


Přednáška 2 – Regresní model + model ve stavovém tvaru



- Náhodné veličiny na systému – spojité nebo diskrétní

Princip stochastického modelu se spojitými veličinami

Matematický popis vztahu y_t a jiných veličin + e_t

Příklad: Pozorovaný systém – úsek silnice s nehodou



- y_t – délka kolony [m] v čase t
- v_t – počet přijíždějících aut
- y_{t-1} – zpožděná hodnota
- parameter θ – průměrná délka auta (odhad)

Deterministický model: $y_t = y_{t-1} + \theta v_t$


Stochastický model: $y_t = y_{t-1} + \theta v_t + e_t \Rightarrow$ hp $f(y_t | y_{t-1}, v_t, \theta)$

Bílý šum s normálním rozdělením

Nemění své stochastické vlastnosti:

- Střední hodnota šumu $E[e_t] = 0$
- Konstantní rozptyl šumu $D[e_t] = r$
- Jednotlivé složky šumu – navzájem nezávislé

Příklad:



- Odlet letadel ± 2 min – **bílý šum**
- Zpoždění narůstá +2 min, +1 min, +2 min, ... – ~~bílý šum~~

hp šumu
$$f(e_t) = \frac{1}{\sqrt{2\pi r}} \exp\left\{-\frac{1}{2r} e_t^2\right\}$$

Princip stochastického modelu se spojitými veličinami

Příklad (délka kolony):

$$y_t = \underbrace{y_{t-1} + \theta v_t}_{\text{determ. část}} + \underbrace{e_t}_{\text{stochast. část}}$$

$$e_t = y_t - \underbrace{(y_{t-1} + \theta v_t)}_{\hat{y}_t}$$

Dosadíme $y_t - \hat{y}_t$ místo e_t do hp šumu: $f(e_t) = \frac{1}{\sqrt{2\pi r}} \exp\{-\frac{1}{2r} e_t^2\}$

$$f(y_t | y_{t-1}, v_t, \theta) = \frac{1}{\sqrt{2\pi r}} \exp\{-\frac{1}{2r} (y_t - \hat{y}_t)^2\}$$

střední hodnota \hat{y}_t , rozptyl r

model
↙ ↘
diferenční rovnice hp

Lineární regresní model s normálním šumem – obecně

$$y_t = \psi_t' \theta + e_t$$

Regresní vektor (data) $\psi_t = [u_t \ y_{t-1} \ u_{t-1} \ \dots \ y_{t-n} \ u_{t-n} \ 1]'$

Vektor regresních koeficientů (neznámé parametry)

$$\theta = [b_0 \ a_1 \ b_1 \ \dots \ a_n \ b_n \ k]'$$

Pořadí veličin a parametrů \Rightarrow aby platilo:

$$y_t = \psi_t' \theta + e_t = b_0 u_t + a_1 y_{t-1} + b_1 u_{t-1} + \dots + a_n y_{t-n} + b_n u_{t-n} + k + e_t,$$

- ψ_t a θ – sloupcové vektory
- Pro skalární y_t – v rovnici násobíme $\psi_t' \theta$ nebo $\theta' \psi_t$

$$[\dots] \begin{bmatrix} \cdot \\ \cdot \\ \cdot \end{bmatrix} = \cdot \begin{bmatrix} \cdot \\ \cdot \\ \cdot \end{bmatrix} [\dots] = \begin{bmatrix} \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \end{bmatrix}$$

- Řád modelu n – největší zpoždění výstupu
- Dynamický model ($n > 0$) vs. statický model ($n = 0$)

Příklady

Dynamický regresní model 1.řádu

$$y_t = b_0 u_t + a_1 y_{t-1} + k + e_t, \quad \psi_t = [u_t \ y_{t-1} \ 1]', \quad \theta = [b_0 \ a_1 \ k]'$$

Dynamický regresní model 2.řádu

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + e_t, \quad \psi_t = [y_{t-1} \ y_{t-2}]', \quad \theta = [a_1 \ a_2]'$$

Statický regresní model 0.řádu

$$y_t = b_2 u_{t-2} + b_3 u_{t-3} + k + e_t, \quad \psi_t = [u_{t-2} \ u_{t-3} \ 1]', \quad \theta = [b_2 \ b_3 \ k]'$$

Využití

Statický model – vztah veličin (spotřeba, emise, atd.)

Dynamický – vývoj (cena, rychlost, plyn, atd.) \Rightarrow **předpověď**


Lineární regresní model ve tvaru hp (skalární y_t) – obecně

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

Program – simulace regresního modelu 1.řádu

```
clear,clc,close
% vektor regr. koeficientů
theta=[1 0.6 -0.3 0.1];
r=0.1; % rozptyl
nd=500; % počet dat
% řídicí vstup
u=sin(50*(1:nd)/nd);
% počáteční podmínky
y(1)=1;
% cyklus
for t=2:nd
    % regresní vektor
    ps=[u(t) y(t-1) u(t-1) 1];
    % generování výstupu
    y(t)=theta*ps'+sqrt(r)*randn(1,1);
end
```

Simulace s regresním modelem



Regresní model ve stavovém tvaru

Regresní model vyššího řádu \Rightarrow stavový model (vždy 1.řádu)

$$x_t = Mx_{t-1} + Nu_t + \omega_t$$

x_t – stav (informace o dosavadním vývoji systému) – vektor

M, N – matice parametrů, ω_t – bílý normální šum

Příklad: $y_t = b_0 u_t + a_1 y_{t-1} + b_1 u_{t-1} + a_2 y_{t-2} + b_2 u_{t-2} + k + e_t$

$x_t = [y_t \ u_t \ y_{t-1} \ u_{t-1} \ 1]'$, $x_{t-1} = [y_{t-1} \ u_{t-1} \ y_{t-2} \ u_{t-2} \ 1]'$

Převod do stavového tvaru:

$$\underbrace{\begin{bmatrix} y_t \\ u_t \\ y_{t-1} \\ u_{t-1} \\ 1 \end{bmatrix}}_{x_t} = \underbrace{\begin{bmatrix} a_1 & b_1 & a_2 & b_2 & k \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}}_M \underbrace{\begin{bmatrix} y_{t-1} \\ u_{t-1} \\ y_{t-2} \\ u_{t-2} \\ 1 \end{bmatrix}}_{x_{t-1}} + \underbrace{\begin{bmatrix} b_0 \\ 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}}_N u_t + \underbrace{\begin{bmatrix} e_t \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}}_{\omega_t}$$

- Výhoda - máme v paměti pouze jeden zpožděný stav.