

PSY252

Statistická analýza dat v psychologii II

**Přednáška 2**

---


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


# Dlouhodobá 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

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


$$a = m_y - b m_x$$

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



$$m_h = 39,6$$

$$s_h = 10,7$$

$$m_v = 13,0$$

$$s_v = 4,9$$

$$r = 0,95$$



# Novinky oproti PSY117

---

- Regr. koeficienty jsou  $b_0$  (průsečík, *a*, (*constant*)) a  $b_1$  (směrnice, *b*)
  - **Beta** – standardizovaný regresní koeficient.
    - O kolik víc násobku SD proměnné Y predikujeme člověku, který má o 1SD proměnné X víc. S jedním prediktorem =  $r$ .
  - Testy jednotlivých regresních koeficientů.
    - Testují  $H_0: b_k = 0$ .      ( $t = b / SE_b$ , *t*-rozložení s  $df = N - k - 1$ , )
-

# *Diagnostika modelu*

## 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)

# Novinky oproti PSY117


---

- Adjusted  $R^2$  – jak velké  $R^2$  bychom čekali, kdybychom analýzu dělali na celé populaci (ne vzorku). Overfitting.
- ANOVA – test  $H_0: R^2=0$ .
- Standard error of the estimate -  $s_{\text{res}}$

# 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 teorií.
  - Extrapolace, neoprávněná extrapolace (≈jako generalizace nad rámec empirických dat)
  - Pozor na odlehlé hodnoty – jako u všech ostatních momentových statistik

# Mnohonásobná lineární regrese

---

## K čemu je?

- Jak moc přispívá proměnná X k predikci jevu Y?
    - Inkrementální validita
  - Liší se muži a ženy v proměnné Y, i když zohledníme intervenující proměnnou Z?
    - Statistická kontrola
  - Je měřítko A lepším prediktorem než B? (lépe pomocí  $r$ )
-

# Mnohonásobná lineární regrese

---

- Počet prediktorů není teoreticky omezen
  - $$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_mX_m + e$$
- Problémy plynoucí z většího množství prediktorů
  - Výpočetní komplikace
  - Korelace mezi prediktory komplikují interpretaci – (multi)kolinearita
  - Otázka „pořadí“ prediktorů
  - Možnost neintuitivních výsledků – př. suprese
  - Více příležitostí k rybaření
  - Méně příležitostí si uvědomit omezenost modelu
  - Množství dat více motivuje k přeskočením detailního se seznamování s daty a prozkoumávání naplnění předpokladů

# Příklad Long1

---

- záv: deprese
  - pred: selfe, effi, duv\_r, duv\_v
  - Celý soubor
-

# MLR: Interpretace regresních koeficientů

---

$$Y = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_m X_m + e$$

- **$B_i$ ;  $b_i$**  vyjadřuje nárůst  $Y'$  při nárůstu  $X_i$  o jednu jednotku; v jednotkách  $Y$ , při kontrole všech ostatních prediktorů ( $\approx$  semiparciální korelace); jedinečný přínos
    - K porovnání síly prediktoru v různých skupinách, modelech, vzorcích
  - **$\beta_i$ ;  $b_i^*$ ;  $BETA$**  vyjadřuje nárůst  $Y'$  při nárůstu  $X_i$  o 1; jsou-li  $X_i$  i  $Y$  standardizovány, při kontrole všech ostatních prediktorů ( $\approx$  semiparciální korelace); jedinečný přínos
    - k porovnání prediktorů mezi sebou v rámci jednoho modelu
    - k porovnání různě operacionalizovaného prediktoru v různých modelech
    - ukazatel velikosti účinku
  - **$b_0$**  – obtížně interpretovatelný průsečík ... leda by prediktory byly **centrované**
  - V různých modelech nemusí být vliv prediktoru stejný
-

# 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
-

# Suprese







# 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
    - ...leda by nám šlo výhradně o zpřesnění predikce (nikoli o testy hypotéz)
-

# Daignostika 2: Kolinearita

---

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

I při korelacích kolem 0,5 komplikuje interpretaci!!

---

# Diagnostika 3: Předpoklady regrese

---


- Závislá alespoň intervalová, prediktory intervalové i kategorické
  - Nenulový rozptyl prediktorů
  - Absence vysoké kolinearity (žádné  $r > 0,9$ , tolerance  $< 0,1$ )
  - Neexistence intervenující proměnné, která by korelovala se závislou i prediktory
  - Homoskedascita (scatterplot ZRESID x ZPRED, parciální scatterplot)
  - Nezávislost reziduí (Durbin-Watson = 2)
  - Normálně rozložená rezidua (histogram, P-P)
  - Nezávislost jednotlivých případů
  - Linearita vztahu
-



# MLR: Shoda modelu s daty: $R^2$


---

- Část rozptylu  $Y$  vysvětleného dohromady všemi prediktory
- Predikční síla sady prediktorů
- Ukazatel velikosti účinku
- $R$ : Mnohonásobná (multiple) korelace
- Vždy nadhodnocuje >> při replikaci vychází nižší  $R^2$ 
  - shrinkage correction – Adjusted (upravené)  $R^2$ 
    - Wherry (SPSS, Statistica) – kdybychom model dělali z cenzových dat
  - cross-validation
    - Stein (Field) – očekávané  $R^2$  při replikaci
    - split-sample analýza



# Síla testu a velikost vzorku v MLR

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.

# Reportování MLR

---

## □ Základ

- Popisné statistiky  $Y$  a  $X_i$  často s korelační maticí
  - Ujištění o naplnění předpokladů
  - Popis shody modelu s daty –  $R^2$ ,  $p$  (někdy i s  $F$ testem)
  - Přehled regresních koeficientů,  $b$ ,  $\beta$  s jejich  $SE$ , popř. s intervaly spolehlivosti, nebo  $p$
-

# Hierarchická lineární regrese

---

- Bloková, se sadami (sets) prediktorů
  - Prediktory vkládáme po skupinách (popř. jednotlivě) v teoreticky zdůvodněném pořadí
  - Teoreticky zdůvodněné pořadí umožňuje rozdělit rozptyl Y na smysluplné části (variance partitioning)
    - Změna pořadí prediktorů změní velikost těch částí
  - Zajímá nás schopnost sady prediktorů vylepsit model
    - Srovnání různých oblastí vlivu na zkoumaný jev
    - Zkoumání inkrementální validity
-

# Obvyklá řazení bloků

---

- Dle času, kauzální priority
    - Př. od dispozičním k situačním...
  - Od známých k neznámým vlivům
    - kontrola intervenujících proměnných
    - Minimalizace chyby 1. typu
  - Podle výzkumné relevance
    - Od ústředních po „co kdyby“; maximalizace síly
-

# Obvyklý postup regresní analýzy

---

- Na základě teoretických rozvah stanovíme různé modely, jejichž srovnání je potenciálně zajímavé
  - Nejjednodušší srovnání je u hierarchických modelů, kdy je jeden model plně vnořen do následujícího – to umožňuje testovat inkrement R<sup>2</sup>
  - Až v druhé řadě se zabýváme jednotlivými regresními koeficienty v modelu, který je nejúplnější/nejlepší
-

# 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, pohlavi a mat99
- Split podle kohorty


# Moderace a Mediace

---

- MODERACE a MEDIACE jsou prototypickým zapojením třetí proměnné do vztahu mezi dvěma proměnnými
  - Terminologii a statistiku v tomto směru ustavili před 25 lety Baron a Kenny, <http://davidakenny.net/kenny.htm>
  - MODERÁTOR je obvykle kategorická proměnná, která mění (historicky snižuje-moderuje) těsnost vztahu mezi X a Y
  - MEDIÁTOR je proměnná, skrze níž se odehrává vztah mezi X a Y. Vztah mezi X a Y je pouze zdánlivý, protože X ve skutečnosti ovlivňuje Moderátor a Moderátor následně ovlivňuje Y.
-


# MODERACE A MEDIACE

---



# Mediace

---




1. X signifikantně predikuje Y (!  $r$  může být při plné mediaci malá)
2. X signifikantně predikuje Mediátor
3. M signifikantně predikuje Y, je-li X kontroloována
4. Původně signifikantní vztah mezi X a Y po zařazení mediátoru klesne (ideálně na 0)
5. Nepřímý efekt X na Y (přes M) se statisticky významně liší od 0 – Sobelův test ( $a=B_{M.X}$ ,  $b=B_{Y.M}$ )

$$z = \frac{ab}{\sqrt{(b^2SE_a^2) + (a^2SE_b^2)}}$$

# Moderace

□ Liší se vliv X na Y např. pro muže a ženy?



# Moderace se realizuje násobením

---

- Je-li proměnná moderátorem vztahu prediktoru a závislé, říkáme, že moderátor **interaguje** s prediktorem
  - Interagovat mohou kategorické i intervalové proměnné
  - Vytvoříme novou proměnnou, která je násobkem interagujících proměnných
    - Př. depBYpoh=Deprese\*pohlaví
  - Vložíme do regrese tuto proměnnou vedle hlavních efektů
    - Př.  $\check{Z}S = b_0 + b_1*D + b_2*P + b_3*depBYpoh + e$
  - Regr. koeficient vyjadřuje rozdíl vlivů jedné interagující proměnné pro různé hodnoty druhé interagující proměnné
-

# Úkol

---

- Vytvořte model predikující životní spokojenost.
- Jako prediktory zařadíte ve zdůvodněném pořadí po blocích následující proměnné
  - Pohlaví a kohorta
  - Self-esteem a deprese
  - Vřelost matky a otce
  - Známka z matematiky
  - Vzdělání otce
  - Zdraví
- Některé proměnné bude nutné překódovat.