

# Lineární regrese

## Matematické metody pro ITS (11MAMY)

---

Jan Příkryl

s využitím díla G. James et al., *An Introduction to Statistical Learning*

8. přednáška 11MAMY


úterý 15. března 2023

verze: 2023-03-13 18:27

Ústav aplikované matematiky

ČVUT v Praze, Fakulta dopravní

- Lineární regrese je jednoduchý přístup k učení s učitelem (supervizovanému učení). Předpokládá, že závislost  $Y$  na  $X_1, X_2, \dots, X_p$  (tedy  $y = f(\mathbf{x})$ ) je lineární.
- Skutečné regresní funkce ale nejsou nikdy lineární!






- Ačkoli se může zdát přehnaně zjednodušená, je lineární regrese extrémně užitečná jak svou koncepcí, tak prakticky.

Uvažujme reklamní údaje, které ukazuje následující slajd.

Otázky, které si můžeme klást:

- Existuje vztah mezi rozpočtem na reklamu a prodejem?
- Jak silný je vztah mezi rozpočtem na reklamu a prodejem?
- Která média přispívají k prodeji?
- Jak přesně můžeme předpovědět budoucí prodeje?
- Je ten vztah lineární?
- Existuje synergie (efekt společného působení) mezi inzertními médii?



- Budeme uvažovat model

$$Y = \beta_0 + \beta_1 X + \epsilon,$$

kde  $\beta_0$  a  $\beta_1$  jsou dvě neznámé konstanty, které představují **regresní konstantu** (absolutní člen) a **sklon** (směrnici), říká se jim také **regresní koeficienty** nebo **parametry**,

- $\epsilon$  je chybový člen, často  $\epsilon \approx \mathcal{N}(0, \sigma^2)$  (šum modelu).
- Jsou-li dány nějaké odhady  $\hat{\beta}_0$  a  $\hat{\beta}_1$  koeficientů modelu, předpovídáme budoucí prodeje pomocí vzorce

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x,$$

kde  $\hat{y}$  označuje předpověď  $Y$  na základě  $X = x$ ,  $E[Y|X = x]$ . Symbol **stříška** označuje odhadnutou hodnotu.

- Necht'  $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$  je předpověď  $Y$  založená na  $i$ -té hodnotě  $X$ . Pak  $e_i = y_i - \hat{y}_i$  představuje  $i$ -té **reziduum**.
- Definujeme **reziduální součet čtverců (RSS)** jako

$$\text{RSS} = e_1^2 + e_2^2 + \cdots + e_n^2,$$


nebo ekvivalentně jako

$$\text{RSS} = (y_1 - \hat{\beta}_0 - \hat{\beta}_1 x_1)^2 + (y_2 - \hat{\beta}_0 - \hat{\beta}_1 x_2)^2 + \cdots + (y_n - \hat{\beta}_0 - \hat{\beta}_1 x_n)^2.$$

- Metoda nejmenších čtverců volí  $\hat{\beta}_0$  a  $\hat{\beta}_1$  tak, aby **hodnota RSS byla minimální**. Dá se ukázat, že tyto minimalizující hodnoty jsou

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}, \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

kde  $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ ,  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  jsou výběrové průměry.



Výsledek metody nejmenších čtverců pro regresi položky **sales** vůči **TV**. V tomto případě lineární aproximace zachycuje podstatu vzájemného vztahu, i když na levém konci grafu je poněkud závadná.

- Směrodatná chyba odhadu odráží to, jak se odhad mění při opakovaném vzorkování. Máme

$$SE(\hat{\beta}_1)^2 = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2},$$
$$SE(\hat{\beta}_0)^2 = \sigma^2 \left[ \frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right],$$

kde  $\sigma^2 = \text{var}(\epsilon)$ .

- Tyto směrodatné chyby se mohou použít k výpočtu **intervalů spolehlivosti**. Interval spolehlivosti 95 % se definuje jako takový rozsah hodnot, že s pravděpodobností 95 % bude tento obor obsahovat skutečnou neznámou hodnotu daného parametru. Pro  $\beta_1$  má tvar

$$\hat{\beta}_1 \pm 2 \cdot SE(\hat{\beta}_1).$$



Znamená to, že je přibližně 95 % možnost, že interval

$$\langle \hat{\beta}_1 - 2 \cdot \text{SE}(\hat{\beta}_1), \hat{\beta}_1 + 2 \cdot \text{SE}(\hat{\beta}_1) \rangle$$

bude obsahovat skutečnou hodnotu  $\beta_1$  (ve scénáři, kdy jsme dostali opakované vzorky jako je současný vzorek).

Pro naše reklamní data je 95 % interval spolehlivosti pro  $\beta_1$  roven  $\langle 0,042, 0,053 \rangle$ .

- Směrodatné chyby mohou být také použity k *testování hypotéz* o koeficientech. Nejběžnější test hypotézy je testování **nulové hypotézy** tvaru

$H_0$ : Mezi  $X$  a  $Y$  není žádný vzájemný vztah

vůči **alternativní hypotéze**

$H_A$ : Existuje nějaký vztah mezi  $X$  a  $Y$ .

- Matematicky to odpovídá testování

$$H_0 : \beta_1 = 0$$

vůči

$$H_A : \beta_1 \neq 0,$$

neboť pokud  $\beta_1 = 0$ , model se redukuje na  $Y = \beta_0 + \epsilon$  a  $X$  s  $Y$  není propojeno.

- K testu nulové hypotézy vypočítáme ***t*-statistiku** danou vztahem

$$t = \frac{\hat{\beta}_1 - 0}{\text{SE}(\hat{\beta}_1)}.$$

- Ta bude mít *t*-rozdělení s  $n - 2$  stupni volnosti, za předpokladu, že  $\beta_1 = 0$ .
- Pomocí statistického softwaru se snadno vypočítá pravděpodobnost, že budeme pozorovat jakoukoli hodnotu rovnou  $|t|$  nebo větší. Tato pravděpodobnost se nazývá ***p*-hodnota**.

	Koeficient	Směr. chyba	<i>t</i> -statistika	<i>p</i> -hodnota
Regr.konst.	7,0325	0,4578	15,36	< 0,0001
<b>TV</b>	0,0475	0,0027	17,67	< 0,0001

- Vypočítáme **reziduální směrodatnou chybu**

$$\text{RSE} = \sqrt{\frac{1}{n-2} \text{RSS}} = \sqrt{\frac{1}{n-2} \sum_{i=1}^n (y_i - \hat{y}_i)^2},$$

kde **reziduální součet čtverců** je  $\text{RSS} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$ .

- **R kvadrát** neboli koeficient determinace je

$$R^2 = \frac{\text{TSS} - \text{RSS}}{\text{TSS}} = 1 - \frac{\text{RSS}}{\text{TSS}},$$

kde  $\text{TSS} = \sum_{i=1}^n (y_i - \bar{y})^2$  je **celkový součet čtverců**.

- Dá se ukázat, že v této jednoduché lineární regresní situaci je  $R^2 = r^2$ , kde  $r$  je korelace mezi  $X$  a  $Y$ :

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}.$$

Veličina	Hodnota
Reziduální směrodatná chyba	3,26
$R^2$	0,612
F-statistika	312,1

- Náš model zde je

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_p X_p + \epsilon,$$

- Interpretujeme  $\beta_j$  jako *průměrný* vliv jednoho jednotkového růstu  $X_j$  na  $Y$ , za předpokladu, že **všechny ostatní prediktory se nemění**. V příkladu s reklamou nabývá model tvaru

$$\text{prodeje} = \beta_0 + \beta_1 \times \text{TV} + \beta_2 \times \text{rozhlas} + \beta_3 \times \text{noviny} + \epsilon.$$

- Ideální scénář je tehdy, když prediktory nejsou korelovány — **vyvážený plán**:
  - Každý koeficient může být odhadnut a testován odděleně.
  - Jsou možné interpretace typu „jednotková změna v  $X_j$  je spojena se změnou  $Y$  o  $\beta_j$ , přičemž všechny ostatní proměnné zůstávají beze změny“.
- Korelace mezi prediktory působí problémy:
  - Rozptyl všech koeficientů má tendenci růst, někdy dramaticky.
  - Interpretace se stávají hazardními — když se změní  $X_j$ , změní se všechno ostatní.
- Měli bychom se vyhnout **kauzalitě** v pozorovaných datech.



## „Data Analysis and Regression“ Mosteller a Tukey 1977

- Regresní koeficient  $\beta_j$  odhaduje očekávanou změnu  $Y$  při jednotkové změně  $X_j$ , přičemž všechny ostatní prediktory jsou zafixovány. Ale prediktory se obvykle mění společně!

### Příklad

$Y$  je celková částka v drobných ve vaší kapse;  $X_1$  je počet mincí;  $X_2$  je počet korun, dvoukorun a pětikorun. Sám o sobě bude regresní koeficient  $Y$  vzhledem k  $X_2$  kladný. Ale co se dá říci o  $X_1$  v modelu?

## „Data Analysis and Regression“ Mosteller a Tukey 1977

- Regresní koeficient  $\beta_j$  odhaduje očekávanou změnu  $Y$  při jednotkové změně  $X_j$ , přičemž všechny ostatní prediktory jsou zafixovány. Ale prediktory se obvykle mění společně!

### Příklad

$Y$  = počet zákroků fotbalového hráče během sezóny;  $W$  a  $H$  jsou jeho váha a výška. Proložený regresní model je  $Y = \hat{\beta}_0 + 0,50W - 0,10H$ . Jak interpretujeme  $\hat{\beta}_2 < 0$ ?

„V zásadě jsou všechny modely špatné, ale některé jsou užitečné.“

George Box

„Jediný způsob, jak zjistit, co se děje při porušení složitého systému, je porušit ten systém a ne jej pouze pasivně pozorovat.“

Fred Mosteller a John Tukey, jako parafráze George Boxe


- Při daných odhadech  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$  můžeme počítat predikce pomocí vzorce

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_p x_p.$$

- Odhadujeme  $\beta_0, \beta_1, \dots, \beta_p$  jako hodnoty, které minimalizují součet kvadrátů reziduí

$$\begin{aligned} \text{RSS} &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\ &= \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_p x_{ip})^2. \end{aligned}$$

Dělá se to pomocí standardního statistického softwaru. Hodnoty  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$ , které minimalizují RSS, jsou odhady regresních koeficientů vícenásobnou metodou nejmenších čtverců.



	Koeficient	Směrod.chyba	t-statistika	p-hodnota
Regr. konst.	2,939	0,3119	9,42	< 0,0001
TV	0,046	0,0014	32,81	< 0,0001
rozhlas	0,189	0,0086	21,90	< 0,0001
noviny	-0,001	0,0059	-0,18	0,8599

Korelace:

	TV	rozhlas	noviny	prodeje
TV	1,0000	0,0548	0,0567	0,7822
rozhlas		1,0000	0,3541	0,5762
noviny			1,0000	0,2283
prodeje				1,0000

- a) *Je alespoň jeden z prediktorů  $X_1, X_2, \dots, X_p$  užitečný při předpovídání odpovědi?*
- b) *Pomáhají všechny prediktory vysvětlit  $Y$ , nebo je užitečná pouze nějaká podmnožina prediktorů?*
- c) *Jak dobře model aproximuje data?*
- d) *Je-li dán soubor hodnot prediktorů, jakou hodnotu odpovědi bychom měli předpovědět a jak přesná je naše předpověď?*

Pro první otázku můžeme použít F-statistiku

$$F = \frac{(TSS - RSS)/p}{RSS/(n - p - 1)} \sim F_{p, n-p-1}$$

Veličina	Hodnota
Reziduální směrodat. chyba	1,69
$R^2$	0,897
F-statistika	570



- Nejpřímější přístup se nazývá regrese se **všemi podmnožinami** nebo s **nejlepší podmnožinou**: počítáme aproximace metodou nejlepších čtverců pro všechny možné podmnožiny a pak z nich vybereme pomocí nějakého kritéria, které vyvažuje trénovací chybu s velikostí modelu.
- Často však nemůžeme vyšetřit všechny možné modely, protože je jich  $2^p$ ; například pro  $p = 40$  existuje přes miliardu modelů!  
Místo toho potřebujeme automatizovaný přístup, který prohledává nějakou jejich podmnožinu. V dalším probereme dva běžně používané přístupy.

- Začni s **nulovým modelem** — modelem, který obsahuje regresní konstantu, ale žádné prediktory.
- Prolož  $p$  jednoduchých lineárních regresí a přidej k nulovému modelu tu proměnnou, která vede k nejnižšímu RSS.
- Přidej k tomu modelu proměnnou, která vede k nejnižšímu RSS mezi všemi modely s dvěma proměnnými.
- Pokračuj, dokud není splněno nějaké zastavovací kritérium, například že všechny zbývající proměnné mají  $p$ -hodnotu nad nějakou hranicí.

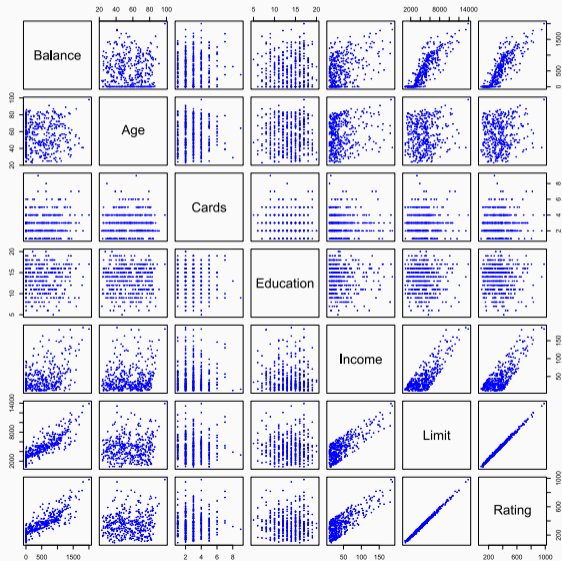
- Začni se všemi proměnnými v modelu.
- Odeber proměnnou s největší  $p$ -hodnotou – to jest proměnnou, která je nejméně statisticky významná.
- Prolož nový model s  $p - 1$  proměnnými a odeber proměnnou s největší  $p$ -hodnotou.
- Pokračuj do splnění nějakého zastavovacího kritéria. Můžeme například zastavit, když všechny zbývající proměnné mají významnou  $p$ -hodnotu definovanou jako nějaká hranice významnosti.

- Později probereme systematictější kritéria pro volbu „optimálního“ modelu na dráze modelů vytvořených postupně dopřednou selekcí nebo zpětnou eliminací.
- Patří k nim Mallowovo  $C_p$ , Akaike informační kritérium (AIC), Bayesovské informační kritérium (BIC), upravené  $R^2$  a křížová validace (CV).

## Kvalitativní prediktory

- Některé prediktory nejsou **kvantitativní**, ale jsou **kvalitativní**, nabývají hodnot v diskrétní množině.
- Nazývají se také **kategoriální** prediktory nebo **proměnné faktory**.
- Viz například matici bodových grafů s údaji o kreditních kartách na následujícím slajdu.

Kromě sedmi kvantitativních proměnných, jež jsou v matici uvedeny, jsou v datech čtyři kvalitativní proměnné: **gender** (pohlaví), **student** (studentský status), **status** (rodinný stav) a **ethnicity** (původ – kavkazský, afroamerický (AA) nebo asijský).



## Příklad (Model s kvalitativními prediktory)

Vyšetřete rozdíl v zůstatku na kreditní kartě mezi muži a ženami, přičemž budete ignorovat ostatní proměnné.

Utvoříme novou proměnnou  $x_i$ , rovnou 1, je-li  $i$ -tá osoba žena, rovnou 0, je-li  $i$ -tá osoba muž. Výsledný model:

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i = \begin{cases} \beta_0 + \beta_1 + \epsilon_i & \text{je-li } i\text{-tá osoba žena,} \\ \beta_0 + \epsilon_i & \text{je-li } i\text{-tá osoba muž.} \end{cases}$$

Q: Interpretace?

Výsledky pro model podle pohlaví:

	Koef.	SE	<i>t</i> -statistika	<i>p</i> -hodnota
Regresní konst.	509,80	33,13	15,389	< 0,0001
<b>gender</b> [žena]	19,73	46,05	0,429	0,6690



- Při více než dvou úrovních utvoříme dodatečné fiktivní proměnné. Tak například pro proměnnou **ethnicity** utvoříme dvě fiktivní proměnné. První by mohla být

$$x_{i1} = \begin{cases} 1 & \text{je-li } i\text{-tá osoba asijského původu,} \\ 0 & \text{není-li } i\text{-tá osoba asijského původu,} \end{cases}$$

a druhá by mohla být

$$x_{i2} = \begin{cases} 1 & \text{je-li } i\text{-tá osoba kavkazského původu,} \\ 0 & \text{není-li } i\text{-tá osoba kavkazského původu.} \end{cases}$$

- Pak mohou být v regresní rovnici použity obě tyto proměnné, takže dostaneme model

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} = \begin{cases} \beta_0 + \beta_1 + \epsilon_i & \text{je-li } i\text{-tá osoba Asiat} \\ \beta_0 + \beta_2 + \epsilon_i & \text{je-li } i\text{-tá osoba běloch} \\ \beta_0 + \epsilon_i & \text{je-li } i\text{-tá osoba Afroameričan.} \end{cases}$$

- Fiktivních proměnných bude vždy o jednu méně než je počet úrovní. Úroveň bez fiktivní proměnné — v tomto příkladu Afroameričani — je známa jako **výchozí úroveň**.

	Koef.	SE	<i>t</i> -statistika	<i>p</i> -hodnota
Regresní konst.	531,00	46,32	11,464	< 0,0001
<i>ethnicity</i> [asijská]	-18,69	65,02	-0,287	0,7740
<i>ethnicity</i> [kavkazská]	-12,50	56,68	-0,221	0,8260

Odstraníme předpoklad aditivity: **interakce a nelinearita**


**Interakce:**

- V naší předchozí analýze reklamních dat jsme předpokládali, že vliv zvýšení prostředků jednoho reklamního média na **sales** (prodeje) nezávisí na objemu prostředků vynaložených na zbylá média.
- Tak například, lineární model

$$\text{sales} = \beta_0 + \beta_1 \times \text{TV} + \beta_2 \times \text{radio} + \beta_3 \times \text{newspaper}$$

říká, že průměrný efekt jednotkového vzrůstu reklamních nákladů v **TV** na **sales** je vždy  $\beta_1$ , nezávisle na množství prostředků vynaložených na **radio**.

- Ale předpokládejme, že peníze vynaložené na rozhlasovou reklamu ve skutečnosti zvyšují efektivitu TV reklamy, takže koeficient sklonu pro **TV** by měl s růstem hodnoty **radio** růst.
- V této situaci, máme-li dán pevný rozpočet \$100 000, investice poloviny do **radio** a poloviny do **TV** může zvýšit **sales** více, než použití celé částky na **TV** nebo na **radio**.
- V marketingu se tomuhle říká efekt **synergie**, ve statistice se o tom mluví jako o efektu **interakce**.



Když je úroveň **TV** nebo **radio** nízká, pak jsou skutečné hodnoty **sales** nižší, než jak předpovídá lineární model.

Ale když se reklama rozdělí mezi tato dvě média, pak má model tendenci **sales** podhodnocovat.

Model nabývá tvaru

$$\begin{aligned} \text{sales} &= \beta_0 + \beta_1 \times \text{TV} + \beta_2 \times \text{radio} + \beta_3 \times (\text{radio} \times \text{TV}) + \epsilon \\ &= \beta_0 + (\beta_1 + \beta_3 \times \text{radio}) \times \text{TV} + \beta_2 \times \text{radio} + \epsilon. \end{aligned}$$

Výsledky:

	Koef.	SE	t-statistika	p-hodnota
Regres. konst.	6,7502	0,248	27,23	< 0,0001
TV	0,0191	0,002	12,70	< 0,0001
radio	0,0289	0,009	3,24	0,0014
TV × radio	0,0011	0,000	20,73	< 0,0001

- Výsledky v této tabulce naznačují, že interakce jsou důležité.
- $p$ -hodnota pro interakční člen **TV**  $\times$  **radio** je extrémně nízká, což ukazuje, že jsou tu silné náznaky platnosti  $H_A : \beta_3 \neq 0$ .
- Hodnota  $R^2$  pro interakční model je 96.8 % ve srovnání s pouhými 89.7 % u modelu, který předpovídá **sales** pomocí **TV** a **radio** bez interakčního členu.
- To znamená, že  $(96,8 - 89,7)/(100 - 89,7) = 69\%$  variability v proměnné **sales**, která zůstává po proložení aditivního modelu, se vysvětlilo interakčním členem.



Odhady koeficientů v tabulce naznačují, že

- zvýšení prostředků na reklamu v televizi o \$1 000 je spojeno se zvýšením prodeje o  $(\hat{\beta}_1 + \hat{\beta}_3 \times \text{radio}) \times 1000 = 19 + 1,1 \times \text{radio}$  jednotek,
- zvýšení prostředků na reklamu v rozhlasu o \$1 000 bude spojeno s růstem prodeje o  $(\hat{\beta}_2 + \hat{\beta}_3 \times \text{TV}) \times 1000 = 29 + 1,1 \times \text{TV}$  jednotek.

- Někdy se stane, že interakční člen má velmi malou  $p$ -hodnotu, ale přidružené hlavní efekty (v tomto případě **TV** a **radio**) nikoliv.
- **Princip hierarchie:**  
*Pokud zahrneme do modelu nějakou interakci, měli bychom také zahrnout hlavní efekty, a to i tehdy, nejsou-li  $p$ -hodnoty spojené s jejich koeficienty významné.*

- Odůvodněním tohoto principu je skutečnost, že interakce se v modelu bez hlavních efektů obtížně interpretují – jejich smysl se změní.
- Speciálně, interakční členy také obsahují hlavní efekty i tehdy, když model nemá členy s hlavními efekty.

Uvažujme soubor dat **Credit** a předpokládejme, že chceme předpovědět **balance** na základě **income** (kvantitativní) a **student** (kvalitativní).



Bez interakčního členu bude model mít tvar

$$\begin{aligned} \text{balance}_i &= \beta_0 + \beta_1 \times \text{income}_i + \begin{cases} \beta_2 & \text{je-li } i\text{-tá osoba student,} \\ 0 & \text{není-li } i\text{-tá osoba student,} \end{cases} \\ &= \beta_1 \times \text{income}_i + \begin{cases} \beta_0 + \beta_2 & \text{je-li } i\text{-tá osoba student,} \\ \beta_0 & \text{není-li } i\text{-tá osoba student.} \end{cases} \end{aligned}$$

Uvažujme soubor dat **Credit** a předpokládejme, že chceme předpovědět **balance** na základě **income** (kvantitativní) a **student** (kvalitativní).


S interakcemi bude model mít tvar

$$\begin{aligned} \text{balance}_i &\approx \beta_0 + \beta_1 \times \text{income}_i + \begin{cases} \beta_2 + \beta_3 \times \text{income}_i & \text{je-li student} \\ 0 & \text{není student} \end{cases} \\ &= \begin{cases} (\beta_0 + \beta_2) + (\beta_1 + \beta_3) \times \text{income}_i & \text{je-li } i\text{-tá osoba student} \\ \beta_0 + \beta_1 \times \text{income}_i & \text{není-li student} \end{cases} \end{aligned}$$



Vlevo: žádná interakce mezi **income** a **student**.

Vpravo: s interakčním členem mezi **income** a **student**.



Obrázek naznačuje, že

$$\text{mpg} = \beta_0 + \beta_1 \times \text{horsepower} + \beta_2 \times \text{horsepower}^2 + \epsilon$$

může dávat lepší aproximaci.

	Koeficient	SE	t-statistika	p-hodnota
Regres. konst.	56,9001	1,8004	31,6	< 0,0001
horsepower	-0,4662	0,0311	-15,0	< 0,0001
horsepower <sup>2</sup>	0,0012	0,0001	10,1	< 0,0001