


Umělá inteligence II



Roman Barták, KTIML


roman.bartak@mff.cuni.cz
<http://ktiml.mff.cuni.cz/~bartak>



5

Na úvod

- Umíme **reprezentovat neurčitost v čase**
 - přechodový $\mathbf{P}(\mathbf{X}_t | \mathbf{X}_{t-1})$ a sensorický model $\mathbf{P}(\mathbf{E}_t | \mathbf{X}_t)$
 - Markovské předpoklady
- Typické **řešené úlohy**
 - filtrace: $\mathbf{P}(\mathbf{X}_t | \mathbf{e}_{1:t})$
 - predikce: $\mathbf{P}(\mathbf{X}_{t+k} | \mathbf{e}_{1:t})$ pro $k > 0$
 - vyhlazování: $\mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:t})$ pro $k: 0 \leq k < t$
 - nejpravděpodobnější průchod: $\operatorname{argmax}_{\mathbf{x}_{1:t}} \mathbf{P}(\mathbf{x}_{1:t} | \mathbf{e}_{1:t})$
- **Skryté Markovské modely (HMM)**
 - speciální případ s jedinou náhodnou a sensorickou proměnnou
 - efektivní řešení úloh pomocí maticových operací




Dynamické Bayesovské sítě

■ Dynamická Bayesovská síť (DBN) reprezentuje temporální pravděpodobnostní model

□ skládá se z opakujících se vrstev proměnných

- stačí tedy popsat první vrstvu
- apriorní distribuci $P(\mathbf{X}_0)$
- přechodový model $P(\mathbf{X}_1 | \mathbf{X}_0)$
- sensorický model $P(\mathbf{E}_1 | \mathbf{X}_1)$




□ dle Markovských předpokladů má každá proměnná rodiče buď ve stejné nebo předchozí vrstvě

Umělá inteligence II, Roman Barták

DBN vs. HMM

- skrytý Markovský model je speciálním případem dynamické Bayesovské sítě
- podobně lze (diskrétní) Bayesovskou síť kódovat do skrytého Markovského modelu

□ jedna proměnná jejíž hodnoty jsou n-tice hodnot původních n proměnných




Jaký je tedy rozdíl?

- stejný jako rozdíl Bayesovské sítě a úplné sdružené distribuce
- DBN s 20 Booleovskými náhodnými proměnnými, každá má tři rodiče
 - pro přechodový model potřebujeme $20 \times 2^3 = 160$ pravděpodobností
- skrytý Markovský model s jedinou náhodnou proměnnou s 2^{20} stavy
 - pro přechodový model potřebujeme $2^{20} \times 2^{20} \approx 10^{12}$ pravděpodobností
 - tj. více paměti a pomalejší odvozování u HMM

Umělá inteligence II, Roman Barták

Modelový příklad

- Uvažujme příklad složitější DBN popisující chování baterií poháněného robota



- potřebujeme zachytit **polohu** robota $\mathbf{X}_t = (X_t, Y_t)$, jeho **rychlost** $\dot{\mathbf{X}}_t = (\dot{X}_t, \dot{Y}_t)$ a **stav baterie**
 - další poloha záleží na rychlosti a původní poloze
 - další rychlost záleží na předchozí rychlosti a stavu baterie
- pozorovat můžeme polohu například prostřednictvím **GPS** Z_t
- podobně můžeme pozorovat stav baterie pomocí **senzoru** $BMeter_t$


Umělá inteligence II, Roman Barták

Vadné senzory

- **Přesný senzor** má v sensorickém modelu na diagonále 1 a jinde 0.

Takové senzory ale nejsou časté. Přesnější model používá mírnou odchylku podobně jako u Gaussova rozložení

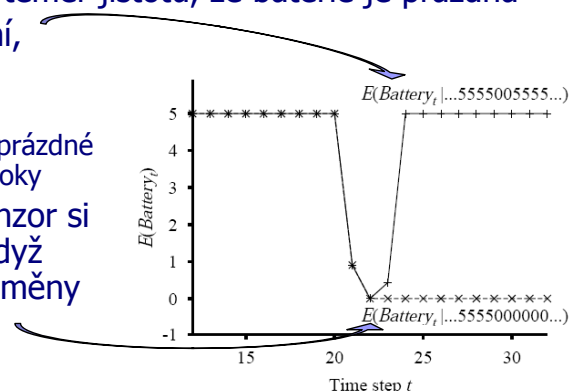
– **Gaussův chybový model**



- **Reálné senzory** ale **chybují** a někdy vykazují úplně jinou hodnotu (např. ukazatel obsahu nádrže auta může při náklonu ukazovat prázdnou nádrž).

Potom se Gaussův chybový model chová jinak než bychom chtěli.

- po dvou chybných zprávách máme téměř jistotu, že baterie je prázdná
- pokud potom přijde korektní měření, model najednou hlásí plnou baterii (**dočasná porucha**)
 - mezitím jsme ale na základě údaje o prázdné baterii mohli podniknout nevhodné kroky
- pokud dále chodí chybné údaje, senzor si je „jistý“, že baterie je prázdná, i když pravděpodobnost takové skokové změny je velmi malá (**trvalá porucha**)

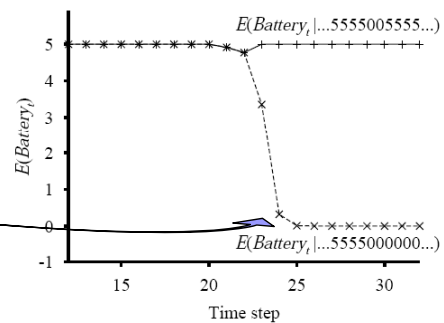


Umělá inteligence II, Roman Barták

Vadné senzory

oprava dočasné poruchy

- Nejjednodušší úprava modelu pro zachycení poruchy spočívá v přidání nenulové pravděpodobnosti zcela mylného měření.
 $P(\text{BMeter}_t=0 \mid \text{Battery}_t=5) = 0.03$
- Hovoříme o **modelu dočasných poruch**.
- Tento model přidá do uvažování jisté zpoždění / **setrvačnost**, takže robot dojde k závěru o prázdné baterii později.
- Nakonec si ale stejně myslí, že baterie je prázdná, takže to neřeší problém s trvale vadným senzorem!





Umělá inteligence II, Roman Barták

Vadné senzory

oprava trvalé poruchy

- Pro **model trvalých poruch** použijeme novou skrytou proměnnou BMBroken indikující stav senzoru.
- Pokud je senzor OK, chová se přechodový model stejně.
- Pokud dojde k trvalé poruše (kombinace možnosti poruchy a delší dobu přicházejících „podivných“ údajů ze senzoru), přepne se proměnná BMBroken trvale na 1 (chybný senzor) a zprávy o stavu baterie se řídí „normálním“ průběhem vybíjení.




Umělá inteligence II, Roman Barták

Odvozování v DBN

exaktní metody

- DBN je v podstatě **Bayesovská síť**, takže pro odvozování můžeme použít stejné techniky.
- Přesněji, nejprve je potřeba DBN **rozvinout** podle získaných pozorování



a potom můžeme použít známé metody odvozování.


- Tento **naivní přístup** má ale zásadní nevýhodu v tom, že čas odvozování se z každým dalším pozorováním prodlužuje.
- Můžeme použít **inkrementální metody**, kdy stačí v paměti udržovat dva časové řezy.
 - podobné jako **eliminace proměnných**
 - špatná zpráva je, že paměť pro pamatování si posledního výsledku je exponenciální v počtu proměnných ve vrstvě $O(d^{n+k})$, což se projeví i v času inference (n-počet proměnných, d-počet hodnot, k-počet rodičů)

Umělá inteligence II, Roman Barták

Odvozování v DBN

aproximační metody

- Můžeme zkusit aproximační metody, z nichž **vážení věrohodností** se lépe adaptuje na DBN.
- Náhodné proměnné budeme vzorkovat od času 0 po čas posledního pozorování.
 - každý vzorek musí projít celou sítí
 - můžeme vzít N vzorků a projít s nimi sítí najednou (podobné jako propagace zprávy u exaktních metod)



- Je tady ale **problém!**
 - **vzorky jsou generovány nezávisle na pozorování!**
 - to obvykle vede k malé váze vzorků a potřebě generovat mnohem větší počet vzorků
 - potřebný **počet vzorků roste exponenciálně s časem**
 - pokud používáme konstantní počet vzorků a vzorky jen inkrementálně rozšiřujeme, klesá s časem přesnost metody

Umělá inteligence II, Roman Barták

Odvozování v DBN

částicové filtrování

- Při generování vzorků se potřebujeme držet v oblastech s velkou pravděpodobností stavů.
- **Částicové filtrování (particle filtering)** množinu vzorků (částic) po každém kroku převzorkuje.
 - začneme s N vzorky **vzorkovanými** podle $\mathbf{P}(\mathbf{X}_0)$
 - každý vzorek **propagujeme** vpřed výběrem hodnoty \mathbf{x}_{t+1} podle $\mathbf{P}(\mathbf{X}_{t+1} | \mathbf{x}_t)$
 - vzorek je **zvážen** podle pozorování $\mathbf{P}(\mathbf{e}_{t+1} | \mathbf{x}_{t+1})$
 - populace vzorků je **převzorkována** podle vah
 - vybereme N vzorků, kde pravděpodobnost výběru vzorku je dána jeho vahou (nové vzorky nemají váhu)


Umělá inteligence II, Roman Barták

Odvozování v DBN

algoritmus částicového filtrování

```
function PARTICLE-FILTERING( $e, N, \text{dbn}$ ) returns a set of samples for the next time step
  inputs:  $e$ , the new incoming evidence
          $N$ , the number of samples to be maintained
          $\text{dbn}$ , a DBN with prior  $\mathbf{P}(\mathbf{X}_0)$ , transition model  $\mathbf{P}(\mathbf{X}_1 | \mathbf{X}_0)$ , and sensor model
 $\mathbf{P}(\mathbf{E}_1 | \mathbf{X}_1)$ 
  static:  $S$ , a vector of samples of size  $N$ , initially generated from  $\mathbf{P}(\mathbf{X}_0)$ 
  local variables:  $W$ , a vector of weights of size  $N$ 

  for  $i = 1$  to  $N$  do
     $S[i] \leftarrow$  sample from  $\mathbf{P}(\mathbf{X}_1 | \mathbf{X}_0 = S[i])$ 
     $W[i] \leftarrow \mathbf{P}(e | \mathbf{X}_1 = S[i])$ 
   $S \leftarrow$  WEIGHTED-SAMPLE-WITH-REPLACEMENT( $N, S, W$ )
  return  $S$ 
```



Umělá inteligence II, Roman Barták

Odvozování v DBN

korektnost částicového filtrování


- Předpokládejme, že vzorky v kroku t jsou konzistentní s pravděpodobnostní distribucí $N(\mathbf{x}_t | \mathbf{e}_{1:t}) / N = P(\mathbf{x}_t | \mathbf{e}_{1:t})$
- Po **propagaci** do času $t+1$ dostaneme $N(\mathbf{x}_{t+1} | \mathbf{e}_{1:t}) = \sum_{\mathbf{x}_t} P(\mathbf{x}_{t+1} | \mathbf{x}_t) N(\mathbf{x}_t | \mathbf{e}_{1:t})$
- Celková **váha** všech vzorků pro stav \mathbf{x}_{t+1} je $W(\mathbf{x}_{t+1} | \mathbf{e}_{1:t+1}) = P(\mathbf{e}_{t+1} | \mathbf{x}_{t+1}) N(\mathbf{x}_{t+1} | \mathbf{e}_{1:t})$
- Po **převzorkování** dostaneme
$$\begin{aligned} N(\mathbf{x}_{t+1} | \mathbf{e}_{1:t+1}) / N &= \alpha W(\mathbf{x}_{t+1} | \mathbf{e}_{1:t+1}) \\ &= \alpha P(\mathbf{e}_{t+1} | \mathbf{x}_{t+1}) N(\mathbf{x}_{t+1} | \mathbf{e}_{1:t}) \\ &= \alpha P(\mathbf{e}_{t+1} | \mathbf{x}_{t+1}) \sum_{\mathbf{x}_t} P(\mathbf{x}_{t+1} | \mathbf{x}_t) N(\mathbf{x}_t | \mathbf{e}_{1:t}) \\ &= \alpha' P(\mathbf{e}_{t+1} | \mathbf{x}_{t+1}) \sum_{\mathbf{x}_t} P(\mathbf{x}_{t+1} | \mathbf{x}_t) P(\mathbf{x}_t | \mathbf{e}_{1:t}) \\ &= P(\mathbf{x}_{t+1} | \mathbf{e}_{1:t+1}) \end{aligned}$$



Umělá inteligence II, Roman Barták

Motivační příklad

- Kde se nachází pták?



- Jakou techniku použijeme pro řešení?
 - filtraci (zjišťujeme aktuální polohu na základě dosavadních pozorování)
 - potřebujeme ale pracovat se spojitými náhodnými proměnnými (poloha a rychlost letu)



Spojité proměnné


- Dosud jsme pracovali pouze s diskrétními proměnnými, kde se pravděpodobnostní distribuce popisovala tabulkou.
- **Jak pracovat se spojitými proměnnými?**

- **diskretizace**

- množina hodnot se rozdělí do disjunktních intervalů
- často vede ke ztrátě přesnosti a velkým tabulkám

- **přímé metody použitím standardních pravděpodobnostních rozdělení**

- Gaussovo (normální) rozdělení
 - často používané rozdělení pravděpodobnosti spojité proměnné
 - popsané střední hodnotou μ a rozptylem σ^2



$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Umělá inteligence II, Roman Barták

Spojité proměnné

podmíněné pravděpodobnosti

- Jak popisovat podmíněné pravděpodobnosti v Bayesovské síti?

- pro závislost **spojité proměnné na spojitě proměnné** se často používá lineární Gaussovo rozdělení

- střední hodnota závisí lineárně na parametrech rodiče
- rozptyl se nemění

$$\begin{aligned} P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy} = \text{true}) \\ &= N(a_t h + b_t, \sigma_t)(c) \\ &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right) \end{aligned}$$

- pro závislost **spojité proměnné na diskrétní proměnné**

- enumerace (pro jednotlivé hodnoty diskrétní proměnné se definují samostatná rozdělení)

- pro závislost **diskrétní proměnné na spojitě proměnné**

- měkký práh

probit (probability unit) rozdělení


$$\Phi(x) = \int_{-\infty}^x N(0, 1)(x) dx$$

$$P(\text{Buys?} = \text{true} | \text{Cost} = c) = \Phi\left(\frac{-c + \mu}{\sigma}\right)$$

logit (logistic function) rozdělení

$$P(\text{Buys?} = \text{true} | \text{Cost} = c) = \frac{1}{1 + \exp\left(-2\frac{-c + \mu}{\sigma}\right)}$$

- probit rozdělení lépe vystihuje reálné situace (je to jako pevný práh, jehož poloha je dána s Gaussovskou chybou)
- logit rozdělení je „protáhlejší“ (long tail), snáze se počítá



Umělá inteligence II, Roman Barták

- Vraťme se k příkladu s letem ptáka, který popíšeme pomocí dynamické Bayesovské sítě.


- náhodné proměnné jsou poloha a rychlost ptáka

- další poloha závisí na předchozí poloze a rychlosti formou lineárního Gaussova rozdělení


$$P(X_{t+\Delta} = x_{t+\Delta} \mid X_t = x_t, \dot{X}_t = \dot{x}_t) = N(x_t + \dot{x}_t \Delta, \sigma^2) (x_{t+\Delta})$$

- pozorujeme polohu ptáka Z_t

- opět můžeme předpokládat použití Gaussova rozdělení



Umělá inteligence II, Roman Barták



- Použití Gaussova rozdělení dává zajímavé vlastnosti pro filtraci, predikci a vyhlazování.
- Je-li současné rozdělení $\mathbf{P}(\mathbf{X}_t \mid \mathbf{e}_{1:t})$ Gaussovo a přechodový model $\mathbf{P}(\mathbf{X}_{t+1} \mid \mathbf{x}_t)$ je lineárně Gaussovský, potom $\mathbf{P}(\mathbf{X}_{t+1} \mid \mathbf{e}_{1:t})$ je také Gaussovo rozdělení.

$$P(\mathbf{X}_{t+1} \mid \mathbf{e}_{1:t}) = \int_{\mathbf{x}_t} P(\mathbf{X}_{t+1} \mid \mathbf{x}_t) P(\mathbf{x}_t \mid \mathbf{e}_{1:t}) d\mathbf{x}_t$$

- Je-li $\mathbf{P}(\mathbf{X}_{t+1} \mid \mathbf{e}_{1:t})$ Gaussovo rozdělení a sensorický model $\mathbf{P}(\mathbf{e}_{t+1} \mid \mathbf{X}_{t+1})$ je lineárně Gaussovský, potom $\mathbf{P}(\mathbf{X}_{t+1} \mid \mathbf{e}_{1:t+1})$ je také Gaussovo rozdělení.




$$P(\mathbf{X}_{t+1} \mid \mathbf{e}_{1:t+1}) = \alpha P(\mathbf{e}_{t+1} \mid \mathbf{X}_{t+1}) P(\mathbf{X}_{t+1} \mid \mathbf{e}_{1:t})$$

- Můžeme proto používat techniku posílání zpráv

Kalmanův filtr

aplikace

- Klasickou aplikací Kalmanova filtru je **sledování** letadel a raket na radaru.
- Používá se také na **rekonstrukci drah** částic ve fyzice elementárních částic případně na sledování mořských proudů.
- Aplikace ale sahají i mimo oblast sledování pohybu, obecně se hodí pro libovolný systém popsaný spojitými náhodnými proměnnými a měření se šumem (chemické provozy, ekosystémy, ekonomiky ...).




Umělá inteligence II, Roman Barták

Kalmanův filtr


problémy

- Kalmanův filtr funguje pro modely s lineárními přechody a Gaussovskou chybou.
- **Co když se ale objekt nechová zcela lineárně?**
příklad: ve směru letu ptáka je strom

Kalmanův filtr



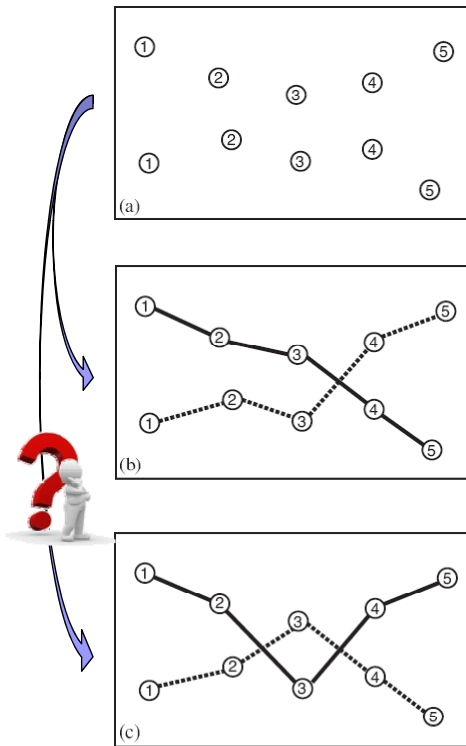
realističtější model



- Možné řešení: **přepínací (switching) Kalmanův filtr**
 - uvažuje se paralelně několik Kalmanových filtrů pro různé situace (přímý let, manévr vlevo, manévr vpravo)
 - vezme se vážený součet předpovědí, kde váha popisuje, jak dobře situace odpovídá datům
 - je to vlastně **rozšíření DBN o novou náhodnou proměnnou**

Umělá inteligence II, Roman Barták

Sledování více objektů



- Zatím jsme mlčky předpokládali, že sledujeme jeden objekt, ale v praxi často sledujeme **více objektů najednou** (např. radary).

■ Kde je problém?

- Nevíme, které pozorování patří jakému objektu!

Umělá inteligence II, Roman Barták

Sledování více objektů

používané metody

Problém asociace dat:

nevíme, které pozorování patří jakému objektu

- Při exaktním uvažování tedy musíme **vysčítat** pravděpodobnosti přes všechna **možná přiřazení**
 - pro jeden časový okamžik a n objektů je to $n!$ možností
 - pro T časových okamžiků máme $(n!)^T$ možností
- Používají se spíše **aproximační metody**
 - v každém kroku se např. vybere nejlepší přiřazení objektů k pozorováním
 - **metoda nejbližšího souseda** (spáruje se pozorování s objektem, který má nejbližší předpovězenou polohu)
 - přesnější metoda je vzít přiřazení, které **maximalizuje sdruženou pravděpodobnost** pozorování při daných předpovězených polohách
 - výběr špatného přiřazení v jednom okamžiku znehodnocuje budoucí přiřazení
 - **částicové filtrování** (udržuje větší množinu možných přiřazení)
 - **MCMC** (prochází prostor možných přiřazení)

Umělá inteligence II, Roman Barták

Situace v praxi je ještě komplikovanější.

- **falešné alarmy**
(pozorování neodpovídá žádnému objektu)
- **chyba detekce**
(existující objekt není pozorován)
- **nové a mizející objekty**
(objevují se nové objekty a jiné objekty mizí)

