

Interakce člověk–počítač v přirozeném jazyce (ICP)

LS 2013 — Markovové modely, modelace fonů

Tino Haderlein, Elmar Nöth

Katedra informatiky a výpočetní techniky (KIV)
Západočeská univerzita v Plzni

Lehrstuhl für Mustererkennung (LME)
Friedrich-Alexander-Universität Erlangen-Nürnberg

Rozpoznávání jednotlivých slov

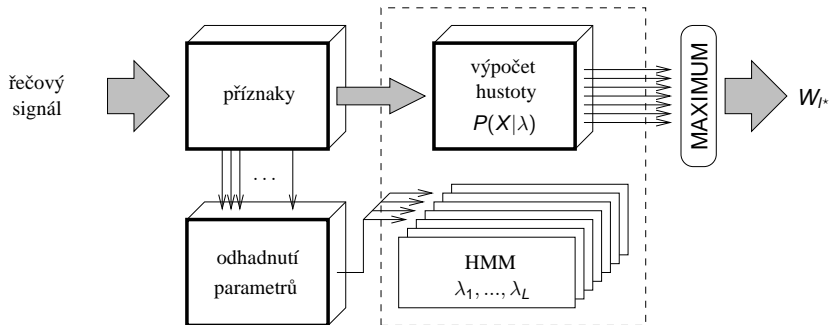
- Ja dána množina slov $\mathcal{W} = \{W_1, \dots, W_L\}$.
- Je pozorována posloupnost příznakových vektorů $\mathbf{X} = \mathbf{x}_1, \dots, \mathbf{x}_T$ (promluva).
- Které slovo bylo řečeno?

→ rozhodnutí podle Bayesovy věty

$$l^* = \underset{l}{\operatorname{argmax}} P(W_l | \mathbf{X}), \quad \text{kde} \quad P(W_l | \mathbf{X}) = \frac{P(\mathbf{X} | W_l) \cdot P(W_l)}{P(\mathbf{X})}$$

- A priori pravděpodobnosti slov $P(W_l)$ se odhadují vypočítáním testovacího vzorku.
- $P(\mathbf{X} | W_l)$ nelze aproximovat hustotou normalního rozdělení, protože délka T promluvy je variabilní.
- Ale $P(\mathbf{X} | W_l)$ lze odhadnout pomocí skrytých Markovových modelů (Hidden Markov Models, HMM).

Rozpoznávání jednotlivých slov



Hidden Markov Models

Úloha: Vypočítej pravděpodobnost $P(x_1, x_2, \dots, x_T)$ pro libovolné hodnoty délky T .

- Problém 1: Náhodný proces, který tvoří x_t , ve skutečnosti není stacionární, tj. $P(x_t)$ je např. závislé na mluvené hlásce; proto není možné snadně počítat
$$P(x_1, x_2, \dots, x_T) = \prod_{t=1}^T P(x_t).$$
- Problém 2: x_t mohou být příznakové vektory, proto je např. počítání $P(x_{t-1}, x_t)$ náročné; když má x_t 24 dimenzí, jsou pro 10 příznakových vektorů nutné 240-dimenzionální hustoty.

Hidden Markov Models

Trik 1: Uvedení diskretních, skrytých stavů $q_t \in \{s_1, \dots, s_N\}$

- x_t jsou závislé jen na aktuálním stavu q_t :

$$P(x_1, x_2, \dots, x_T) = \sum_{q_1, \dots, q_T} P(q_1) \cdot P(x_1|q_1) \cdot \prod_{t=2}^T P(x_t|q_t) \cdot P(q_t|q_1, \dots, q_{t-1})$$

Trik 2: Předpokládej, že náhodný proces, který tvoří q_t , je stacionární Markovův proces prvního řádu, tj. platí

$$P(q_t | q_1, \dots, q_{t-1}) = P(q_t | q_{t-1}).$$

- Pak lze vypočítat $P(x_1, x_2, \dots, x_T)$ takto:


$$P(x_1, x_2, \dots, x_T) = \sum_{q_1, \dots, q_T} P(q_1) \cdot P(x_1|q_1) \cdot \prod_{t=2}^T P(x_t|q_t) \cdot P(q_t|q_{t-1})$$

Pro vypočítání $P(x_1, x_2, \dots, x_T)$ jsou tedy nutné jen hustoty

$P(x_t|q_t)$, $q_t \in \{s_1, \dots, s_N\}$ a pravděpodobnosti $P(q_t|q_{t-1})$.

- Pokud je Markovův proces stacionární, $P(q_t|q_{t-1})$ jsou nezávislé na t ; lze je uložit do matice $N \times N$.
- $P(q_1)$ jsou N různé hodnoty.
- Lze vybrat $P(x_t|q_t)$ podle aplikace, např. N různých hustot normálního rozdělení.

Hidden Markov Models: definice



HMM $\lambda = (\pi, \mathbf{A}, \mathbf{B})$, kde

- $\pi = (\pi_i)$: počáteční pravděpodobnosti
- $\mathbf{A} = [a_{ij}]$: $P(q_t = s_j | q_{t-1} = s_i)$ přechodové pravděpodobnosti
- $\mathbf{B} = (b_j)$: $P(x_t | q_t = s_j)$ výstupní pravděpodobnosti podle typu modelu:
 - diskrétní HMM: konečná výstupní abeceda, např. třídy kódové knihy vektorového kvantizéru
 - kontinuální HMM: vážené sumy rozdělení

$$b_j(\mathbf{x}) = \sum_{k=1}^{K_j} \omega_{jk} \cdot \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_{jk}, \boldsymbol{\Gamma}_{jk})$$
 - semi-kontinuální HMM:



$$b_j(\mathbf{x}) = \sum_{k=1}^K \omega_{jk} \cdot \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Gamma}_k)$$

HMM: Základní otázky

- Jak bychom měli stanovit topologie HMM, tj. které přechody mezi stavy bychom měli dovolit a které ne, tj. $P(s_i | s_j) = 0$?
- Jak vypočítáme produkční pravděpodobnost $P(x_1, \dots, x_T | \lambda)$ účinně?
- Dekódování: Jak získáme nejpravděpodobnější posloupnost stavů, když je dáno pozorování x_1, \dots, x_T ?
- Jak odhadujeme parametry HMM z tréninkového vzorku?

Topologie HMM

- topologie a počet stavů se většinou stanoví manuálně
- vhodné modelové topologie pro rozpoznávání řeči;
prvky přechodové matice, které nejsou nula, jsou vybarveny šedivě



- HMM, ve kterém jsou spojené všechny stavy, se jmenuje ergodický HMM.

Určení produkční pravděpodobnosti

Hledáme $P(\mathbf{O} \mid \lambda)$, tj. pravděpodobnost, že $\mathbf{O} = O_1, \dots, O_T$ je tvořeno pomocí λ .

- jako nahoře, jen v nové notaci: počítání produkční pravděpodobnosti sumací všech možných posloupností stavů

$$P(\mathbf{O} \mid \lambda) = \sum_{\mathbf{q} \in \mathcal{Q}^T} P(\mathbf{O}, \mathbf{q} \mid \lambda) = \sum_{\mathbf{q} \in \mathcal{Q}^T} \pi_{q_1} b_{q_1}(O_1) \cdot \prod_{t=2}^T a_{q_{t-1}q_t} b_{q_t}(O_t)$$

- kolem $2T \cdot N^T$ násobení: exponenciální komplexita s T
- zjednodušení počítání zavedením dopředných a zpětných pravděpodobností α, β

- dopředná pravděpodobnost: $\alpha_t(j) = P(O_1 \dots O_t, q_t = j \mid \lambda)$

- zpětná pravděpodobnost:

$$\beta_t(i) = P(O_{t+1} \dots O_T \mid q_t = i, \lambda)$$

- v každé chvíli t platí:

$$\alpha_t(j) \cdot \beta_t(j) = P(\mathbf{O}, q_t = j \mid \lambda), \quad P(\mathbf{O} \mid \lambda) = \sum_{j=1}^N \alpha_t(j) \beta_t(j)$$

Určení produkční pravděpodobnosti

dva ekvivalentní algoritmy, buď s dopřednými anebo zpětnými pravděpodobnostmi

■ Inicializace:

Pro všechna $j = 1, \dots, N$ buď

$$\alpha_1(j) = \pi_j b_j(O_1)$$

Pro všechna $i = 1, \dots, N$ buď

$$\beta_T(i) = 1$$

■ Rekurze:

Pro $t > 1$ a $j = 1, \dots, N$ buď

$$\alpha_t(j) = \left(\sum_{i=1}^N \alpha_{t-1}(i) a_{ij} \right) b_j(O_t)$$

Pro $t < T$ a $i = 1, \dots, N$ buď

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)$$

■ Terminace:

Počítej

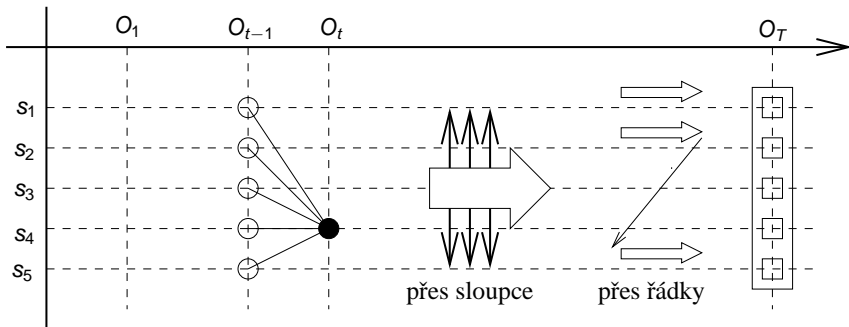
$$P(\mathbf{O} \mid \lambda) = \sum_{j=1}^N \alpha_T(j)$$

Počítej

$$P(\mathbf{O} \mid \lambda) = \sum_{j=1}^N \pi_j b_j(O_1) \beta_1(j)$$

Určení produkční pravděpodobnosti

- Oba algoritmy mají stejnou výpočetní složitost.
- Komplexita je kvadratická vzhledem k N a lineární v T :
 $2 \cdot N^2 \cdot T$ násobení



Viterbiův algoritmus

Hledáme posloupnost stavů q_1, \dots, q_T , která maximalizuje $P(q_1, \dots, q_T \mid \mathbf{O}, \lambda)$, tj. posloupnost stavů, kterou HMM při pozorování nejpravděpodobněji probíhal.

- **a posteriori pravděpodobnost** vztažená na výstup

$$P(\mathbf{q} \mid \mathbf{O}, \lambda) = \frac{P(\mathbf{O}, \mathbf{q} \mid \lambda)}{P(\mathbf{O} \mid \lambda)}$$

- \mathbf{q}^* je **optimální posloupnost stavů**, když

$$P(\mathbf{O}, \mathbf{q}^* \mid \lambda) = \max_{\mathbf{q} \in \mathcal{Q}^T} P(\mathbf{O}, \mathbf{q} \mid \lambda) =: P^*(\mathbf{O} \mid \lambda).$$

- **Viterbiův algoritmus**: varianta počítání dopředné matice

- místo $\alpha_t(j)$ se počítají tyto pravděpodobnosti:

$$\vartheta_t(j) = \max\{P(O_1 \dots O_t, q_1 \dots q_t \mid \lambda) \mid \mathbf{q} \in \mathcal{Q}^T\}, \text{ kde } q_t = j$$

- zpětné indexy pro extrakci posloupnosti stavů

Viterbiův algoritmus

■ Inicializace:

Buď $\vartheta_1(j) = \pi_j b_j(O_1)$ a $\psi_1(j) = 0$ pro všechny $j = 1, \dots, N$.

■ Rekurze: Pro všechny $j = 1, \dots, N$ buď

$$\vartheta_t(j) = \max_i (\vartheta_{t-1}(i) a_{ij}) b_j(O_t); \quad \psi_t(j) = \operatorname{argmax}_i \vartheta_{t-1}(i) a_{ij}$$

■ Terminace: Buď

$$P^*(\mathbf{O} \mid \lambda) = \max_j \vartheta_T(j); \quad q_T^* = \operatorname{argmax}_j \vartheta_T(j)$$

■ Zpětné sledování: Pro $t = T - 1, \dots, 1$ lze počítat optimální posloupnost pomocí

$$q_t^* = \psi_{t+1}(q_{t+1}^*).$$

Odhad ML modelových parametrů

Hledáme množinu $\hat{\lambda}$ parametrů HMM, když je dána tréninková promluva \mathbf{O} .

- odhad ML: Vyber $\hat{\lambda}$ tak, aby cílová funkce byla maximální:

$$\log_{\text{HMM}}(\lambda) = \log P(\mathbf{O} | \lambda) = \log \sum_{\mathbf{q} \in \mathcal{Q}^T} P(\mathbf{O}, \mathbf{q} | \lambda)$$
- pozorovatelná náhodná proměnná: $X = \mathbf{O}$
- skrytá náhodná proměnná: $Y = \mathbf{q}$
- parametr, který odhadujeme: $B = \hat{\lambda}$
- vztah mezi \mathbf{O} a \mathbf{q} je znám
 → aplikace algoritmu EM
- maximalizuj $\hat{\lambda}$ vzhledem ke **Kullback-Leiblerově statistice**

$$Q(\lambda, \hat{\lambda}) = \sum_{\mathbf{q} \in \mathcal{Q}^T} P(\mathbf{q} | \mathbf{O}, \lambda) \cdot \log P(\mathbf{O}, \mathbf{q} | \hat{\lambda})$$

Odhad ML modelových parametrů

Pro počítání a posteriori pravděpodobnosti $P(\mathbf{q} \mid \mathbf{O}, \lambda)$ se uvádí následující veličiny:

- **a posteriori přechodná pravděpodobnost** pro $s_i \rightarrow s_j$ ve chvíli t :

$$\begin{aligned} \xi_t(i, j) &= P(q_t = i, q_{t+1} = j \mid \mathbf{O}, \lambda) \\ &= \frac{P(q_t = i, q_{t+1} = j, \mathbf{O} \mid \lambda)}{P(\mathbf{O} \mid \lambda)} \\ &= \frac{\alpha_t(i) a_{ij} b_j(\mathbf{O}_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \alpha_t(i) \beta_t(i)}, \quad 1 \leq t < T \end{aligned}$$

- **a posteriori stavová pravděpodobnost** pro s_i ve chvíli t :

$$\gamma_t(i) = P(q_t = i \mid \mathbf{O}, \lambda) = \frac{\alpha_t(i) \beta_t(i)}{\sum_{j=1}^N \alpha_t(j) \beta_t(j)} = \sum_{j=1}^N \xi_t(i, j)$$

- sumace těch $\xi_t(i, j)$, popř. $\gamma_t(i)$ přes všechna t
 → očekávané hodnoty pro přechody $s_i \rightarrow s_j$, popř. pro pobyt v s_i

Baum-Welchovy rovnice

Rovnice odhadu, které vznikají z algoritmu EM pro HMM, se nazývají Baum-Welchovy rovnice; trénink se nazývá Baum-Welchův trénink nebo algoritmus prohledávání dopředu a dozadu.

$$\hat{\pi}_i = \gamma_1(i) = \frac{\alpha_1(i)\beta_1(i)}{\sum_{j=1}^N \alpha_1(j)\beta_1(j)}$$

$$\hat{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i,j)}{\sum_{t=1}^{T-1} \gamma_t(i)} = \frac{\sum_{t=1}^{T-1} \alpha_t(i) \mathbf{a}_{ij} \mathbf{b}_j(\mathbf{O}_{t+1}) \beta_{t+1}(j)}{\sum_{t=1}^{T-1} \alpha_t(i) \beta_t(i)}$$

$$\hat{b}_{jk} = \frac{\sum_{t=1}^T \gamma_t(j) \chi_{[O_t=v_k]}}{\sum_{t=1}^T \gamma_t(j)} = \frac{\sum_{t=1}^T \alpha_t(j) \beta_t(j) \chi_{[O_t=v_k]}}{\sum_{t=1}^T \alpha_t(j) \beta_t(j)}$$

- $\chi_{[\cdot]} = 1$ pro případné výroky a jinak 0.
- Iterativní aplikace vede k lokálnímu optimu.
- Nárok jedné iterace je jen o málo vyšší než počítání dopředné a zpětné matice.

Viterbiův trénink

- Aplikace algoritmu EM* se nazývá Viterbiův trénink nebo segmentově členěný algoritmus k-means.
- Optimalizuje se podle Viterbiova hodnocení $P^*(\mathbf{O} \mid \lambda) = P(\mathbf{O}, \mathbf{q}^* \mid \lambda^{(n-1)})$.
- Je **mnohem účinnější** než Baum-Welchův trénink (BWT).
- Při malém tréninkovém vzorkům **není spolehlivější** než BWT.
- Viterbiův trénink odpovídá BWT s **modifikovanými a posteriori pravděpodobnostmi**: $\gamma_t^*(i) = \chi_{[q_t^*=s_i]}$, $\xi_t^*(i, j) = \chi_{[q_t^*=s_i, q_{t+1}^*=s_j]}$

Viterbiův trénink

- Vyber počáteční model $\lambda^{(0)}$.
- Pro $n = 1, 2, \dots$:
 - (1) Urči optimální posloupnost stavů \mathbf{q}^* , kde

$$P(\mathbf{O}, \mathbf{q}^* | \lambda^{(n-1)}) = \max_{\mathbf{q}} P(\mathbf{O}, \mathbf{q} | \lambda^{(n-1)})$$

pomocí Viterbiova algoritmu.

- (2) Spočítej počáteční, přechodové a výstupní četnosti patřící ke \mathbf{q}^*

$$\bar{\pi}_i = \chi_{[q_1=s_i]}, \quad \bar{a}_{ij} = \sum_{t=1}^{T-1} \chi_{[q_t^*=s_i, q_{t+1}^*=s_j]}, \quad \bar{b}_{jk} = \sum_{t=1}^T \chi_{[q_t^*=s_j, O_t=v_k]} \cdot$$

- (3) Normalizuj $\hat{\pi}_i = \bar{\pi}_i / \sum_i \bar{\pi}_i$, $\hat{a}_{ij} = \bar{a}_{ij} / \sum_j \bar{a}_{ij}$, $\hat{b}_{jk} = \bar{b}_{jk} / \sum_k \bar{b}_{jk}$.
- (4) Stanov $\lambda^{(n)} = (\hat{\pi}_i, \hat{a}_{ij}, \hat{b}_{jk})$.

Praktická aplikace skrytých Markovových modelů

Pro dlouhé promluvy při omezené numerické přesnosti může násobení mnohých pravděpodobností rychle vést k hodnotám = 0.

- 1. řešení: V algoritmu prohledávání dopředu užíváme stupnice/normalizace

$$\tilde{\alpha}_t(j) = \frac{1}{C_t} \cdot \alpha_t(j) = \frac{\alpha_t(j)}{\sum_i \alpha_t(i)}$$

s faktory stupnice C_t vztažené na čas t .

$\alpha_t(j)$ můžeme vždycky rekonstruovat, protože platí

$$\alpha_t(j) = C_1 \cdot C_2 \cdots C_t \cdot \tilde{\alpha}_t(j).$$

- 2. řešení: logaritmizace:

- Ve Viterbiovu algoritmu pracujeme s logaritmovanými pravděpodobnostmi → násobení se stane adicí.
- Problém: V algoritmu prohledávání dopředu musíme sčítat logaritmované pravděpodobnosti → **Kingsbury-Raynerova rovnice** $\log(p_1 + p_2) = \log p_1 + \log(1 + e^{\log p_2 - \log p_1})$.
- zrychlení s tabulkou všech $\log(1 + e^{\log p_2 - \log p_1})$

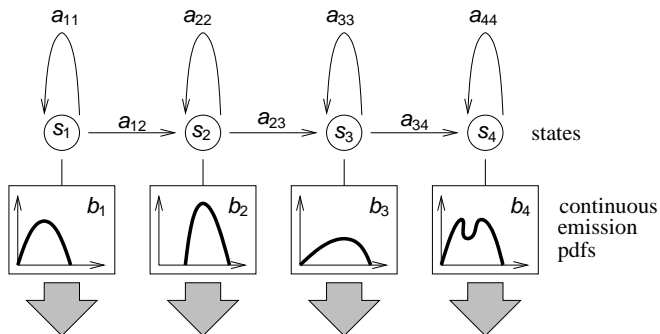
Praktická aplikace skrytých Markovových modelů

- Je nutné vhodné stanovení iniciálních odhadnutých hodnot $\lambda^{(0)}$:
 - S algoritmem LBG shlukujeme (clustering) všechny příznakové vektory; odhadujeme iniciální diskrétní HMM, který je inicializací kontinuálního HMM.
 - Výstupní rozdělení kontinuálního HMM inicializujeme prostřednictvím shluku segmentace, kterou vytvořil diskrétní HMM.
- Když je pro HMM víc než jeden tréninkový příklad, rovnice na odhad se mění jako při algoritmu EM.
- Příklad: Rovnice na odhad přechodné pravděpodobnosti:

$$\hat{a}_{ij} = \frac{\sum_{l=1}^L \sum_{m=1}^{M_l} \left(\sum_{t=1}^{T_{l,m-1}} \xi_t^{(l,m)}(i,j) \right)}{\sum_{l=1}^L \sum_{m=1}^{M_l} \left(\sum_{t=1}^{T_{l,m-1}} \gamma_t^{(l,m)}(i) \right)}$$

Kontinuální HMM

- Diskrétní HMM vyžadují předchozí vektorovou kvantizaci:
 $\mathbf{X} = \mathbf{x}_1 \dots \mathbf{x}_T \longrightarrow \mathbf{O} = O_1, \dots, O_T \Rightarrow$ **ztráta informace**
- **Kontinuální výstupní rozdělovací hustoty** $b_j(\mathbf{x})$, $\mathbf{x} \in \mathbb{R}^D$ pro zpracování příznakových vektorů: chování charakterizováno váženou sumou hustot rozdělení $P(\mathbf{X}, \mathbf{q} \mid \lambda)$



- $b_j(\mathbf{x})$ z **parametrické rodiny** hustot, např. normální hustota \mathcal{N}

Kontinuální HMM: Rovnice na odhad

- Rovnice na odhad počátečních a přechodových pravděpodobností a počítání hodnot pravděpodobností jsou ekvivalentní s diskrétními HMM.
- Při normálních rozdělovacích hustotách platí

$$b_j(\mathbf{x}) = \mathcal{N}(\mathbf{x} \mid \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)$$

$$\hat{\boldsymbol{\mu}}_j = \frac{1}{\sum_t \gamma_t(j)} \sum_{t=1}^T \gamma_t(j) \mathbf{x}_t$$

$$\hat{\boldsymbol{\Sigma}}_j = \frac{1}{\sum_t \gamma_t(j)} \sum_{t=1}^T \gamma_t(j) (\mathbf{x}_t - \hat{\boldsymbol{\mu}}_j)(\mathbf{x}_t - \hat{\boldsymbol{\mu}}_j)^T$$

$$= \frac{1}{\sum_t \gamma_t(j)} \sum_{t=1}^T \gamma_t(j) \mathbf{x}_t \mathbf{x}_t^T - \hat{\boldsymbol{\mu}}_j \hat{\boldsymbol{\mu}}_j^T.$$

Gaußovy vážené sumy hustot rozdělení

- Výstupní hustota je Gaußova vážená suma hustot rozdělení (svázaná/spojená hustota rozdělení):

$$b_j(\mathbf{x}) = \sum_{k=1}^K c_{jk} g_{jk}(\mathbf{x}) = \sum_{k=1}^K c_{jk} \mathcal{N}(\mathbf{x} \mid \boldsymbol{\mu}_{jk}, \boldsymbol{\Sigma}_{jk}), \quad \sum_{k=1}^K c_{jk} = 1$$

- může při vysokém počtu hustot aproximovat každou hustotu
- rozšiřovaný v rozpoznávání řeči
- komponenta $k_t \in \mathcal{K}$ sumy je skrytá náhodná proměnná
- produkční pravděpodobnost

$$P(\mathbf{X} \mid \lambda) = \sum_{\mathbf{q} \in \mathcal{Q}^T} \sum_{\mathbf{k} \in \mathcal{K}^T} P(\mathbf{X}, \mathbf{q}, \mathbf{k} \mid \lambda)$$

Baum-Welchovy rovnice odhadu

pro Gaußovy vážené sumy hustot rozdělení

a posteriori pravděpodobnost selekce komponenty k v s_j ve chvíli t :

$$\begin{aligned} \zeta_t(j, k) &= P(q_t = j, k_t = k \mid \mathbf{X}, \lambda) \\ &= \begin{cases} \frac{1}{P(\mathbf{X} \mid \lambda)} \sum_{i=1}^N \alpha_{t-1}(i) a_{ij} c_{jk} g_{jk}(\mathbf{x}_t) \beta_t(j), & \text{když } t > 1 \\ \frac{1}{P(\mathbf{X} \mid \lambda)} \sum_{i=1}^N \pi_j c_{jk} g_{jk}(\mathbf{x}_1) \beta_1(j) & , \text{ když } t = 1 \end{cases} \end{aligned}$$

rovnice odhadu:



$$\begin{aligned} \hat{c}_{jk} &= \frac{1}{\sum_t \gamma_t(j)} \sum_{t=1}^T \zeta_t(j, k) \\ \hat{\mu}_{jk} &= \frac{1}{\sum_t \zeta_t(j, k)} \sum_{t=1}^T \zeta_t(j, k) \mathbf{x}_t \\ \hat{\Sigma}_{jk} &= \frac{1}{\sum_t \zeta_t(j, k)} \sum_{t=1}^T \zeta_t(j, k) \mathbf{x}_t \mathbf{x}_t^T - \hat{\mu}_{jk} \hat{\mu}_{jk}^T \end{aligned}$$

Semikontinuální HMM (SCHMM)

- Markovovy modely se **semikontinuálními** výstupními hustotami:

$$b_j(\mathbf{x}) = \sum_{k=1}^K c_{jk} g_k(\mathbf{x}) = \sum_{k=1}^K c_{jk} \mathcal{N}(\mathbf{x} \mid \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k), \quad \sum_{k=1}^K c_{jk} = 1$$


- rozdíl oproti kontinuálnímu HMM s váženými sumami hustot: tam komponenty pro **jeden** stav, tady pro **všechny** stavy
- SCHMM má schopnost aproximace jako vážené sumy hustot, vyžaduje ale méně parametrů.



Semikontinuální HMM

- Váhy c_{ij} sumy mohou být také považované za výstupní pravděpodobnosti diskrétního HMM.
- SCHMM hodnotí **všechny** třídy kódové knihy, hodnoty $g_k(\mathbf{x})$ hustoty váží diskrétní výstupní pravděpodobnost (**měkká** nebo **neostrá** vektorová kvantizace).
- Vektorová kvantizace je součástí SCHMM.
- SCHMM může tedy být zařazen mezi diskrétní a kontinuální HMM.

Vlastnosti semikontinuálních HMM



■ Vlastnosti SCHMM:

- kompaktní parametrový prostor
- žádné zkřivení kvůli kvantizaci
- vektorová kvantizace je zahrnuta do procesu optimalizace modelu

- SCHMM je lepší než kontinuální HMM, když je málo dat k dispozici; když je víc dat, je horší.

Semikont. HMM: Baum-Welchovy rovnice odhadu

sumace statistik hustot přes všechny stavy

$$\hat{\boldsymbol{\mu}}_k = \frac{1}{\sum_t \sum_j \zeta_t(j, k)} \sum_{t=1}^T \sum_{j=1}^N \zeta_t(j, k) \mathbf{x}_t$$

$$\hat{\boldsymbol{\Sigma}}_k = \frac{1}{\sum_t \sum_j \zeta_t(j, k)} \sum_{t=1}^T \sum_{j=1}^N \zeta_t(j, k) \mathbf{x}_t \mathbf{x}_t^T - \hat{\boldsymbol{\mu}}_k \hat{\boldsymbol{\mu}}_k^T$$


Nevýhody užívání HMM

■ modelování trvání

- Doba pobytu v **jednotlivém** stavu je rozdělená exponenciálně:
$$d_i(\tau) = P(q_{t-\tau+1} = \dots = q_{t-1} = s_i, q_t \neq s_i \mid q_{t-\tau} = s_i, \lambda) = a_{ii}^{\tau-1} \cdot (1 - a_{ii})$$
- Ve skutečnosti je ale nejpravděpodobnější délka hlásky > 0 .
- Řešení: explicitní modelování délky anebo vhodné modelové topologie s několikrát za sebou zapojenými stavy
- Víc stavů může opravdové rozdělení délky hlásky aproximovat lépe.


Nevýhody užívání HMM

rozdělení trvání anglické hlásky („laut“) a jeho model podle HMM



Nevýhody užívání HMM

různá modelování trvání hlásky pomocí HMM (x: doba; y: pravděpodobnost)



Nevýhody užívání HMM

- Markovův proces prvního řádu
 - řešení: generalizované HMM vyššího řádu
 - problém: vysoká výpočetní složitost
- předpoklad podmíněné nezávislosti pozorování
 - příklad: odhad diskrétního HMM s 2 stavy na textech
mmmmmmmmmm, wwwwwwwwww.
 - srovnatelné s mužskými a ženskými mluvčími s váženými sumami
rozdělení jako výstupní hustota
 - HMM bude mít vysoké produkční pravděpodobnosti pro texty
wwwmmmm a mmmmwww.
 - Proč?
 - řešení: paralelně zapojené HMM, segmentové modely

HMM – střední hodnoty výstupní rozdělení

