

Přednáška 4 – Bayesianý odhad parametrů modelu

Obecný tvar

$$f(y_t | \psi_t, \Theta)$$

ψ_t – naměřená data

Θ – neznámé parametry:

- $\{\theta, r\}$ – regresní,
- $\Theta_{y_t | \psi_t}$ – diskrétní, θ – logistický

Bayesovské odhadování parametrů

Parametry – neznámá náhodná veličina

hp $f(\Theta | \text{průběžně měřená data})$ – bodové odhady

Označení:

$d_t = \{y_t, u_t\}$ – data v čase t

$d(t) = \{d_0, d_1, \dots, d_t\}$
stará data + d_t

Průběžný vývoj hp:

$$f(\Theta | d(0)) \underbrace{\Rightarrow}_{d_1} f(\Theta | d(1)) \underbrace{\Rightarrow}_{d_2} f(\Theta | d(2)) \Rightarrow \dots \underbrace{\Rightarrow}_{d_t} f(\Theta | d(t))$$

Obecně:

$$\text{apriorní hp } f(\Theta | d(t-1)) \underbrace{\Rightarrow}_{d_t} \text{aposteriorní hp } f(\Theta | d(t))$$

Bayesovo pravidlo

$$\underbrace{f(\Theta | d(t))}_{\text{aposteriorní}} \propto \underbrace{f(y_t | \psi_t, \Theta)}_{\text{model}} \underbrace{f(\Theta | d(t-1))}_{\text{apriorní}}$$

Odvození Bayesova pravidla pro náhodné veličiny A, B, C

$$\underbrace{f(A, B|C)}_{\text{sdužená hp}} = \begin{cases} f(A|B, C)f(B|C) = \text{podmíněná} \times \text{marginální} \\ \text{nebo} \\ f(B|A, C)f(A|C) \end{cases}$$

Obě strany:

$$f(A|B, C)f(B|C) = f(B|A, C)f(A|C)$$

Podmíněná hp:

$$f(B|A, C) = \frac{f(A|B, C)f(B|C)}{f(A|C)} \quad - \text{ Bayesovo pravidlo}$$

Význam:

$$\text{apriorní } f(B|C) \Rightarrow \text{aposteriorní } f(B|A, C)$$

Jmenovatel $f(A|C)$ je nezávislý na B (normalizační konstanta)

$$f(B|A, C) \underbrace{\propto}_{\text{úměrné}} f(A|B, C)f(B|C)$$

Použití pro odhad parametrů Θ

- $A = y_t$
- $B = \Theta$
- $C = \{d(t-1), u_t\}$
- $\{A, C\} = \{d_t, d(t-1)\} = d(t)$

$$f(\Theta|d(t-1)) \Rightarrow f(\Theta|d(t))$$

$$\underbrace{f(\Theta|d(t))}_{\text{aposteriorní}} = \frac{f(y_t|\psi_t, \Theta)f(\Theta|d(t-1))}{f(y_t|d(t-1))}$$
$$\propto \underbrace{f(y_t|\psi_t, \Theta)}_{\text{model}} \underbrace{f(\Theta|d(t-1))}_{\text{apriorní}}$$

Předpoklad – přirozené podmínky řízení:

Θ ↙
 u_t ↘
stejná data $d(t-1)$

$$f(\Theta|u_t, d(t-1)) = f(\Theta|d(t-1))$$
$$f(u_t|\Theta, d(t-1)) = f(u_t|d(t-1))$$

Použití řídicího vstupu v regresním vektoru:

$$\underbrace{f(\Theta|d(t))}_{\text{aposteriorní}} \propto \underbrace{f(y_t|\psi_t, \Theta)}_{\text{model}} \underbrace{f(u_t|d(t-1), \Theta)}_{\text{apriorní}} \underbrace{f(\Theta|d(t-1))}_{\text{apriorní}}$$

Reprodukovatelnost apriorní a aposteriorní hp

Bayesovo pravidlo – rekurze



Pro normální regresní model:

Konjugovaná hp – inverzní Gauss-Wischartovo (GiW) rozdělení

$$f(\Theta|d(t-1)) \propto r^{-0.5\kappa_{t-1}} \exp\left\{-\frac{1}{2r}[-1 \ \theta'] V_{t-1} \begin{bmatrix} -1 \\ \theta \end{bmatrix}\right\}$$

V_{t-1} – informační matice, κ_{t-1} – počítadlo

Bayesovo pravidlo pro odhad parametrů regresního modelu

$$\underbrace{f(\Theta|d(t))}_{\text{GiW}} \propto \underbrace{f(y_t|\psi_t, \Theta)}_{\text{normální}} \underbrace{f(\Theta|d(t-1))}_{\text{GiW}}$$

Update statistik: $V_t = V_{t-1} + D_t$, $\kappa_t = \kappa_{t-1} + 1$

Proč je to tak?

Model: $f(y_t|\psi_t, \Theta) = \frac{1}{\sqrt{2\pi}} r^{-0.5} \exp\left\{-\frac{1}{2r}(y_t - \psi_t'\theta)^2\right\}$

Úprava: $y_t - \psi_t'\theta = -1[-1 \ \theta'] \begin{bmatrix} y_t \\ \psi_t \end{bmatrix} = -1 \underbrace{\begin{bmatrix} y_t & \psi_t' \end{bmatrix}}_{\text{data}} \underbrace{\begin{bmatrix} -1 \\ \theta \end{bmatrix}}_{\text{parametry}}$

$$(y_t - \psi_t'\theta)^2 = [-1 \ \theta'] \underbrace{\begin{bmatrix} y_t \\ \psi_t \end{bmatrix} \begin{bmatrix} y_t & \psi_t' \end{bmatrix}}_{D_t - \text{datová matice}} \begin{bmatrix} -1 \\ \theta \end{bmatrix}$$

Model: $f(y_t|\psi_t, \Theta) = \frac{1}{\sqrt{2\pi}} r^{-0.5} \exp\left\{-\frac{1}{2r}[-1 \ \theta'] D_t \begin{bmatrix} -1 \\ \theta \end{bmatrix}\right\}$

Model a GiW – do Bayesova pravidla:

$$V_t = V_{t-1} + D_t$$

$$\kappa_t = \kappa_{t-1} + 1$$

Algebraický přepočítání statistik
aposteriori hp GiW

Po přepočtu statistik:

Rozklad informační matice:

$$V_t = \begin{bmatrix} V_y & V'_{y\psi} \\ V_{y\psi} & V_\psi \end{bmatrix}$$
$$= \begin{bmatrix} \cdot & \overline{\quad} \\ | & \begin{bmatrix} \dots & \dots \\ \dots & \dots \end{bmatrix} \end{bmatrix}$$

Bodový odhad regresních koeficientů a rozptylu:

$$\hat{\theta}_t = V_\psi^{-1} V_{y\psi}$$
$$\hat{\kappa}_t = \frac{V_y - V'_{y\psi} V_\psi^{-1} V_{y\psi}}{\kappa_t}$$

Algoritmus odhadu:

- 1 Pro čas $t = 0$ nastavíme počáteční statistiky V_0, κ_0
- 2 Pro čas $t = 1, 2, \dots$
 - 1 Měříme data $d_t = \{y_t, u_t\}$
 - 2 Datová matice D_t
 - 3 Update statistik V_t, κ_t
 - 4 Jdeme na krok 2.1
- 3 Rozklad informační matice V_t
- 4 Výpočet bodových odhadů parametrů $\hat{\theta}_t, \hat{\kappa}_t$

Využití pro odhad/predikci výstupu:

$$\hat{y}_t = \underbrace{\psi'_t \hat{\theta}_{t-1}}_{\text{střední hodnota}}$$

Program – odhad regresního modelu 1.řádu

```
nd=size(y,2); % počet dat
nps=5 % rozměr statistiky V
% počáteční statistiky
V=zeros(nps,nps); k=0;
for t=2:nd
    % rozšířený regresní vektor
    Ps=[y(t) u(t) y(t-1) u(t-1) 1];
    V=V+Ps'*Ps % update statistik
    k=k+1
end
% rozklad informační matice
Vy=V(1,1) % část Vy
Vyps=V(2:end,1) % část Vyps
Vps=V(2:end,2:end) % část Vps
% bodové odhady
theta_odhad=inv(Vps)*Vyps
r_odhad=(Vy-Vyps'*inv(Vps)*Vyps)/k
```

Predikce s regresním modelem

