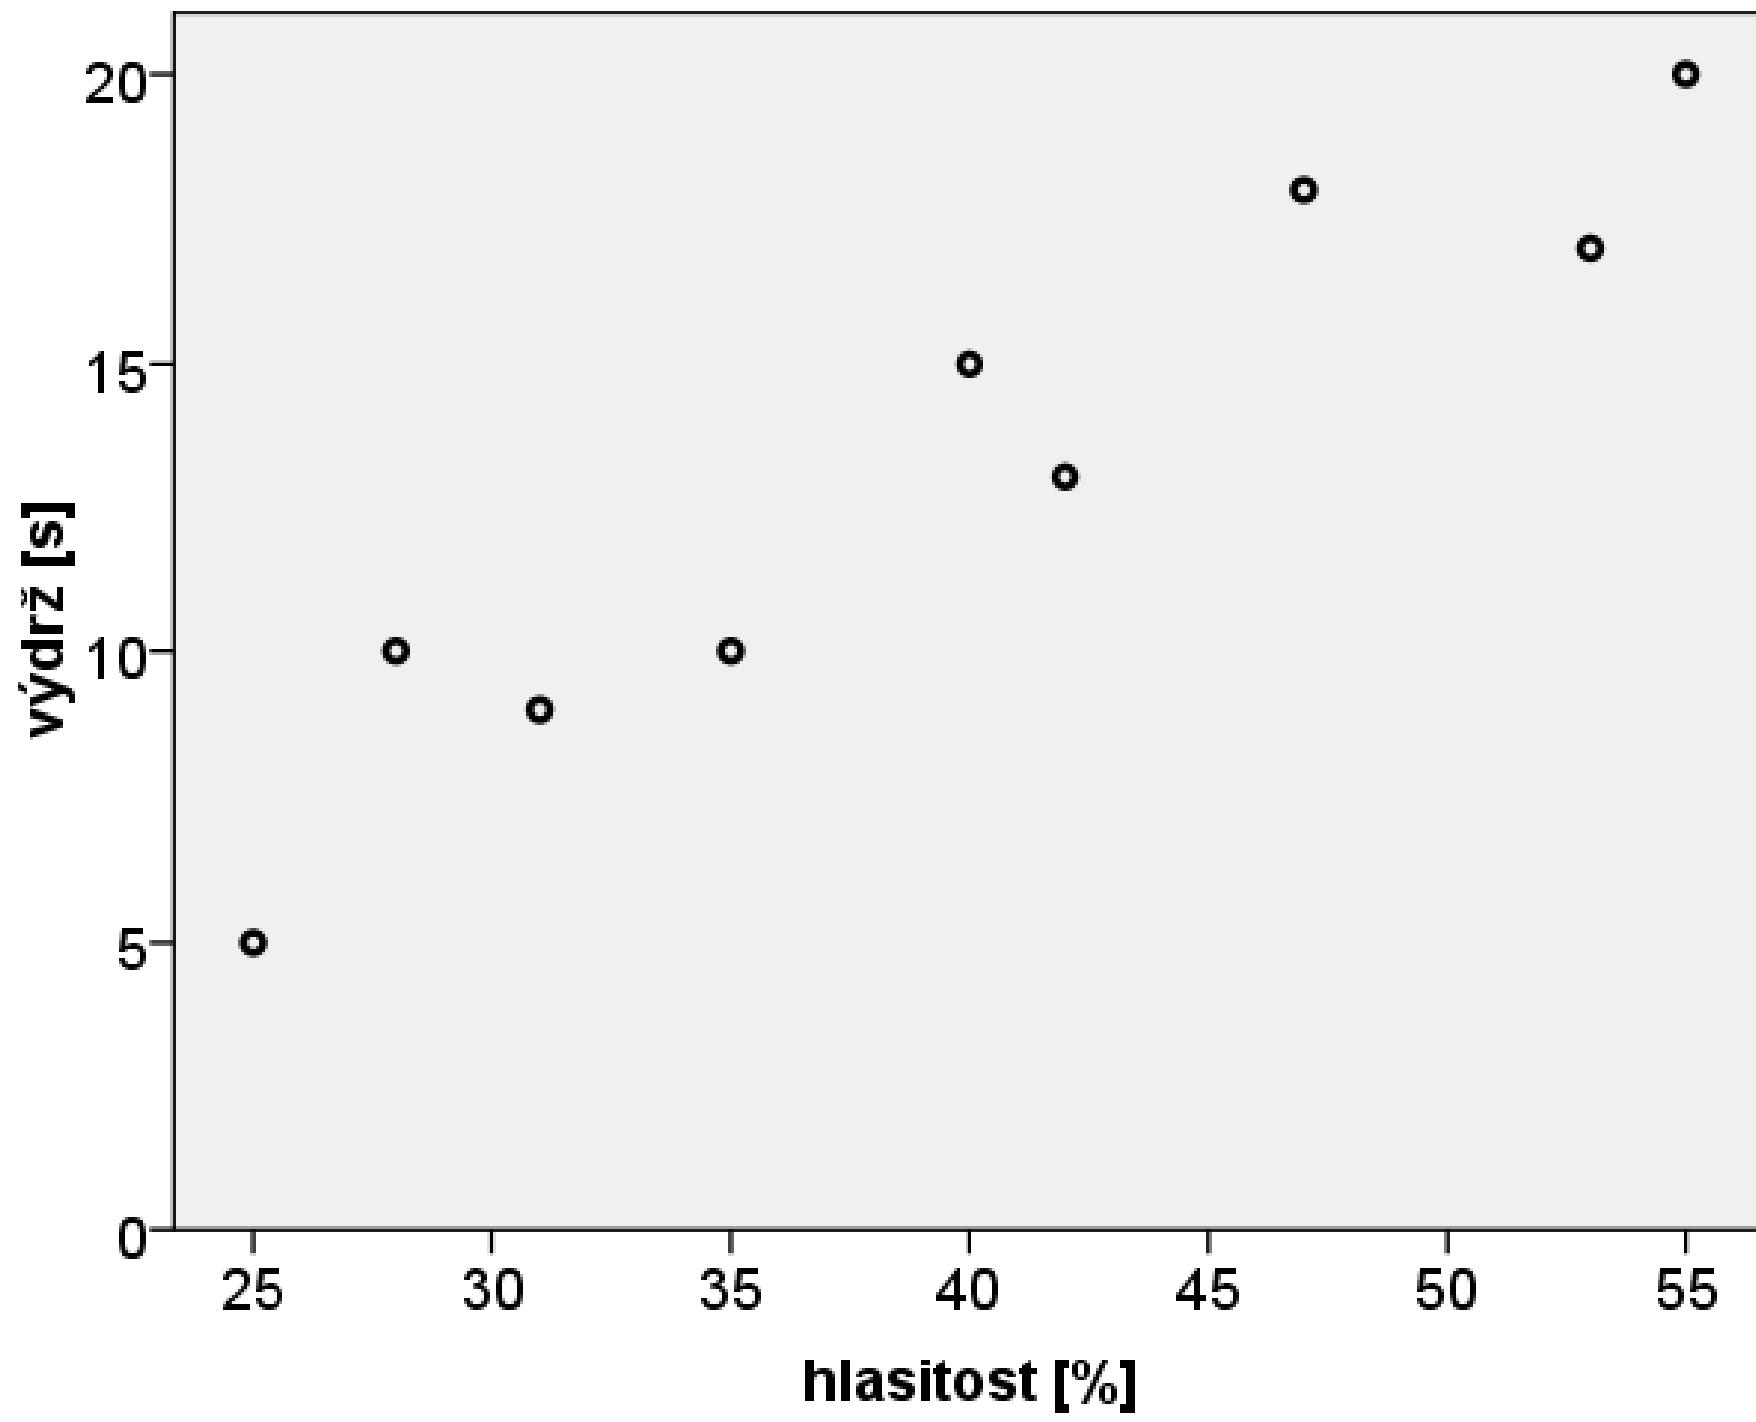
{*Mnohonásobná, vícenásobná*} **lineární regrese**  
**Multiple linear regression**

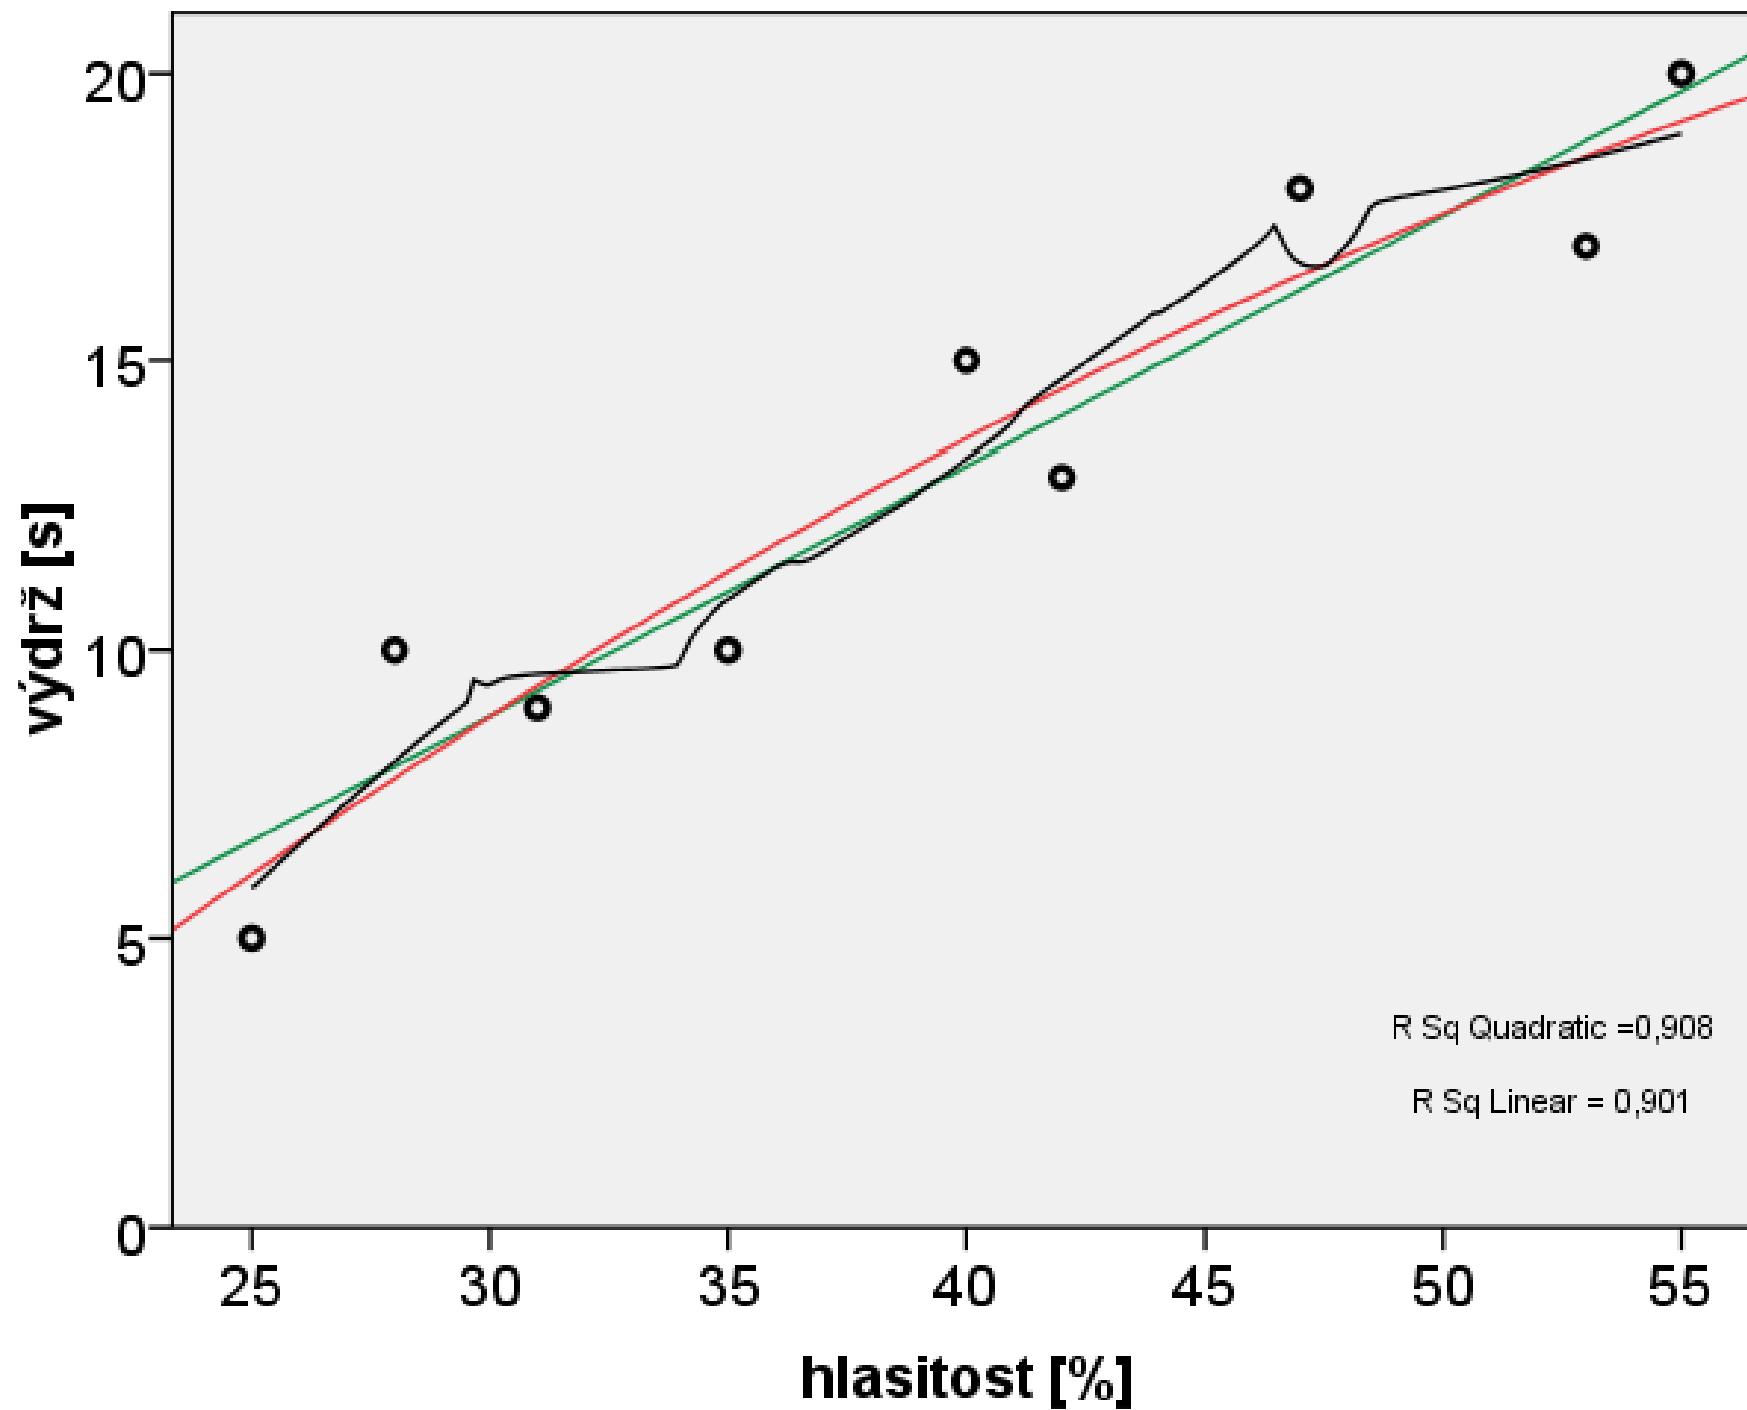
# Dhodobá adaptace sluchu

---

Lidé, kteří poslouchají osobní přehrávač na vysokou **hlasitost** [% z maxima přehrávače], **vydrží** nepříjemný hlasitý zvuk déle?

hlasitost [%]	výdrž [s]
25	5
31	9
55	20
42	13
47	18
53	17
40	15
35	10
28	10





# Lineární regrese I. - MODEL

Je-li Pearsonova korelace dobrým popisem vztahu mezi dvěma proměnnými,  
lze popsat vztah mezi nimi lineární funkcí

$$Y' = a + bX$$

$b$  – směrnice

$a$  – průsečík

$$Y = Y' + e$$

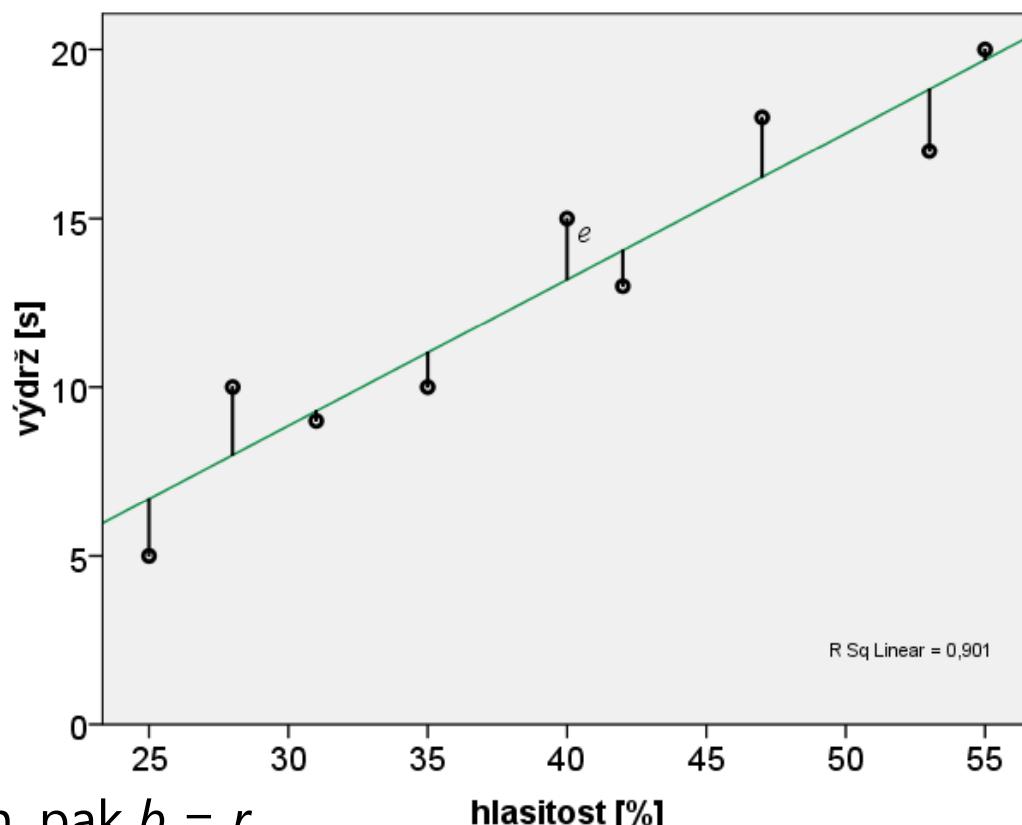
$$Y = a + bX + e$$

Odhad metodou  
nejmenších čtverců

$$b = r_{xy}(s_y/s_x)$$

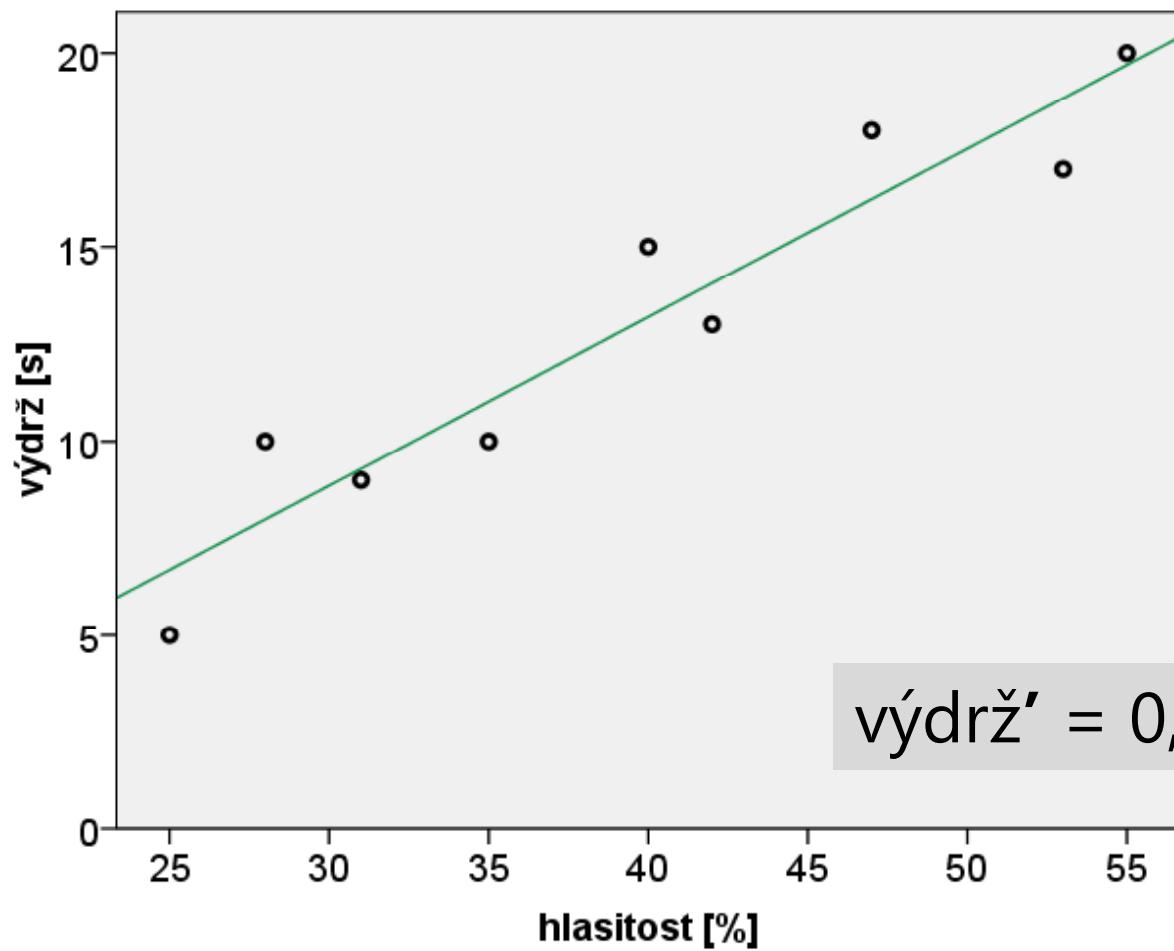
$$a = m_y - bm_x$$

Jsou-li  $X$  a  $Y$  vyjádřeny v z-skórech, pak  $b = r_{xy}$



AJ: slope, intercept, least squares (estimation), regression coefficients (a,b)

# Lineární regrese II. – příklad



$$m_h = 39,6$$

$$s_h = 10,7$$

$$m_v = 13,0$$

$$s_v = 4,9$$

$$r = 0,95$$

# Predikované hodnoty a rezidua

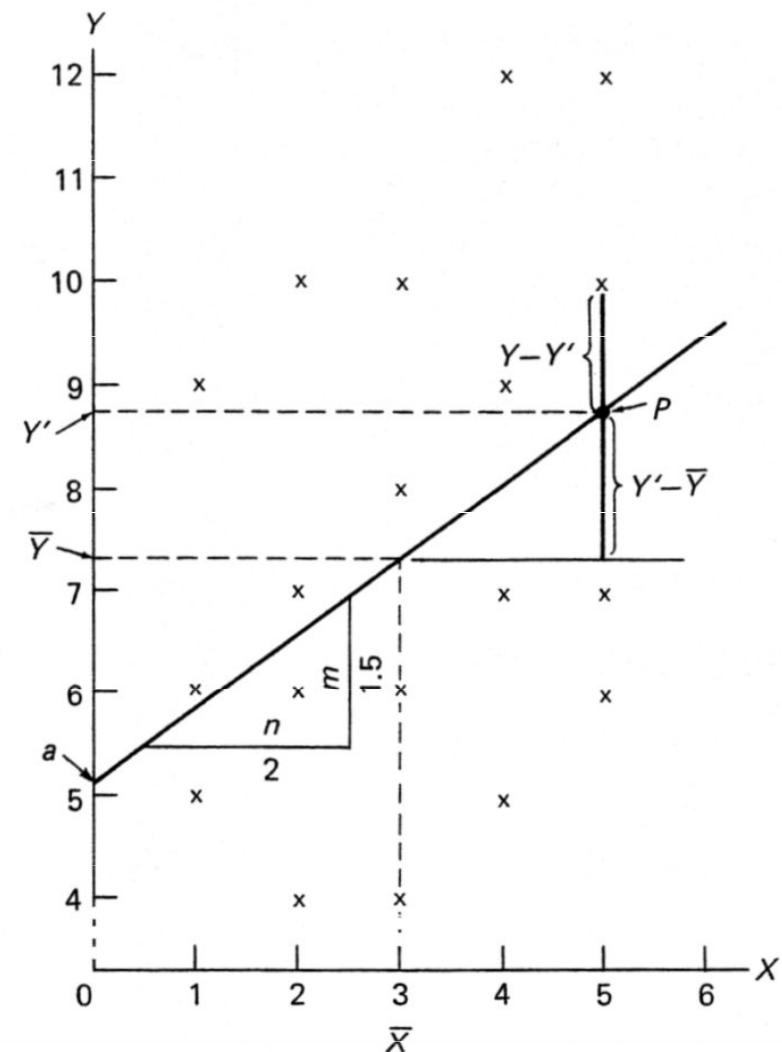
hlasitost [%]	výdrž [s]	výdrž' [s]	reziduum [s]
25	5	6,69	-1,69
31	9	9,29	-0,29
55	20	19,70	0,30
42	13	14,06	-1,06
47	18	16,23	1,77
53	17	18,83	-1,83
40	15	13,19	1,81
35	10	11,02	-1,02
28	10	7,99	2,01

# Lineární regrese III. – úspěšnost predikce

$$s_{reg}^2 = \frac{\sum (m_y - Y')^2}{n-1} \quad s_{res}^2 = \frac{\sum (Y - Y')^2}{n-1}$$

$$s_y^2 = \frac{\sum (Y - m_y)^2}{n-1}$$

- $s_y^2 = s_{reg}^2 + s_{res}^2 \quad (ss_y = ss_{res} + ss_{reg})$
- $R^2 = s_{reg}^2 / s_y^2$
- Koeficient determinace ( $R^2$ )
  - Podíl rozptylu vysvětleného modelem
  - Je ukazatelem kvality, úspěšnosti regrese
  - Vyjadřuje shodu modelu s daty
- Pro jednoduchou lin. regr. platí  $R^2 = r^2$

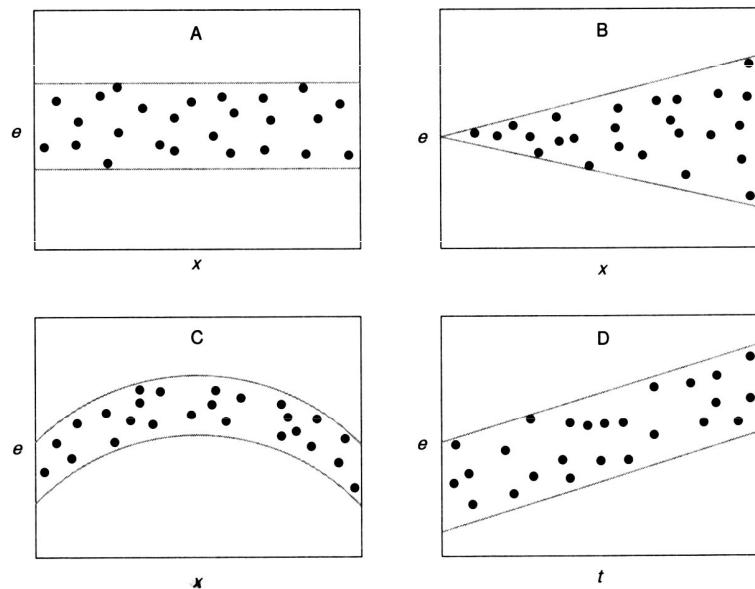


AJ: regression and residual variance (sum of squares), explained variance, **model fit with the data**, coefficient of determination (R square)

# Lineární regrese IV. – předpoklady, platnost

Předpoklady oprávněnosti použití lineárního modelu

- jako u Pearsonovy korelace
- konceptuální předpoklad: vztah je ve skutečnosti lineární
- rezidua mají normální rozložení s průměrem 0
- homoskedascita
  - =rozptyl reziduí (chyb odhadu) se s rostoucím  $X$  nemění



- Platnost modelu je omezena daty, z nichž byl získán, a teorii.
  - Extrapolace, neoprávněná extrapolace (≈jako generalizace nad rámec empirických dat)
  - Pozor na odlehlé hodnoty – jako u všech ostatních momentových statistik

# Mnohonásobná lineární regrese

---

- Počet prediktorů není omezen
  - $$Y = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_m X_m + e$$
- Problémy plynoucí z většího množství prediktorů
  - Výpočetní komplikace
  - Korelace mezi prediktory komplikují interpretaci – (multi)kolinearita
  - Otázka „pořadí“ prediktorů
  - Možnost a problémy porovnávání prediktorů mezi sebou
    - $b_i$  vyjadřuje nárůst  $Y$  při nárůstu  $X_i$  o jednu jednotku; v jednotkách  $Y$
    - $\beta_i$  vyjadřuje nárůst  $Y$  při nárůstu  $X_i$  o 1; jsou-li  $X_i$  i  $Y$  standardizovány
    - K porovnání prediktorů mezi sebou v rámci regrese slouží  $\beta_i$
    - K porovnání síly prediktoru v různých skupinách slouží  $b_i$

# Hrátky s prediktory

---

Prediktory lze do modelu vložit všechny najednou, jednotlivě, nebo po skupinkách

Porovnáváme tak vlastně mnoho modelů lišících se zahrnutými prediktory.

- Vše najednou = ENTER
  - Postupně po jednom = FORWARD
  - Vše a postupně ubírat = BACKWARD
  - Po blocích, clockwise = ENTER + další blok
-

# Diagnostika 1: Outliery a vlivné případy

---

Nemají některé případy příliš velký vliv na výsledky regrese?

- Outliery – mohou zvyšovat i snižovat  $b$ 
    - **Rezidua** – případy s vysokými r. regrese predikuje nejhůř, standardizovaná, studentizovaná  $\pm 3$
    - **Vlivné případy** – případy, které nejvíce ovlivňují parametry
      - Co se stane s parametry regrese, když případ odstraníme?
      - DFBeta – rozdíl mezi parametrem s a bez, standardizované  $> 1$
      - DFFit – rozdíl mezi predikovanou hodnotou a predikovanou hodnotou bez případu (adjustovanou)
      - Cookova vzdálenost  $> 1$
      - Leverage  $> 2(k+1)/n$ , kde  $k$  = počet prediktorů,  $n$  = velikost vzorku
  - Případy s vysokými rezidui či vlivné případy **NEODSTRAŇUJEME**
    - ...leda by šlo o zjevnou chybu v datech či vzorku
-

# Daignostika 2: Kolinearita

---

- Když 2 prediktory vysvětlují tutéž část variability závislé, jeden z nich je téměř zbytečný
  - Komplikuje porovnávání síly preditorů
  - Snižuje stabilitu odhadu parametrů
  - V extrému (když lze jeden prediktor přesně vypočítat z ostatních) regresi úplně znemožňuje
- 
- Korelace nad 0,9
  - VIF (= 1/tolerance) cca nad 10
-

# Diagnostika 3: Předpoklady regrese

---

- Závislá alespoň intervalová
  - Prediktory intervalové i kategorické
  - Nenulový rozptyl prediktorů
  - Absence vysoké kolinearity (žádné  $r > 09$ )
  - Neexistence intervenující proměnné, která by korelovala se závislou i prediktory
  - Homoscedascita (scatterplot ZRESID x ZPRED, parciální scatter)
  - Nezávislost reziduí (Durbin-Watson = 2)
  - Normálně rozložená rezidua (histogram, P-P)
  - Nezávislost jednotlivých případů
  - Linearita vztahu
-

# Síla testu v regresi (Hair, 7th ed.)

Přibývá nový faktor síly testu: **množství prediktorů**

**TABLE 5 Minimum  $R^2$  That Can Be Found Statistically Significant with a Power of .80 for Varying Numbers of Independent Variables and Sample Sizes**

Sample Size	Significance Level ( $\alpha$ ) = .01 No. of Independent Variables				Significance Level ( $\alpha$ ) = .05 No. of Independent Variables			
	2	5	10	20	2	5	10	20
20	45	56	71	NA	39	48	64	NA
50	23	29	36	49	19	23	29	42
100	13	16	20	26	10	12	15	21
250	5	7	8	11	4	5	6	8
500	3	3	4	6	3	4	5	9
1,000	1	2	2	3	1	1	2	2

*Note: Values represent percentage of variance explained.*

*NA = not applicable.*

# Zapojení kategorických prediktorů

---

Dummy coding -> dummy variables

- Pomocí  $k-1$  kategorických proměnných
- Indikátorové kódování (indicator coding)
  - Referenční kategorie = 0
- Efektové kódování (effect coding)
  - Referenční kategorie = -1

Člen rodiny	Původní proměnná	Indikátorové kódování		Efektové kódování	
		Matka	Otec	Matka	Otec
Matka	1	1	0	1	0
Otec	2	0	1	0	1
Dítě	3	0	0	-1	-1

# Interpretace vah dummy proměnných

---

- $Y = b_0 + b_{A1}X_{A1} + b_{A2}X_{A2} + \dots + b_mX_m + e$
- Po dosazení do regresní rovnice predikujeme člověku průměr jeho skupiny (pokud nejsou žádné další prediktory).
- Indikátorové kódování
  - $b_{Ai}$  udává rozdíl průměrných hodnot  $Y$  mezi indikovanou skupinou a referenční skupinou; sig  $b_{Ai}$  znamená sig rozdílu
  - $b_{Ai}$  udává o kolik nám členství ve skupině zvyšuje/snižuje predikovanou hodnotu oproti referenční skupině
  - $b_0$  udává (při absenci jiných prediktorů) průměr  $Y$  v referenční skupině
- Efektové kódování
  - $b_{Ai}$  udává rozdíl průměrných hodnot  $Y$  mezi indikovanou skupinou a celkovým průměrem
  - $b_0$  udává (při absenci jiných prediktorů) celkový průměr

- záv: deprese
- pred: selfe, effi3, duv\_r, duv\_v