

4EK211 Základy ekonometrie

ZS 2016/17 Cvičení 6: Multikolinearita, umělé proměnné



LENKA FIŘTOVÁ

KATEDRA EKONOMETRIE, FAKULTA INFORMATIKY A STATISTIKY

VYSOKÁ ŠKOLA EKONOMICKÁ V PRAZE

1. Multikolinearita

Otevřete si data z minula. Upravte proměnnou price (vydělte 1000).

Data: pizza.wf1

Zdroj: ECON2300, University of Queensland, 2012, upraveno

Co budeme zkoumat: kolik utrácí lidi za pizzu v závislosti na různých faktorech

1. Multikolinearita

Proměnné:

- pizza: roční útrata za pizzu v dolarech
- zena: = 1 pro ženy, jinak 0 (umělá proměnná, dummy variable)
- muz: = 1 pro muže, jinak 0 (umělá proměnná, dummy variable)
- příjem roční příjem v dolarech
- vek věk (v letech)
- hranolky roční útrata za hranolky v dolarech
- hamburgery roční útrata za hamburgery v dolarech
- salaty roční útrata za saláty v dolarech

1. Multikolinearita

Budeme zkoumat vliv pohlaví na útratu za pizzu.

Odhadněte model:

$$pizza = \beta_0 + \beta_1 prijem + \beta_2 vek + \beta_3 zena + \beta_4 muz + u$$

V čem je problém? Který G-M předpoklad je porušen? Jakou úpravu modelu byste navrhli?

1. Multikolinearita

Odhadněte následující modely a posuďte, zda jsou proměnné v modelu významné.

$$pizza = \beta_0 + \beta_1 hranolky + u$$

$$pizza = \beta_0 + \beta_1 hranolky + \beta_2 hamburgery + u$$

$$pizza = \beta_0 + \beta_1 hranolky + \beta_2 hamburgery + \beta_3 salaty + u$$

Může zde hrát roli multikolinearita?

1. Multikolinearita

- jde o lineární závislost vysvětlujících proměnných
- je pak obtížné poznat, jak každá z vysvětlujících proměnných ovlivňuje vysvětlující proměnnou (poznáme, jak ji ovlivňují dohromady)
- příčiny:
 - Tendence časových řad vyvíjet se stejným směrem
 - Průřezová data
 - Zpožděné hodnoty proměnných
 - Nesprávný počet dummy proměnných - kdy jsme se s tím dnes setkali?

1. Multikolinearita

→ netestujeme ji, nýbrž ji měříme v jednom konkrétním souboru

→ důsledky:

- Odhady jsou nestranné i vydatné, ale...
- Odhady nejsou stabilní, jsou citlivé i na malé změny v matici \mathbf{X}
- Směrodatné chyby koeficientů jsou velké - proměnná se může jevit jako nevýznamná, i když to nemusí být pravda

1. Multikolinearita

Měření - 2 proměnné:

multikolinearita je v modelu únosná, pokud platí současně:

$$|r_{x_1, x_2}| \leq 0,9$$

$$r_{x_1, x_2}^2 \leq R^2$$

Kde r_{x_1, x_2} je párový korelační koeficient mezi dvěma vysvětlujícími proměnnými

R^2 je koeficient determinace z modelu

2. Multikolinearita

Měření - více než 2 proměnné:

Tabulka párových korelačních koeficientů

(Quick → Group Statistics → Correlations)

	HAMBURGE...	HRANOLKY	SALATY
HAMBURGE...	1.000000	0.828942	-0.751122
HRANOLKY	0.828942	1.000000	-0.734738
SALATY	-0.751122	-0.734738	1.000000

Odhalí lineární závislost mezi jednotlivými dvojicemi proměnných. To ale někdy nestačí...

V případě více proměnných používáme **pomocné regrese**.

1. Multikolinearita

Měření - více než 2 proměnné:

Původní regrese:

$$y = f(x_1, x_2, x_3) \rightarrow R^2$$

Pomocné regrese:

$$x_1 = f(x_2, x_3) \rightarrow R_1^2$$

$$x_2 = f(x_1, x_3) \rightarrow R_2^2$$

$$x_3 = f(x_1, x_2) \rightarrow R_3^2$$

Jsou-li všechny dílčí koeficienty determinace z pomocných regresí menší než koeficient determinace z původní regrese, je multikolinearita v modelu únosná.

1. Multikolinearita

$$pizza = \beta_0 + \beta_1 hranolky + \beta_2 hamburgery + \beta_3 salaty + u \rightarrow R^2 = 0,16$$

$$hranolky = \beta_0 + \beta_1 hamburgery + \beta_2 salaty + u \rightarrow R^2 = 0,72$$

$$hamburgery = \beta_0 + \beta_1 hranolky + \beta_2 salaty + u \rightarrow R^2 = 0,73$$

$$salaty = \beta_0 + \beta_1 hranolky + \beta_2 hamburgery + u \rightarrow R^2 = 0,60$$

Multikolinearita není v modelu únosná.

1. Multikolinearita

→ řešení:

- Získat další pozorování
- Použít jiný model (jiná formulace, vypuštění proměnné), pozor na specifikační chybu
- Transformace pozorování (první diference, podíly)

2. Umělé proměnné

Zkuste nyní odhadnout následující dva modely:

$$(1) \textit{pizza} = \beta_0 + \beta_1 \textit{prijem} + \beta_2 \textit{zena} + u$$

$$(2) \textit{pizza} = \beta_0 + \beta_1 \textit{prijem} + \beta_2 (\textit{prijem} \cdot \textit{zena}) + u$$

Interpretujte koeficienty a nakreslete v obou případech regresní přímku pro muže a pro ženy.

2. Umělé proměnné


$$(1) \text{ pizza} = \beta_0 + \beta_1 \text{prijem} + \beta_2 \text{zena} + u$$

$$\widehat{\text{pizza}} = 226 + 1,41 \cdot \text{prijem} - 182 \cdot \text{zena}$$

Střední hodnota vysvětlované proměnné:

$$\text{Muž: } E(\text{pizza}) = 226 + 1,41 \cdot \text{prijem}$$

$$\text{Žena: } E(\text{pizza}) = 44 + 1,41 \cdot \text{prijem}$$



2. Umělé proměnné

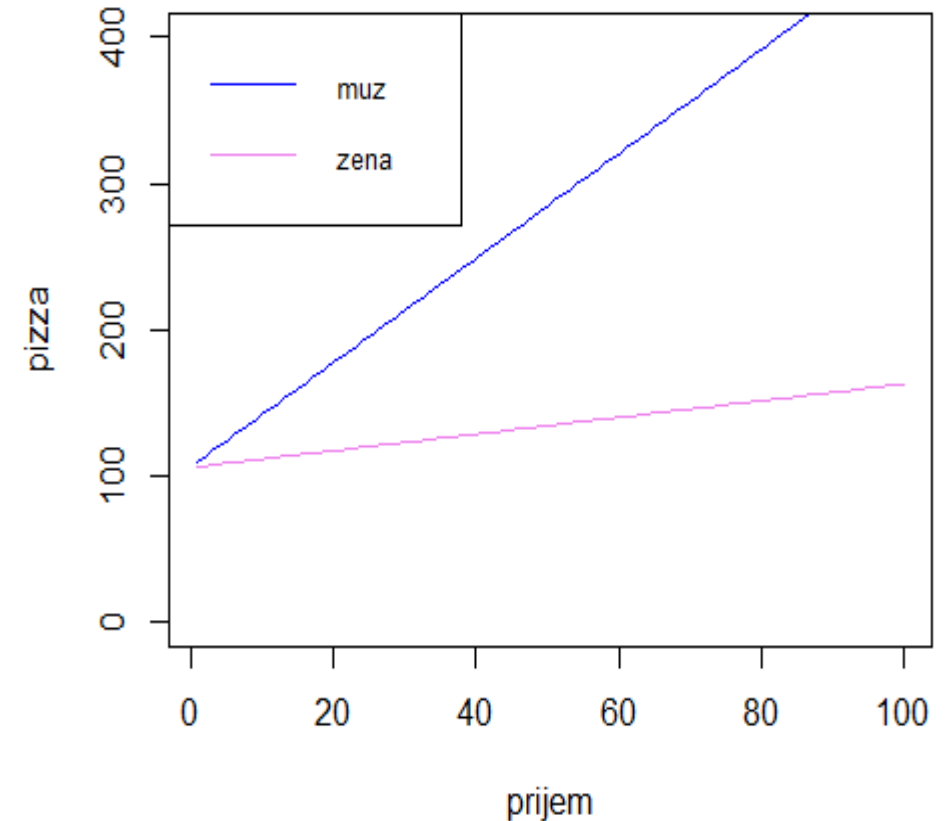
$$(2) \text{pizza} = \beta_0 + \beta_1 \text{prijem} + \beta_2 (\text{prijem} \cdot \text{zena}) + u$$

$$\widehat{\text{pizza}} = 106 + 3,57 \cdot \text{prijem} - 3 \cdot \text{prijem} \cdot \text{zena}$$

Střední hodnota vysvětlované proměnné:

$$\text{Muž: } E(\text{pizza}) = 106 + 3,57 \cdot \text{prijem}$$

$$\text{Žena: } E(\text{pizza}) = 106 + 0,57 \cdot \text{prijem}$$



2. Umělé proměnné

1. Kdybyste chtěli zkoumat útratu za pizzu v závislosti na tom, zda má člověk základní, střední či vyšší vzdělání, jaká data byste museli nasbírat a jak byste takový model specifikovali?
2. Napadá vás, jak by se mohly použít umělé proměnné při analýze časových řad?

Na doma: Co byste měli umět

1. Co je to multikolinearita, co je její příčinou?
2. Jak se měří multikolinearita v daném výběru?
3. Co je důsledkem multikolinearity?
4. Co jsou umělé proměnné, jak s nimi pracovat?