

# Bayesiánská analýza

II. Normální lineární regresní model s přirozeně konjugovanou apriorní hustotou (jediná vysvětlující proměnná)

# Obsah tématu

- 1 Lineární regresní model
- 2 Věrohodnostní funkce
- 3 Apriorní hustota
- 4 Posteriorní hustota
- 5 Neinformativní apriorní hustota
- 6 Porovnání modelů
- 7 Predikce
- 8 Empirická ilustrace

- Koop (2003) - kapitola 2
- Normální lineární regresní model s jedinou vysvětlující proměnnou (není třeba maticové algebry).
- Přirozeně konjugovaný prior  $\Rightarrow$  analytické výsledky.
- Význam před rozvojem výpočetní techniky.
- Ukázka propojení klasické a bayesovské ekonometrie.

# Obsah tématu

- 1 Lineární regresní model
- 2 Věrohodnostní funkce
- 3 Apriorní hustota
- 4 Posteriorní hustota
- 5 Neinformativní apriorní hustota
- 6 Porovnání modelů
- 7 Predikce
- 8 Empirická ilustrace

# Lineární regresní model

- $y_i$  – pozorovaná data vysvětlované proměnné ( $i = 1, \dots, N$ ).
- $x_i$  – pozorovaná data vysvětlující proměnné ( $i = 1, \dots, N$ ).
- LRM s jedinou vysvětlující proměnnou a bez úrovňové konstanty (pro zjednodušení):

$$y_i = \beta x_i + \epsilon_i$$

- $\epsilon_i$  – náhodná složka (chyba);  $\beta$  – parametr.
- Vektorově pro  $y = (y_1, \dots, y_N)'$ ,  $x = (x_1, \dots, x_N)'$  a  $\epsilon = (\epsilon_1, \dots, \epsilon_N)'$ :

$$y = \beta x + \epsilon$$

# Předpoklady

- Předpoklady o  $\epsilon_i$  a  $x_i$  determinují podobu věrohodnostní funkce.
- Klasické předpoklady (později uvolněny):
  - ①  $\epsilon_i$  je i.i.d.  $N(0, \sigma^2)$  (independent and identically distributed).
  - ②  $x_i$  je fixní proměnná (tj. nenáhodná veličina), popř. náhodná s omezeními.

# Obsah tématu

- 1 Lineární regresní model
- 2 Věrohodnostní funkce
- 3 Apriorní hustota
- 4 Posteriorní hustota
- 5 Neinformativní apriorní hustota
- 6 Porovnání modelů
- 7 Predikce
- 8 Empirická ilustrace

# Věrohodnostní funkce I

- Věrohodnostní funkce = funkce sdružené hustoty pravděpodobnosti pro všechna data podmíněná neznámými parametry:

$$p(y|\beta, \sigma^2).$$

- Získáme z definovaných předpokladů.

- $p(y_i|\beta, \sigma^2)$  má normální rozdělení,
- $E(y_i|\beta, \sigma^2) = \beta x_i$ ,
- $\text{var}(y_i|\beta, \sigma^2) = \sigma^2$ .

# Věrohodnostní funkce II

- Věrohodnostní funkce:

$$p(y|\beta, \sigma^2) = \frac{1}{(2\pi)^{\frac{N}{2}} \sigma^N} \exp \left[ -\frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - \beta x_i)^2 \right].$$

# Věrohodnostní funkce III

- Další vyjádření věrohodnostní funkce:

$$\sum_{i=1}^N (y_i - \beta x_i)^2 = \nu s^2 + (\beta - \hat{\beta})^2 \sum_{i=1}^N x_i^2,$$

- kdy

$$\nu = N - 1$$

$$\hat{\beta} = \frac{\sum x_i y_i}{\sum x_i^2}$$

$$s^2 = \frac{\sum (y_i - \hat{\beta} x_i)^2}{\nu}$$

- $\hat{\beta}$ ,  $s^2$  a  $\nu$  = OLS odhad pro  $\beta$ , rozptyl reziduů a počet stupňů volnosti.

# Věrohodnostní funkce IV

- Obvykle využíváme přesnost chyby,  $h$ , místo variability:

$$h = \frac{1}{\sigma^2}$$

- Věrohodnostní funkce:

$$p(y|\beta, h) = \frac{1}{(2\pi)^{\frac{N}{2}}} \left\{ h^{\frac{1}{2}} \exp \left[ -\frac{h}{2}(\beta - \hat{\beta})^2 \sum_{i=1}^N (x_i)^2 \right] \right\} \left\{ h^{\frac{\nu}{2}} \exp \left[ -\frac{h\nu}{2s^2} \right] \right\}.$$

- První člen je podobný jádrové hustotě (kernelu) normální hustoty pro  $\beta$ ; druhý člen je podobný rozdělení gama pro  $h$ .

# Obsah tématu

1 Lineární regresní model

2 Věrohodnostní funkce

**3 Apriorní hustota**

4 Posteriorní hustota

5 Neinformativní apriorní hustota

6 Porovnání modelů

7 Predikce

8 Empirická ilustrace

# Konjugovaná apriorní hustota

- Konjugovaná apriorní hustota – interpretovatelná jako dodatečná data.
- Jestliže je  $\mathcal{F}$  třída výběrových rozdělení  $p(y|\theta)$  a  $\mathcal{P}$  je třída apriorních rozdělení pro  $\theta$ , potom třída  $\mathcal{P}$  je konjugovaná pro  $\mathcal{F}$  jestliže

$$p(\theta|y) \in \mathcal{P} \quad \text{pro všechna} \quad p(\cdot|\theta) \in \mathcal{F} \quad \text{a} \quad p(\cdot) \in \mathcal{P}.$$

- Vágní definice, pokud  $\mathcal{P}$  je třída všech rozdělení, potom  $\mathcal{P}$  je vždy konjugovaná bez ohledu na použitou třídu výběrových rozdělení.
- Zájem o třídy **přirozeně konjugovaných apriorních hustot**, kdy  $\mathcal{P}$  je množina všech hustot majících stejnou funkční podobu jako věrohodnostní funkce.

# Prior I

- Apriorní hustota – libovolná forma, obvykle určitá třída priorů, které lze snadno interpretovat a (nebo) zjednodušují výpočet.
- Apriorní hustota pro  $\beta$  a  $h$ :  $p(\beta, h)$ .
- Pravidla pravděpodobnosti:  $p(\beta, h) = p(\beta|h)p(h)$ .
- Forma věrohodnostní funkce – konjugovaný prior jako normální rozdělení pro  $\beta|h$  a gama rozdělení pro  $h$ .

# Prior II

- Normální-gama rozdělení:

$$\begin{aligned}\beta|h &\sim N(\underline{\beta}, h^{-1} \underline{V}) \\ h &\sim G(\underline{s}^{-2}, \underline{\nu})\end{aligned}$$

- Přirozeně konjugovaný prior pro  $\beta$  a  $h$ :

$$\beta, h \sim NG(\underline{\beta}, \underline{V}, \underline{s}^{-2}, \underline{\nu})$$

- Volba hodnoty apriorních hyperparametrů:  $\underline{\beta}$ ,  $\underline{V}$ ,  $\underline{s}^{-2}$  a  $\underline{\nu}$  (zohlednění apriorní informace).

# Obsah tématu

- 1 Lineární regresní model
- 2 Věrohodnostní funkce
- 3 Apriorní hustota
- 4 Posteriorní hustota
- 5 Neinformativní apriorní hustota
- 6 Porovnání modelů
- 7 Predikce
- 8 Empirická ilustrace

# Posterior I

- Posteriorní hustota je proporcionální součinu věrohodnostní funkce a apriorní hustoty.
- Normální-gama rozdělení (apriorní hustota je tedy skutečně přirozeně konjugovaná):

$$\beta, h | y \sim NG(\bar{\beta}, \bar{V}, \bar{s}^{-2}, \bar{\nu}),$$

přičemž platí

$$\bar{V} = \frac{1}{\underline{V}^{-1} + \sum x_i^2},$$

$$\bar{\beta} = \bar{V}(\underline{V}^{-1}\underline{\beta} + \hat{\beta} \sum x_i^2),$$

$$\bar{\nu} = \underline{\nu} + N.$$

- $\bar{s}^{-2}$  je implicitně definováno následovně:

$$\bar{\nu}s^2 = \underline{\nu}s^2 + \nu s^2 + \frac{(\hat{\beta} - \underline{\beta})^2}{\underline{V} + \sum x_i^2}.$$

# Vlastnosti posteriorní hustoty I

- $p(\beta|y, h)$  má normální rozdělení.
- Chceme  $p(\beta|y)$ .
- Marginální posteriorní rozdělení pro  $\beta$  je  $t$ -rozdělení:

$$\beta|y \sim t(\bar{\beta}, \bar{s}^2 \bar{V}^2, \bar{\nu}).$$

- Z definice  $t$ -rozdělení vyplývá:

$$E(\beta|y) = \bar{\beta},$$

$$\text{var}(\beta|y) = \frac{\bar{\nu} \bar{s}^2}{\bar{\nu} - 2} \bar{V}.$$

# Vlastnosti posteriorní hustoty II

- Bayesiánský bodový odhad  $\bar{\beta}$  je vážený průměr OLS odhadu a apriorní střední hodnoty  $\underline{\beta}$ .
- Váhy jsou proporcionální k  $\sum x_i^2$  a  $\underline{V}^{-1}$ .
- $\underline{V}^{-1}$  = důvěra v apriorní a datovou infomaci (v klasické ekonometrii je  $(\sum x_i^2)^{-1}$  proporcionální k variabilitě  $\hat{\beta}$ ).
- Alternativní intuice: jednoduchý případ  $x_i = 1$  pro  $i = 1, \dots, N \Rightarrow \sum x_i^2 = N$  a váha přiřazená k  $\hat{\beta}$  je velikost vzorku (rozumné měřítko pro objem informací v datech).

# Vlastnosti posteriorní hustoty III

- Rozptyl OLS estimátoru  $s^2(\sum x_i^2)^{-1}$  (využití např. k testování statistické významnosti parametru, kdy  $t$ -statistika pro testování  $\beta = 0$  je  $\frac{\hat{\beta}}{\sqrt{s^2(\sum x_i^2)^{-1}}}$ ).
- Bayesiánská analogie – posteriorní rozptyl  $\beta$  (podobná podobu  $\times$  zahrnuje datovou i nedatovou informaci).
- Přirozeně konjugovaná apriorní hustota = prior vyplývá z fiktivní datové množiny (podobná role  $\underline{v}$  a  $N$ ).
- $\underline{v}$ : apriorní velikost vzorku.

# Vlastnosti posteriorní hustoty IV

- Fiktivní datová množina → lze využít při specifikaci  $\underline{\beta}$ ,  $\underline{V}$ ,  $\underline{s}^{-2}$  a  $\underline{\nu}$ .
- Citlivostní analýza prioru – empirické výsledky lze prezentovat za využití různých priorů.
- Síla datové informace může i nemusí rozhodnout (nutnost zdůvodnění volby apriorních hyperparametrů).

# Obsah tématu

- 1 Lineární regresní model
- 2 Věrohodnostní funkce
- 3 Apriorní hustota
- 4 Posteriorní hustota
- 5 Neinformativní apriorní hustota
- 6 Porovnání modelů
- 7 Predikce
- 8 Empirická ilustrace

# Neinformativní prior I

- Neinformativní prior z nastavení  $\underline{\nu} = 0$  a  $\underline{V}^{-1} = 0$  (tj.  $\underline{V} \rightarrow \infty$ ).
- V tomto případě:  $\beta, h|y \sim NG(\bar{\beta}, \bar{V}, \bar{s}^{-2}, \bar{\nu})$ , kde

$$\bar{V} = \frac{1}{\sum x_i^2},$$

$$\bar{\beta} = \hat{\beta},$$

$$\bar{\nu} = N,$$

$$\bar{\nu}s^2 = \nu s^2.$$

# Neinformativní prior II

- Jedná se čistě o OLS odhad.
- Rozdílná interpretace:
  - bayesovský přístup –  $\beta$  je náhodná veličina;
  - klasický přístup –  $\hat{\beta}$  je náhodná veličina.
- Tato apriorní „hustota“ neintegraruje na hodnotu jedna → tzv. nepravý prior (improper prior).
- Problémy s použitím.

# Obsah tématu

- 1 Lineární regresní model
- 2 Věrohodnostní funkce
- 3 Apriorní hustota
- 4 Posteriorní hustota
- 5 Neinformativní apriorní hustota
- 6 Porovnání modelů
- 7 Predikce
- 8 Empirická ilustrace

# Porovnání modelů

- Dva modely  $M_1$  a  $M_2$ .
- $M_j$  pro  $j = 1, 2$  mají různé vysvětlující proměnné:

$$y_i = \beta_j x_{ji} + \epsilon_{ji}.$$

- Přirozeně konjugovaná normální-gama apriorní hustota:

$$\beta_j, h_j | M_j \sim NG(\underline{\beta}_j, \underline{V}_j, \underline{s}_j^{-2}, \underline{\nu}_j).$$

- Posteriorní hustota:

$$\beta_j, h_j | y, M_j \sim NG(\bar{\beta}_j, \bar{V}_j, \bar{s}_j^{-2}, \bar{\nu}_j).$$

# Posteriorní podíl šancí I

$$PO_{12} = \frac{p(y|M_1)p(M_1)}{p(y|M_2)p(M_2)}$$

- Apriorní pravděpodobnosti modelů  $p(M_j)$  (před konfrontací s daty); neinformativní volba  $p(M_1) = p(M_2) = \frac{1}{2}$ .
- Marginální věrohodnost  $p(y|M_j)$ :

$$p(y|M_j) = \iint p(y|\beta_j, h_j)p(\beta_j, h_j)d\beta_j dh_j.$$

- Lze pro náš případ spočítat analyticky:

$$p(y|M_j) = c_j \left( \frac{\bar{V}_j}{V_j} \right)^{\frac{1}{2}} (\bar{\nu}_j \bar{s}_j^2)^{-\frac{\bar{\nu}_j}{2}}.$$

# Posteriorní podíl šancí II

- $c_j$  konstanta nezávislá na datech

$$c_j = \frac{\Gamma\left(\frac{\underline{\nu}_j}{2}\right) (\underline{\nu}_j \underline{s}_j^2)^{\frac{\underline{\nu}_j}{2}}}{\Gamma\left(\frac{\underline{\nu}_j}{2}\right) \pi^{\frac{N}{2}}}.$$

- Posteriorní podíl šancí:

$$PO_{12} = \frac{c_1 \left(\frac{\bar{V}_1}{\underline{V}_1}\right)^{\frac{1}{2}} (\bar{\nu}_1 \bar{s}_1^2)^{-\frac{\bar{\nu}_1}{2}} p(M_1)}{c_2 \left(\frac{\bar{V}_2}{\underline{V}_2}\right)^{\frac{1}{2}} (\bar{\nu}_2 \bar{s}_2^2)^{-\frac{\bar{\nu}_2}{2}} p(M_2)}.$$

# Faktory ovlivňující bayesovské porovnání modelů

- ① Čím větší je apriorní podíl šancí  $\frac{p(M_1)}{p(M_2)}$ , tím vyšší je podpora pro  $M_1$ .
- ②  $\bar{\nu}_j \bar{s}_j^2$  obsahuje člen  $\nu_j s_j^2$ , což je součet čtverců chyb (měřítka souladu modelu s daty).
- ③ Pokud všechny ostatní charakteristiky jsou stejné: posteriorní podíl šancí upřednostní model s větší koherencí mezi apriorní a datovou informací  $((\hat{\beta}_j - \underline{\beta}_j)^2$  vstupuje do  $\bar{\nu}_j \bar{s}_j^2$ ).
- ④  $\left(\frac{\bar{V}_i}{V_i}\right)$  je podíl posteriorní a apriorní variancí  $\Rightarrow$  pokud vše ostatní zůstane stejné, upřednostní model s větší apriorní informací (menší apriorní varianci), relativně k posteriorní informaci.
- ⑤ Použitím neinformativního prioru není marginální věrohodnost definována (stějně tak posteriorní podíl šancí).

# Obsah tématu

1 Lineární regresní model

2 Věrohodnostní funkce

3 Apriorní hustota

4 Posteriorní hustota

5 Neinformativní apriorní hustota

6 Porovnání modelů

7 Predikce

8 Empirická ilustrace

# Predikční hustota

- Chceme předpovědět  $y^*$  v bodě  $x^*$ :

$$y^* = \beta x^* + \epsilon^*.$$

- $y^*$  není pozorováno.

$$p(y^*|y) = \iint p(y^*|y, \beta, h)p(\beta, h|y)d\beta dh.$$

- Lze ukázat:

$$y^*|y \sim t(\bar{\beta}x^*, \bar{s}^2\{1 + \bar{V}x^{*2}\}, \bar{\nu}).$$

- Bodová předpověď a s ní spojená nejistota (např. směrodatná odchylka predikce).

# Bayesovské průměrování modelů

- Předpokládáme, že známe  $p(M_j|y)$ , pro  $j = 1, 2$
- Bayesovské průměrování modelů v sobě zahrnuje průměrování přes všechny modely.
- Zákony pravděpodobnosti implikují:

$$p(y^*|y) = p(y^*|y, M_1)p(M_1|y) + p(y^*|y, M_2)p(M_2|y).$$

- Nezaměřovat na jediný model a pracovat např. s  $p(y^*|y, M_1) \times$  průměrování výsledků přes oba (všechny) modely s váhami danými posteriorními hustotou pravděpodobnosti.

# Obsah tématu

- 1 Lineární regresní model
- 2 Věrohodnostní funkce
- 3 Apriorní hustota
- 4 Posteriorní hustota
- 5 Neinformativní apriorní hustota
- 6 Porovnání modelů
- 7 Predikce
- 8 Empirická ilustrace

# Umělá data

- Umělá data pro ilustraci s  $N = 50$ ,  $\beta = 2$  a  $h = 1$ .
- Neinformativní prior a informativní prior s  $\underline{\beta} = 1.5$ ,  $\underline{V} = 0.25$ ,  $\nu = 10$  a  $\underline{s}^{-2} = 1$ .
- „Originální“ data obsahem *data\_NLRM1.mat* + skript *priklad\_NLRM1.m*.

# Apriorní a posteriorní charakteristiky parametru $\beta$

	Prior	Posterior	
	Informativní	(Inf. prior)	(Neinf. prior)
Stř. hodnota	1.500	1.794	1.862
Sm. odchylka*	0.559	0.199	0.216

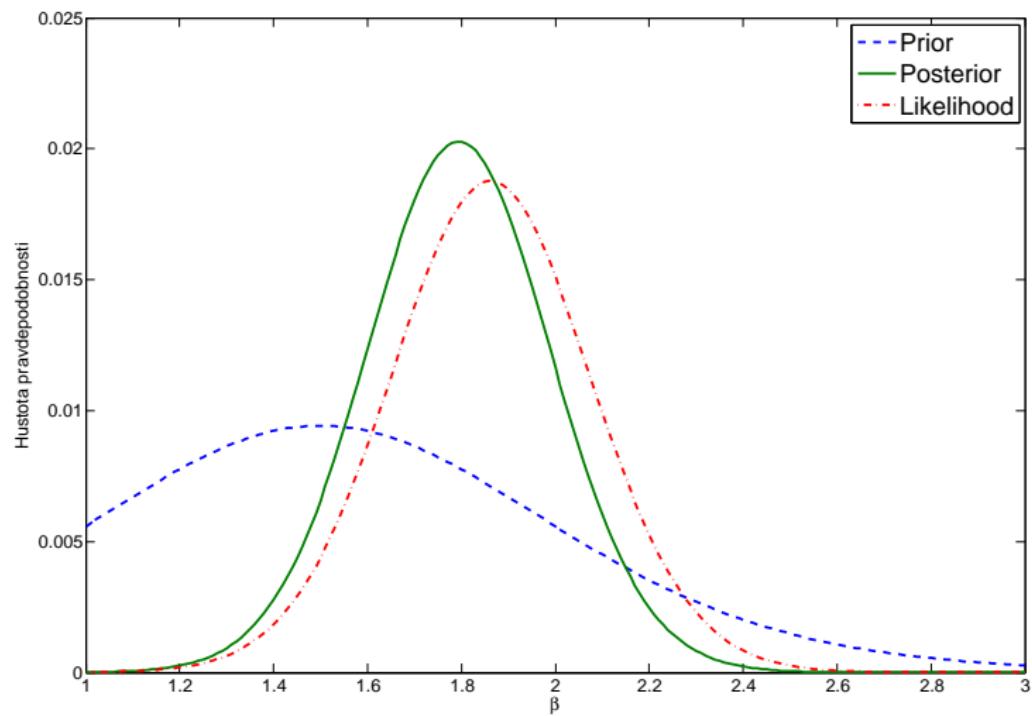
\* Jedná se o směrodatnou odchylku příslušného  $t$ -rozdělení, apriorní či posteriorní  $V$  tedy neudává přímo hodnotu rozptylu.

# Apriorní a posteriorní charakteristiky parametru $h$

	Prior	Posterior	
	Informativní	(Inf. prior)	(Neinf. prior)
Stř. hodnota	1.000	1.215	1.283
Sm. odchylka*	0.447	0.222	0.257

\* Jedná se o směrodatnou odchylku odpovídajícího gama rozdělení.

# Marginální apriorní a posteriorní hustoty pro parametr $\beta$ .



# Apriorní a posteriorní charakteristiky pro model jen s úrovňovou konstantou

	$\beta$		$h$	
	Prior	Posterior	Prior	Posterior
Stř. hodnota	1.500	0.990	1.000	0.917
Sm. odchylka	0.559	0.145	0.447	0.167

# Další výsledky

- Posteriorní podíl šancí je  $7346 \Rightarrow p(M_1|y) = 0.9999$  a  $p(M_2|y) = 0.0001$ .
- Predikce pro  $x^* = 0.5$ :
  - při využití informativního prioru je  $y^*|y \sim t(0.897, 0.833, 60)$ ,
  - V případě neinformativní apriorní hustoty je  $y^*|y \sim t(0.931, 0.7915, 50)$ .