

# Přednáška 6 – Odhad diskrétního modelu

## Konjugovaná hp – Dirichletovo rozdělení (Dir)

$$f(\Theta | d(t-1)) \propto \prod_{\forall y|\psi} (\Theta_{y|\psi})^{\nu_{y|\psi; t-1}}$$

$\nu_{t-1}$  — tabulka,  $\nu_{y|\psi; t-1}$  — její prvky

### Bayesovo pravidlo

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

### Úprava diskrétního modelu

$$f(y_t | \psi_t, \Theta) = \prod_{\forall y|\psi} (\Theta_{y|\psi})^{\delta(y|\psi; y_t|\psi_t)}$$

### Kroneckerovo delta

$$\delta = \begin{cases} \text{číslo sloupce } y = y_t \\ \text{číslo řádku } \psi = \psi_t \\ 0 \text{ jinak} \end{cases}$$

Update statistik:  $\nu_{y|\psi; t} = \nu_{y|\psi; t-1} + \delta(y|\psi; y_t|\psi_t)$

Bodový odhad:  $\hat{\Theta}_{y|\psi; t} = \frac{\nu_{y|\psi; t}}{\sum_{i=1}^n \nu_{i|\psi; t}}$

# Algoritmus Bayesovského odhadování diskrétního modelu

- ① Pro čas  $t = 0$  nastavíme počáteční statistiku  $\nu_0$
- ② Pro čas  $t = 1, 2, \dots$ 
  - ① Měříme data  $d_t = \{y_t, u_t\}$
  - ② Update statistik  $\nu_{y|\psi;t} = \nu_{y|\psi;t-1} + \delta(y|\psi; y_t|\psi_t)$
  - ③ Jdeme na krok 2.1

- ③ Výpočet bodových odhadů parametrů

$$\underbrace{\hat{\Theta}_{y|\psi;t}}_{\text{model}} = \frac{\nu_{y|\psi;t}}{\sum_{i=1}^n \nu_{i|\psi;t}}$$

Příklad:

Systém: úsek silnice

$y_t \in \{1, 2, 3, 4\}$  – pohon automobilu

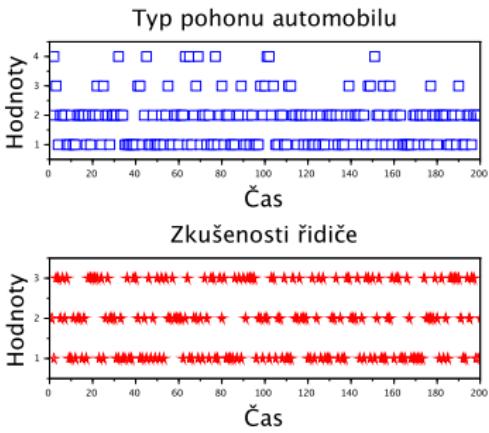
(benzínový, naftový, hybridní, elektrický)

$v_t \in \{1, 2, 3\}$  – zkušenosti řidiče

(začátečník, pokročilý, profesionál)

Čas  $t$  – minuty (cca 8h)

|       |   |   |   |   |   |   |   |   |     |
|-------|---|---|---|---|---|---|---|---|-----|
| $y_t$ | 2 | 4 | 3 | 1 | 2 | 2 | 2 | 1 | ... |
| $v_t$ | 2 | 1 | 3 | 3 | 2 | 3 | 2 | 3 | ... |



# Algoritmus, kroky 1–2.3

| $y_t$     | 1              | 2              | 3              | 4              |
|-----------|----------------|----------------|----------------|----------------|
| $\psi_t$  |                |                |                |                |
| $v_t = 1$ | $\Theta_{1 1}$ | $\Theta_{2 1}$ | $\Theta_{3 1}$ | $\Theta_{4 1}$ |
| $v_t = 2$ | $\Theta_{1 2}$ | $\Theta_{2 2}$ | $\Theta_{3 2}$ | $\Theta_{4 2}$ |
| $v_t = 3$ | $\Theta_{1 3}$ | $\Theta_{2 3}$ | $\Theta_{3 3}$ | $\Theta_{4 3}$ |

## Algoritmus:

①  $t = 0$ , dimenze počáteční statistiky  $\nu_0$

$$\dim(\nu_0) = \text{dim(model)} = 3 \times 4$$

`zeros(3, 4), ones(3, 4)`

②  $t = 1, 2, \dots$

① Měříme data:  $y_1 = 2, v_1 = 2$

② Update statistik

$$\nu_{y|\psi;1} = \nu_{y|\psi;0} + \delta(y|\psi; 2|2)$$

$$\nu_{2|2;1} = \nu_{2|2;0} + 1$$

③ Jdeme na krok 2.1 ...

$$\nu_{4|1;2} = \nu_{4|1;1} + 1 \dots$$

$$\nu_{3|3;3} = \nu_{3|3;2} + 1 \dots$$

**Diskrétní model**  $f(y_t|v_t, \Theta)$

$\psi_t = v_t$  – data

$\Theta$  – neznámé parametry

## Vývoj statistiky $\nu_t$ v čase

$\nu_0$

|   |   |   |   |
|---|---|---|---|
| 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 |

$\nu_1$

|   |   |    |   |
|---|---|----|---|
| 0 | 0 | 0  | 0 |
| 0 | 0 | +1 | 0 |
| 0 | 0 | 0  | 0 |

$\nu_2$

|   |   |   |    |
|---|---|---|----|
| 0 | 0 | 0 | +1 |
| 0 | 1 | 0 | 0  |
| 0 | 0 | 0 | 0  |

$\nu_3$

|   |   |    |   |
|---|---|----|---|
| 0 | 0 | 0  | 1 |
| 0 | 1 | 0  | 0 |
| 0 | 0 | +1 | 0 |

# Algoritmus, pokračování, kroky 2.3 – 3

$$t = 200, \nu_{2|2;200} = \nu_{2|2;199} + 1$$

|    |    |   |   |
|----|----|---|---|
| 33 | 29 | 7 | 8 |
| 17 | 33 | 8 | 2 |
| 31 | 26 | 6 | 0 |

$\nu_{200}$

- ③ Bodové odhady parametrů  $\hat{\Theta}_{y|\psi;t} = \frac{\nu_{y|\psi;t}}{\sum_{i=1}^n \nu_{i|\psi;t}}$

$$\hat{\Theta}_{1|1;t} = \frac{33}{33+29+7+8}, \quad \hat{\Theta}_{2|1;t} = \frac{29}{77}, \quad \hat{\Theta}_{3|1;t} = \frac{7}{77}, \quad \hat{\Theta}_{4|1;t} = \frac{8}{77}$$

$$\hat{\Theta}_{1|2;t} = \frac{17}{17+33+8+2}, \quad \hat{\Theta}_{2|2;t} = \frac{33}{60}, \quad \hat{\Theta}_{3|2;t} = \frac{8}{60}, \quad \hat{\Theta}_{4|2;t} = \frac{2}{60}$$

$$\hat{\Theta}_{1|3;t} = \frac{31}{31+26+6+0}, \quad \hat{\Theta}_{2|3;t} = \frac{26}{63}, \quad \hat{\Theta}_{3|3;t} = \frac{6}{63}, \quad \hat{\Theta}_{4|3;t} = \frac{0}{63}$$

**Výsledek** – model – podmíněná pf  $f(y_t|v_t, \Theta)$

| $y_t$     | 1         | 2         | 3         | 4         |
|-----------|-----------|-----------|-----------|-----------|
| $\psi_t$  |           |           |           |           |
| $v_t = 1$ | 0.4285714 | 0.3766234 | 0.0909091 | 0.1038961 |
| $v_t = 2$ | 0.2833333 | 0.55      | 0.1333333 | 0.0333333 |
| $v_t = 3$ | 0.4920635 | 0.4126984 | 0.0952381 | 0         |

Bodový odhad výstupu (predikce) – maximální  $\hat{\Theta}_{y|\psi;t}$  podle  $v_t$

# Program

```
% nahrajeme data
% počet dat
nd=200;
% počáteční statistiky
ni=zeros(max(v),max(y));
for t=1:nd
    ni(v(t),y(t))=ni(v(t),y(t))+1; % update statistiky
end
% bodový odhad pravděpodobnosti
theta_odhad=ni./ sum(ni,2);
```

# Odhad logistické regrese s výstupem $y_t \in \{0, 1\}$

## Logistický model

$$f(y_t | \psi_t, \theta) = \frac{\exp\{\psi_t' \theta\}}{1 + \exp\{\psi_t' \theta\}}$$

Nemá konjugované rozdělení  
 Bayesovo pravidlo není rekurzivní

## Bayesovo pravidlo

$$\underbrace{f(\theta | d(t))}_{\text{aposteriorní}} \propto L_t(\theta) \underbrace{f(\theta | d(t-1))}_{\text{apriorní}}$$

$$\begin{aligned} z_t &= \psi_t' \theta + e_t \\ \psi_t &= \underbrace{[v_{1;t} \ v_{2;t} \ v_{3;t} \ \dots \ 1]'}_{\text{data}} \\ \theta &= \underbrace{[c_1 \ c_2 \ c_3 \ \dots \ k]'}_{\text{neznámé parametry}} \end{aligned}$$

## Věrohodnostní funkce

$$L_t(\theta) = \prod_{\tau=1}^t f(y_\tau | \psi_\tau, \theta)$$

Odhad – jednorázový výpočet (offline)

## Metoda maximální věrohodnosti

$$\ln L_t(\theta) = \ln \prod_{\tau=1}^t \frac{e^{y_\tau z_\tau}}{1 + e^{z_\tau}}$$

$$\hat{\theta} = \arg \max_{\theta} \ln L_t(\theta)$$

Výhody – známé derivace  $\ln L_t(\theta)$

max – Newtonova metoda hledání extrémů

$$x_{i+1} = x_i - \frac{f'(x_i)}{f''(x_i)}$$

Odkaz na web

# Příklad – klasifikace s logistickou regresí

Systém: úsek dálnice

$y_t \in \{0, 1\}$  – nehoda (NE, ANO)

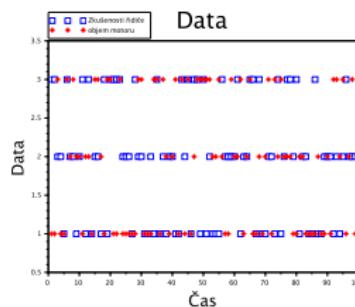
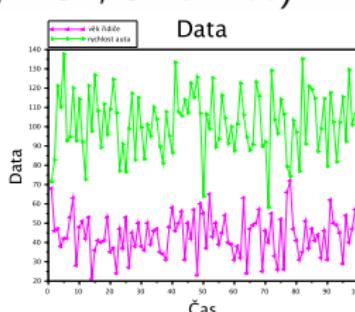
$v_{1;t}$  – věk řidiče

$v_{2;t} \in \{1, 2, 3\}$  – zkušenosti řidiče (začátečník, pokročilý, profesionál)

$v_{3;t} \in \{1, 2, 3\}$  – objem motoru auta (do 2 l; 2-3 l; 3 l a více)

$v_{4;t}$  – rychlosť auta [km/h]

| $v_{1;t}$ | $v_{2;t}$ | $v_{3;t}$ | $v_{4;t}$ | $y_t$ |
|-----------|-----------|-----------|-----------|-------|
| 42        | 3         | 3         | 92.676063 | 0     |
| 53        | 2         | 2         | 94.71603  | 1     |
| 63        | 2         | 3         | 120.06312 | 0     |
| 28        | 1         | 2         | 92.568545 | 0     |
| 48        | 2         | 2         | 114.32204 | 0     |
| ...       | ...       | ...       | ...       | ...   |



# Program

```
% nahrajeme data
% pro nominální data y
y=nominal(y);

% odhadování (trénovací data)
[B,dev,stats] = mnrfit(vL,yL)

% klasifikace (testovací data)
py = mnrvval(B,vT)

for i=1:size(py,1)
    [mx ix]=max(py(i,:)); % index max.
    yp(i)=ix-1; % otočíme na 0 a 1
end

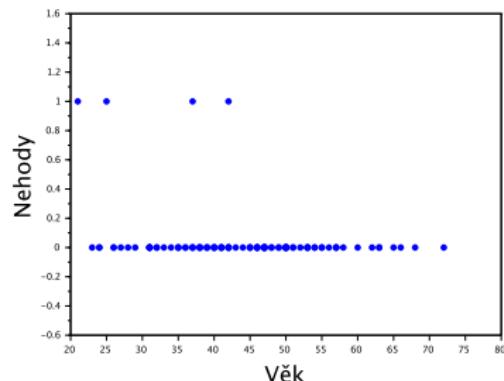
% Chyba predikce
PE=sum(categorical(yT)~=categorical(yp));
Acc=(PE*100) / size(yp,2);
```

## Výsledky

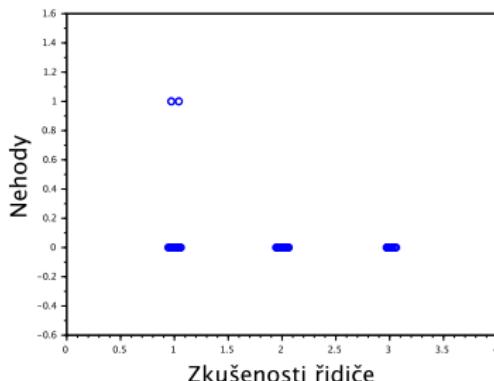
|     |    |    |           |    |
|-----|----|----|-----------|----|
| 68. | 3. | 1. | 71.374685 | 0. |
| 46. | 3. | 1. | 82.791157 | 0. |
| 47. | 2. | 3. | 121.15277 | 0. |
| 38. | 2. | 1. | 110.24375 | 0. |
| 42. | 1. | 1. | 137.60589 | 1. |
| 42. | 3. | 3. | 92.676063 | 0. |
| 53. | 2. | 2. | 94.71603  | 0. |
| 63. | 2. | 3. | 120.06312 | 0. |
| 28. | 1. | 2. | 92.568545 | 0. |
| 48. | 2. | 2. | 114.32204 | 0. |
| 51. | 3. | 1. | 92.129863 | 0. |
| 42. | 1. | 2. | 72.665487 | 0. |
| 53. | 3. | 2. | 121.30124 | 0. |
| 21. | 1. | 1. | 97.61611  | 1. |
| 36. | 2. | 3. | 126.78148 | 0. |

# Klasifikace s logistickou regresí

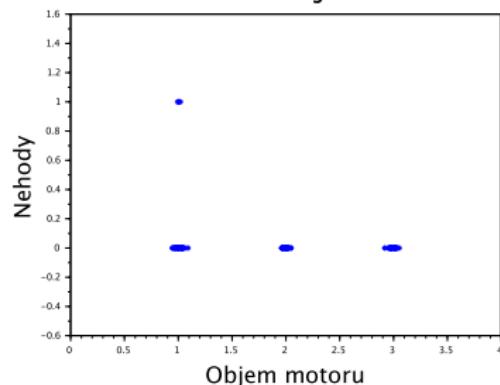
Klasifikace – věk



Klasifikace – zkušenosti řidiče



Klasifikace – objem motoru



Klasifikace – rychlosť

