

# Pravděpodobnostní usuzování v čase

## Markovské procesy

- příklad: diabetický pacient, hladina inzulinu, léky, jídlo
- předpokládáme, že se množina možných stavů  $S$  nemění v průběhu času
- předpokládáme diskrétní čas
- předpokládáme stacionární proces – pravidla přechodu z času  $t$  na  $t + 1$  nezáleží na čase

# Markovská vlastnost

- Markovská vlastnost: aktuální stav závisí jen na konečném počtu předchozích kroků ( $n$ -krocích,  $n > 0$ ), tj. stav v čase  $t + 1$  je nezávislý na stavu v čase  $t - n$ , při znalosti stavů v mezičase  $t, \dots, t - (i - 1)$ , tj.

$$S_{t+1} \perp\!\!\!\perp S_{t-n} | S_t, \dots, S_{t-(n-1)}$$

- Pro Markovský model 1. řádu (často jen Markovský proces, Markovský model)

$$S_{t+1} \perp\!\!\!\perp S_{t-1} | S_t$$

- Pro Markovský proces 2. řádu:

$$S_{t+1} \perp\!\!\!\perp S_{t-2} | S_t, S_{t-1}$$

Pro zadání MP 1. řádu tedy potřebujeme:

- $P(S_0)$
- $P(S_t | S_{t-1})$  pro jedno  $t$ , pro ostatní stejná

# Skrytý Markovský proces (HMM)

= částečně pozorovaný markovský proces

- Aktuální stav  $S$  nemůžeme pozorovat přímo, ale jen částečně
- pozorování  $O$  závisí pouze na aktuálním stavu, nikoli na minulosti či budoucnosti
- pro zadání definujeme  $P(O_t|S_t)$

Za daných předpokladů máme vlastně speciální bayesovskou síť, tj. pro každé konečné  $t$

$$P(S_0, S_1, \dots, S_t, O_1, \dots, O_t) = P(S_0) \cdot \prod_{i=1}^t P(S_i|S_{i-1}) \cdot P(O_i|S_i)$$

## Je proces markovský?

- jak který, často ano, nebo zhruba – náhodná procházka, stav pacienta, pozice robota
- pokud ne, tak buď můžeme zkusit zvýšit řád Markovského procesu nebo rozšířit množinu stavů
- nové stavy ale musíme také predikovat, tj. potřebujeme porozumět procesu, který modelujeme
- nebo mít dobré senzory, které nám dobře určí aktuální stav

Příklad: Chřipka trvá 7 dní.

Robot v mřížce: pozice, rychlost, stav baterie.

Vše je speciální případ propagace v bayesovské síti.

- Filtrování (=monitorování) – zajímá mě pravděpodobnostní rozložení (marginála) na aktuálním stavu  $P(S_t|o_1, \dots, o_t)$
- predikce – zajímá nás budoucí stav,  $P(S_{t+k}|o_1, \dots, o_t), k > 0$
- vyhlazování, pohled zpět: nová evidence nám přináší informace o tom, kde jsme byli v minulém čase,  $P(S_k|o_1, \dots, o_t), t > k \geq 0$
- nejpravděpodobnější průchod (vysvětlení)

$$\operatorname{argmax}_{s_0, \dots, s_t} P(s_0, \dots, s_t | o_0, \dots, o_t)$$

# Filtrování

Definuji:  $o_{1:t} = o_1, \dots, o_t$ .

Pravděpodobnost nového stavu při rozložení na starém:

$$\begin{aligned}P(S_{t+1}|o_{1:t}) &= \sum_{s_t} P(S_{t+1}|s_t, o_{1:t}) \cdot P(s_t|o_{1:t}) \\ &= \sum_{s_t} P(S_{t+1}|s_t) \cdot P(s_t|o_{1:t})\end{aligned}$$

Zpracování pozorování:

$$\begin{aligned}P(S_{t+1}|o_{1:t}, o_{t+1}) &= \frac{1}{P(o_{t+1}|o_{1:t})} \cdot P(o_{t+1}, S_{t+1}|o_1, \dots, o_t) \\ &= \alpha \cdot P(o_{t+1}|S_{t+1}, o_{1:t}) \cdot P(S_{t+1}|o_{1:t}) \\ &= \alpha \cdot P(o_{t+1}|S_{t+1}) \cdot P(S_{t+1}|o_{1:t})\end{aligned}$$

Dohromady:

$$P(S_{t+1}|o_{1:t}, o_{t+1}) = \alpha \cdot P(o_{t+1}|S_{t+1}) \cdot \sum_{s_t} P(S_{t+1}|s_t) \cdot P(s_t|o_{1:t})$$

## Vyhlazování (zpět)

Pro  $k: 0 \leq k < t$ .

$$\begin{aligned}P(S_k | o_{1:t}) &= P(S_k | o_{1:k}, o_{(k+1):t}) \\ &= \alpha \cdot P(S_k | o_{1:k}) \cdot P(o_{(k+1):t} | S_k, o_{1:k}) \\ &= \alpha \cdot f_{1:k} \cdot b_{(k+1):t}\end{aligned}$$

kde  $f_{1:k}$  je zpráva zleva (před  $k$ ),  $b_{(k+1):t}$  zpráva zprava (po  $k$ ).  
Zpětná zpráva:

$$\begin{aligned}P(o_{(k+1):t} | S_k) &= \sum_{s_{k+1}} P(o_{(k+1):t} | S_k, s_{k+1}) \cdot P(s_{k+1} | S_k) \\ &= \sum_{s_{k+1}} P(o_{(k+1):t} | s_{k+1}) \cdot P(s_{k+1} | S_k) \\ &= \sum_{s_{k+1}} P(o_{(k+1)}, o_{(k+2):t} | s_{k+1}) \cdot P(s_{k+1} | S_k) \\ &= \sum_{s_{k+1}} P(s_{k+1} | S_k) \cdot P(o_{(k+1)} | s_{k+1}) \cdot P(o_{(k+2):t} | s_{k+1})\end{aligned}$$

# Maticový zápis

$$T = P(S_{t+1}|S_t)$$
$$O_k = \begin{cases} P(o_k|S_i) & \text{na diagonále} \\ 0 & \text{jinak} \end{cases}$$

$f$ ,  $b$  bereme jako sloupcové vektory.

Potom se dá psát:

$$f_{1:(t+1)} = \alpha \cdot O_{t+1} T f_{1:t}$$
$$b_{(k+1):t} = T^T O_{k+1} b_{(k+2):t}$$

Navíc se dá počítat i v protisměru, tj.:

$$\alpha T^{-1} O_{t+1}^{-1} f_{1:(t+1)} = f_{1:t}$$
$$O_{t+1}^{-1} (T^T)^{-1} b_{(k+1):t} = b_{(k+2):t}$$



# Vyhlažování s konstantním zpožděním např. sledování letadla na radaru

- Mám pevné zpoždění  $d$ .
- Zajímá mě  $P(S_{t-d} | o_{1:t})$ , aniž bych propagovala od začátku a konce.
- tj.  $P(S_{t-d} | o_{1:t}) = \alpha f_{1:(t-d)} b_{(t-d+1):t}$
- Dopředná zpráva jako dříve.

Zpětná zpráva –  $d$  krát dosadím:

$$b_{(t-d+1):t} = \left( \prod_{i=t-d+1}^t T^T O_i \right) b_{(t+1):t} = B_{(t-d+1):t} \mathbf{1}$$

$$b_{(t-d+2):(t+1)} = \left( \prod_{i=t-d+2}^{t+1} T^T O_i \right) b_{(t+2):(t+1)} = B_{(t-d+2):(t+1)} \mathbf{1}$$

Odtud vidíme, že  $B$  můžeme průběžně aktualizovat:

$$B_{(t-d+2):(t+1)} = O_{t-d+1}^{-1} (T^T)^{-1} B_{(t-d+1):t} (T^T) O_{t+1}$$

## Nalezení nejpravděpodobnějšího průchodu

- Pozorované pozice:  $[a1, a2, b2, f6, c3, d3]$ . Jaký je nejpravděpodobnější průchod?
- používá se např. při zpracování řeči
- NENÍ ekvivalentní najít pro každý krok maximálně pravděpodobný stav! Taková posloupnost může být nemožná, tj. pravděpodobnosti nula.

# Viterbi algoritmus

## Nalezení nejpravděpodobnějšího průchodu

### Algoritmus

- Pro každý stav si pamatujeme pravděpodobnost nejpravděpodobnější cesty do něj.
- Na začátku známe apriorní  $P(s_1)$  jednotlivých stavů  $s_1$ .

$$\max_{s_1, \dots, s_t} P(s_1, \dots, s_t, S_{t+1} | o_{1:(t+1)}) =$$

$$\alpha P(o_{t+1} | S_{t+1}) \max_{s_t} P(S_{t+1} | s_t) \max_{s_1, \dots, s_{t-1}} P(s_1, \dots, s_t, S_t | o_{1:t})$$

- čili dopředně šířená zpráva místo sumy používá maximalizaci, tj. zpráva je

$$m_{1:t} = \max_{s_1, \dots, s_{t-1}} P(s_1, \dots, s_{t-1}, S_t | o_{1:t})$$

vždy vynásobíme  $P(S_{t+1} | s_t)$  a maximalizujeme přes  $s_t$ .

# Dynamické Bayesovské sítě

- Příklady jsme už viděli – nákresy Markovských procesů
- Zadáme BN v jednom časovém řezu plus vazby pro přechod z jednoho řezu do druhého a příslušné podmíněné pravděpodobnosti
- předpokládáme, že model časového řezu a přechodu se nemění s časem
- Matematicky je (diskrétní) DBN ekvivalentní HMM.
- výhoda je v rozloženém zadání: pro 20 binárních proměnných, každý 3 rodiče v předchozím čase, máme  $20 \cdot 2^3 = 160$  přechodových pravděpodobností, u HMM  $2^{20} \cdot 2^{20} = 2^{40}$ .
  - HMM potřebuje více prostoru
  - a více času při inferenci, musím matici vždy projít
  - především, odhad takového množství parametrů je velmi diskutabilní (pokud není definován generujícím procesem)
  - v rámci jednoho času je vztah DBN vs. HMM podobný, jako BN a plné rozložení na všech veličinách.

- pozice, rychlost, stav baterie, GPS – viz tabule
- model chyby senzorů – klasicky gausovské rozložení okolo správné hodnoty
- přechodné selhání senzoru – když někdo do robota narazí, senzor baterie hlásí nulu (vybitou baterii)
- gausovský chybový model hlásí vybitou baterii, robot přejde do krizového režimu a vypne se.
  - přidáme do modelu:  $P(BMeter_t = 0 | Battery_t = 5) = 0.03$
  - modely viz obrázky
  - výhoda: méně věří senzoru, vybitou baterii hlásí až po několika nulových měření, počet závisí na poměru predikce vybití baterie a pravděpodobnosti chyby senzoru.

- Např. u auta jedoucího do prudkého kopce nefunguje měřák paliva
- předchozí model nepomůže, do kopce jedeme docela dlouho
- řešení: modelujeme vadný senzor

# Přesná inference DBN

- rozvinout a spočítat jako BN; klasicky příliš velké
- smůla je, že "mezivýsledné tabulky" nemusí faktorizovat, tj. po čase máme jednu tabulku pro celý časový bod, tj. velikost  $O(d^{n+1})$  tabulky, složitost aktualizace  $O(d^{n+2})$ , pořád lepší než  $O(d^{2n})$  u HMM, ale obojí příliš náročné.

# Přibližný výpočet DBN

## částicové filtrování, particle filtering

- Pro BN se používá (mimo jiné) vážené vzorkování (likelihood weighting)
- s délkou času v DBN váhy exponenciálně klesají k nule, tj. potřebujeme stále exponenciálně větší vzorek; to nejde
- upravíme algoritmus



# Částicové filtrování

## přibližný výpočet DBN

- vstup:  $o$  pozorování,  $N$  požadovaný počet vzorků, DBN model
- statické:  $S$ , vektor vzorků, na počátku dle  $P(S_0)$ ,  $W$  vektor vah
- for  $i = 1$  to  $n$ 
  - $S[i] \leftarrow \text{sample from } P(S_1 | S_0 = S[i])$
  - $W[i] \leftarrow P(o | S_1 = S[i])$
- $S \leftarrow \text{vážený vzorek s navracením}(N, S, W)$

Pro  $N$  jdoucích k nekonečnu konverguje ke přesnému vyhodnocení.

- Nejmenší jednotka: **foném**
- Liší se podle způsobu a místa tvoření, artikulujícího orgánu nebo sluchového dojmu (fonologie). Celkem ve svět. jazycích jen cca. 12 diferenciálních příznaků.
- Počet fonémů v jazycích je 12 až 60. (ČJ 36, AJ 42, RJ 40).
- Fonémy se spojují co posloupností. Ty lze dělit na slabiky, slabiky tvoří slova. Slovanské jazyky cca. 2500–3000 slabik, 45000 – 50000 slov.
- Člověk při hovoru vysloví 80–130 slov za minutu, tj. cca 10 fonémů za sekundu. Při informaci 3–4 bity na foném je přenos informace 30–40 bit/s; člověk je schopen zpracovat informaci o rychlosti maximálně 50 bit/s.
- V češtině je fonologicky funkční symbol pauza pro hranici mezi slovy, v angličtině ne.

# Zpracování signálu

- Snímáme v určité frekvenci (sampling) 8–20 kHz
- kvantování – diskretizujeme velikost signálu 12–14 bitů
- příznaky (features) – např. krátkodobá energie či častěji krátkodobá intenzita, krátkodobá funkce středního počtu průchodů signálu nulou, autokorelační funkce, a Fourierovy transformace pro frekvenční oblast.
- vektorová kvantizace – hodně kombinací příznaků reprezentují jedním kódem, tím zmenším prostor, ve kterém pak budu pracovat (např. 256 kódů).

# Pravděpodobnostní přístup

- Skryté Markovské procesy
- základ – Vintsyuk – každé slovo vlastní model, 40–50 stavů, odpovídajících průměrnému počtu mikrosegmentů ve slově
- těžko by se trénovalo obecně, proto se učí modely pro jednotlivé fonémy; z modelů pro fonémy složí slovo (transkripce slova pro češtinu celkem snadná)

# Viterbiův algoritmus

Skrytý Markovský model  $P(S_1), P(S_{t+1}|S_t), P(O_t|S_t)$

$S$  má stavy  $i = 1, \dots, N$

hledám maximálně pravděpodobný průchod.

- 1** Inicializace:  $\delta_1(i) \leftarrow P(S_1 = i) \cdot P(O_1 = o_1 | S_1 = i)$   
 $\psi_1 = 0$
- 2** Rekurze v čase  $t = 2, \dots, T$  a nový stav  $j = 1, \dots, N$   
 $\delta_t(j) \leftarrow \max_i \delta_{t-1}(i) \cdot P(S_{t+1} = j | S_t = i) \cdot P(O_t = o_t | S_t = j)$   
 $\psi_t = \operatorname{argmax}_i [\delta_{t-1}(i) \cdot P(S_{t+1} = j | S_t = i)]$
- 3** Výsledná pravděpodobnost a index maximálně pravděpodobného stavu v čase  $T$  jsou:  
 $P^* = \max_i [\delta_T(i)]$   
 $i^* = \operatorname{argmax}_i [\delta_T(i)]$  O nejpravděpodobnější průchod zpětně vystopujeme z  $\psi$ ,  $i_t^* = \psi_{t+1}(i_{t+1}^*)$

Pozn: nejpravděpodobnější průchod není to samé co nejpravděpodobnější posloupnost fonémů.

- Baum–Welchův algoritmus
- v zásadě EM algoritmus, klasická metoda učení modelu se skrytými parametry ve Strojovém učení.