

# Rozpoznávání řeči – HMM

Jan Černocký ÚPGM FIT VUT Brno, cernocky@fit.vutbr.cz

FIT VUT Brno

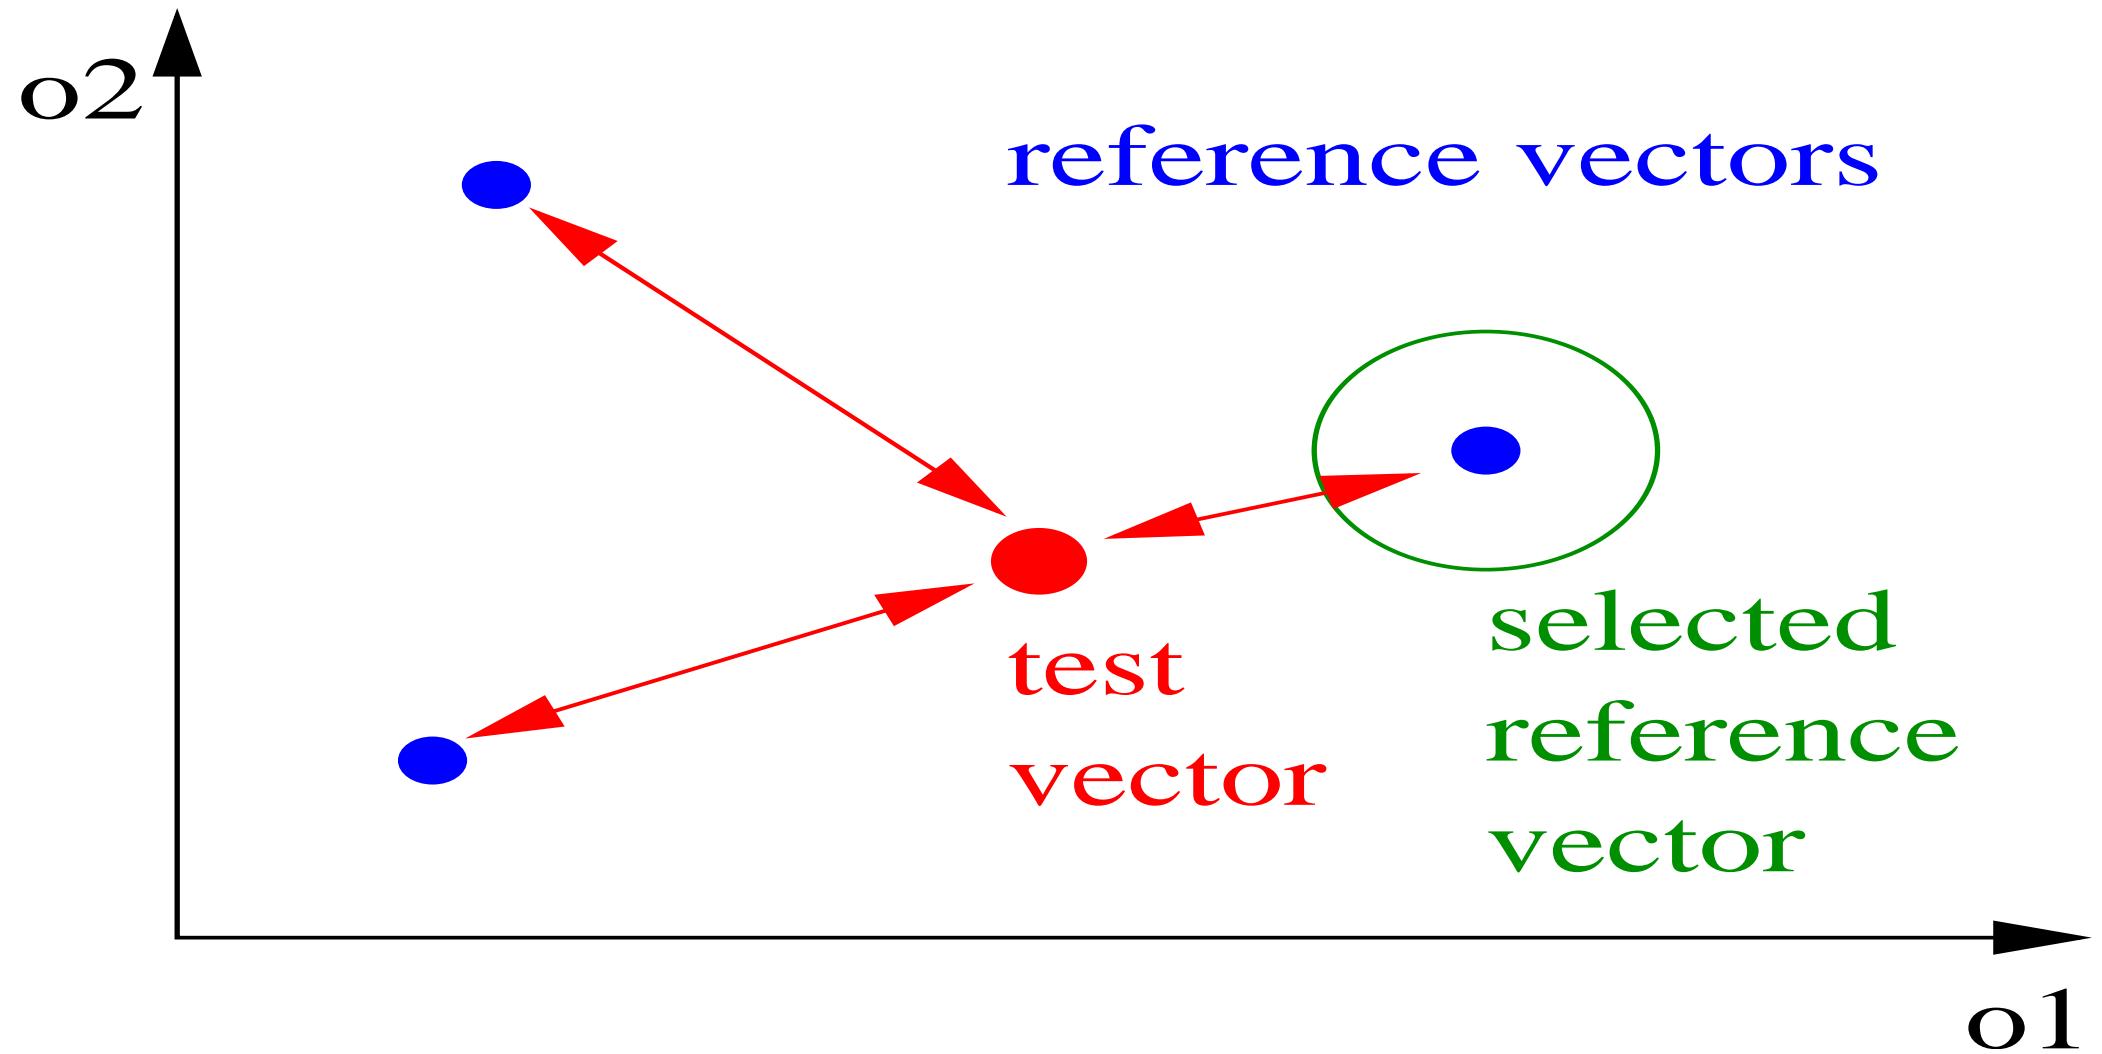
## Plán

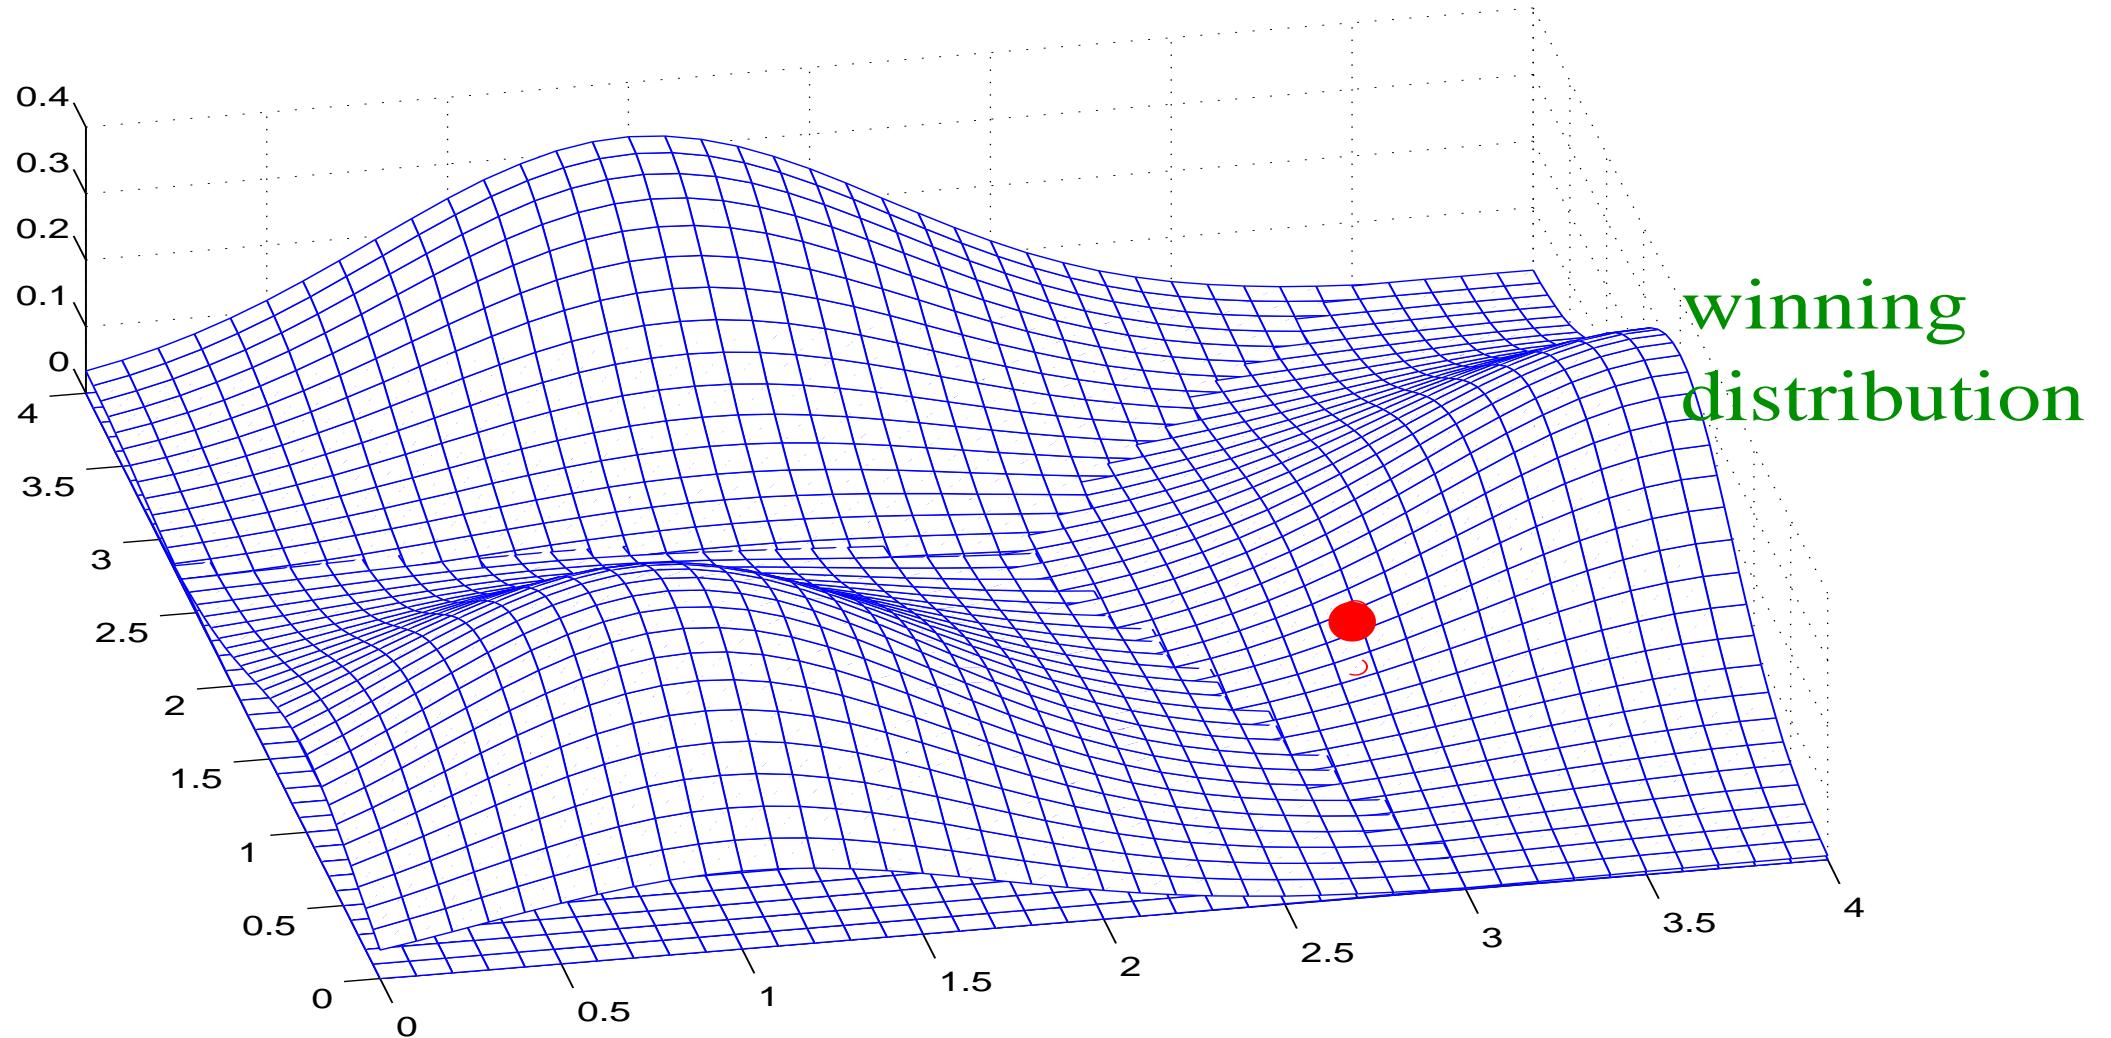
- Opakování – variabilita v řeči.
- Statistický přístup.
- Model a jeho parametry.
- Pravděpodobnost vyslání matice  $\mathbf{O}$  modelem  $M$ .
- Trénování parametrů.
- Rozpoznávání.
- Viterbi a Pivo-passing.

## Opakování – jak na variabilitu v řeči

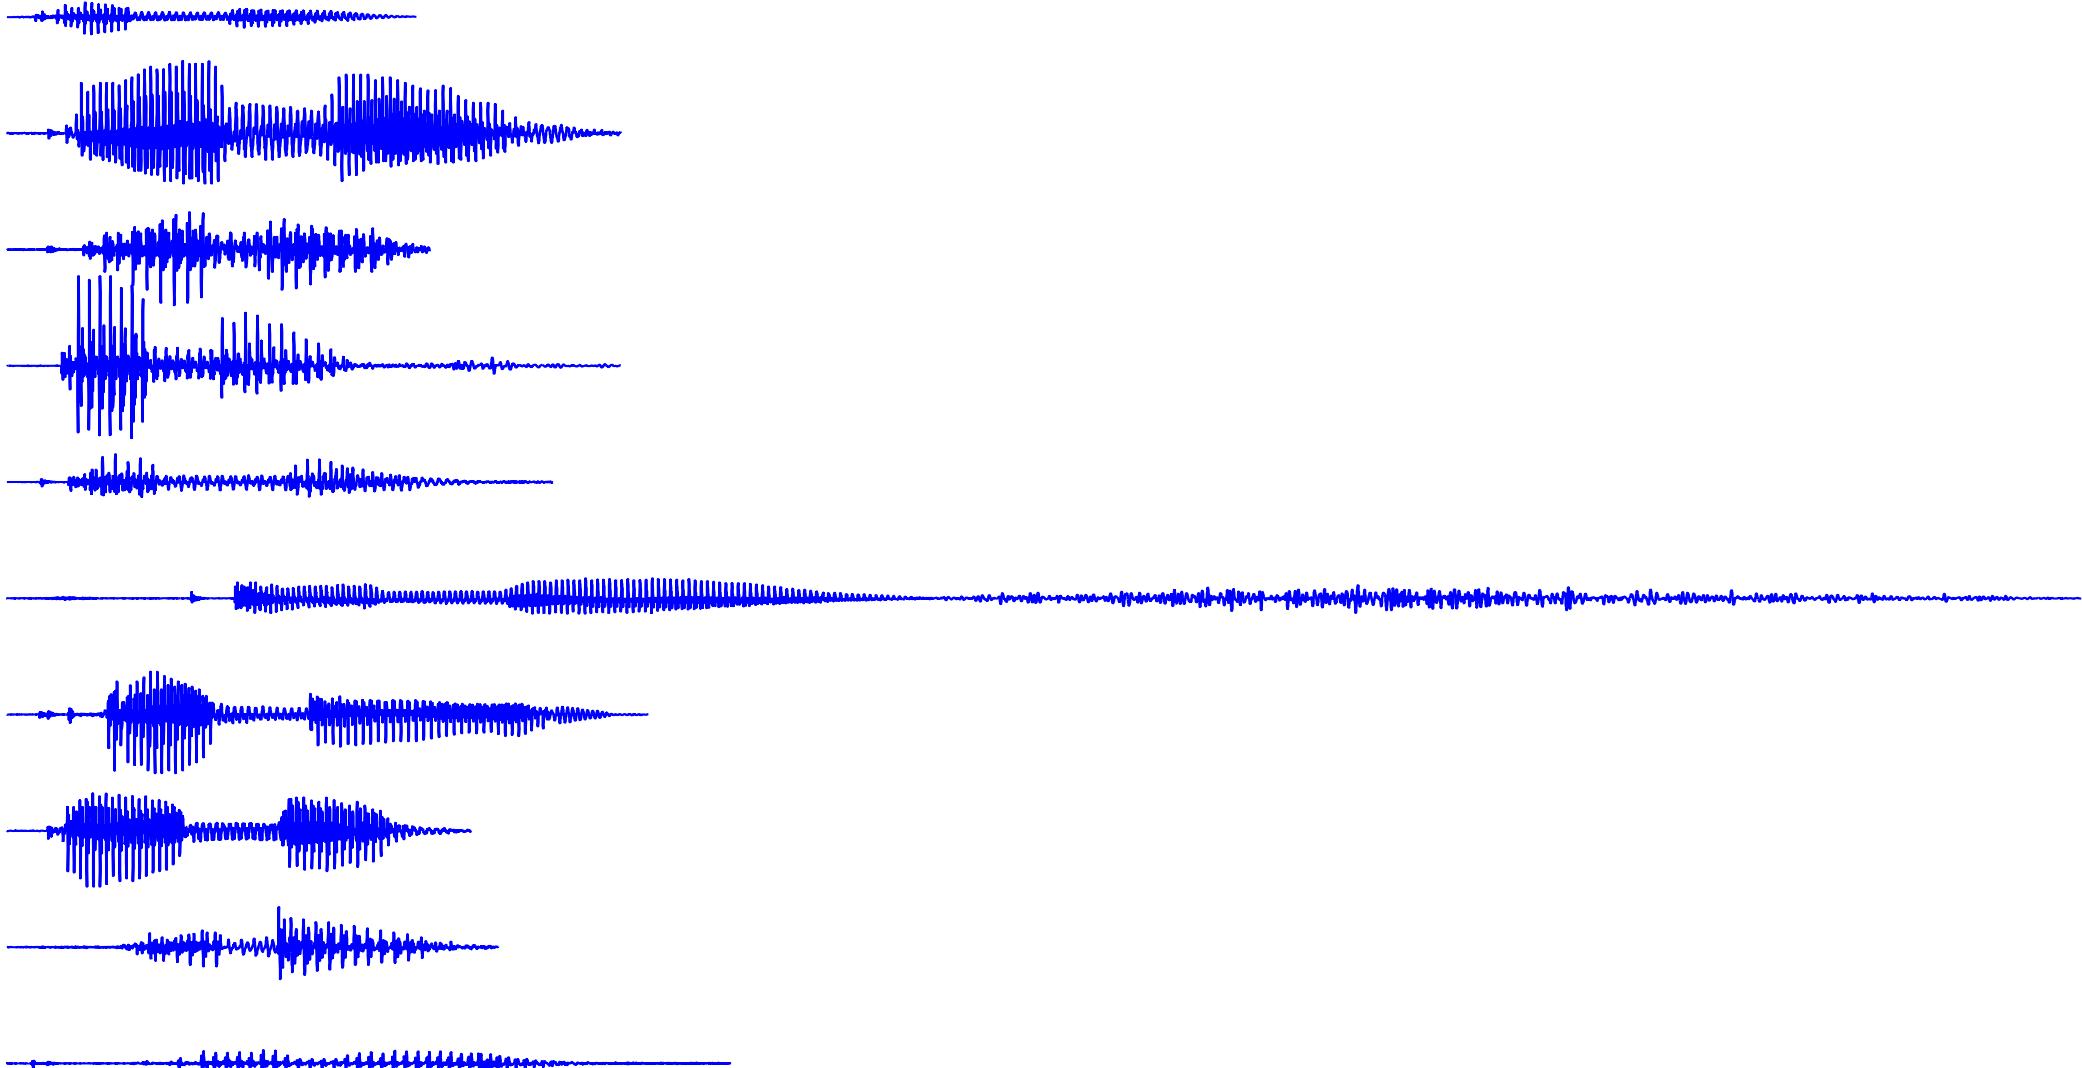
**prostor parametrů** - člověk nikdy neřekne jednu věc stejně  $\Rightarrow$  vektory parametrů se **vždy liší**.

1. Měření vzdálenosti mezi vektory.
2. Statistické modelování.

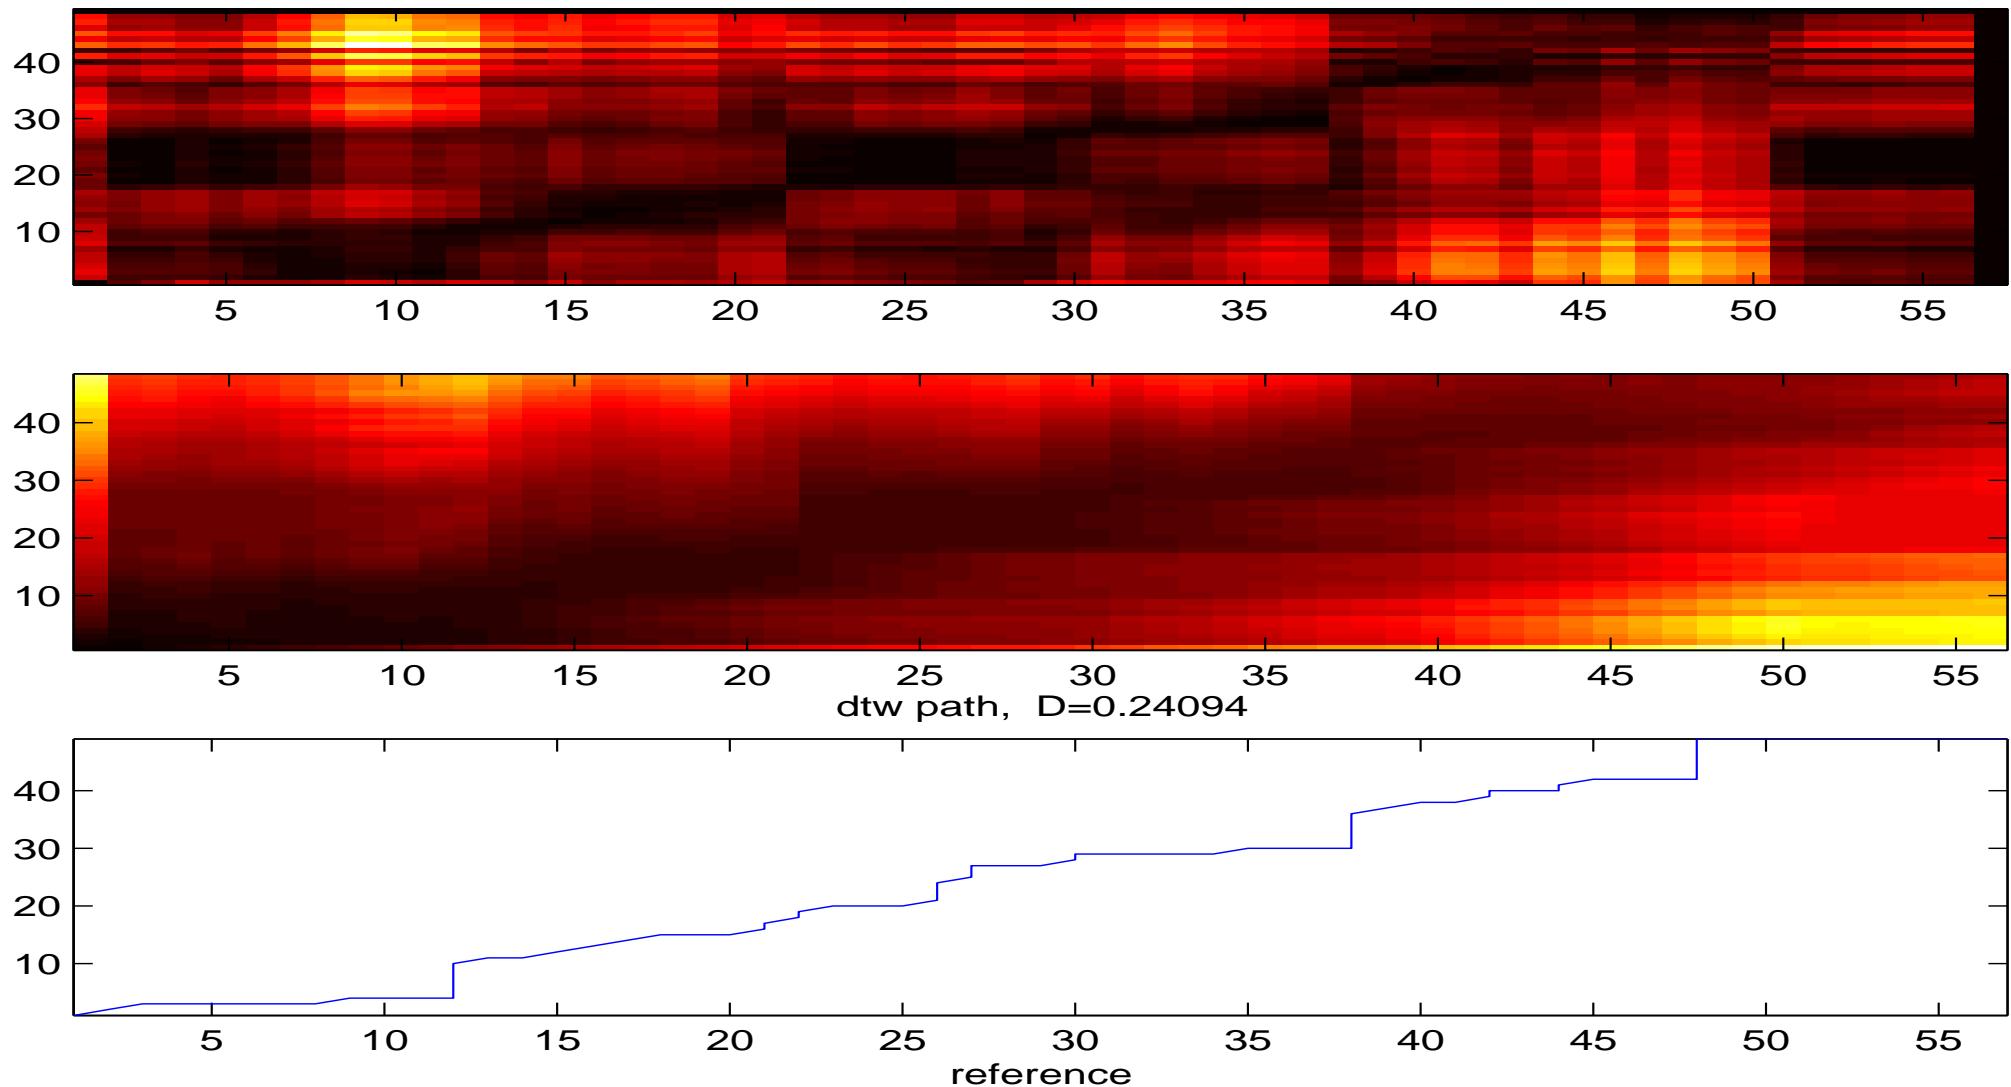




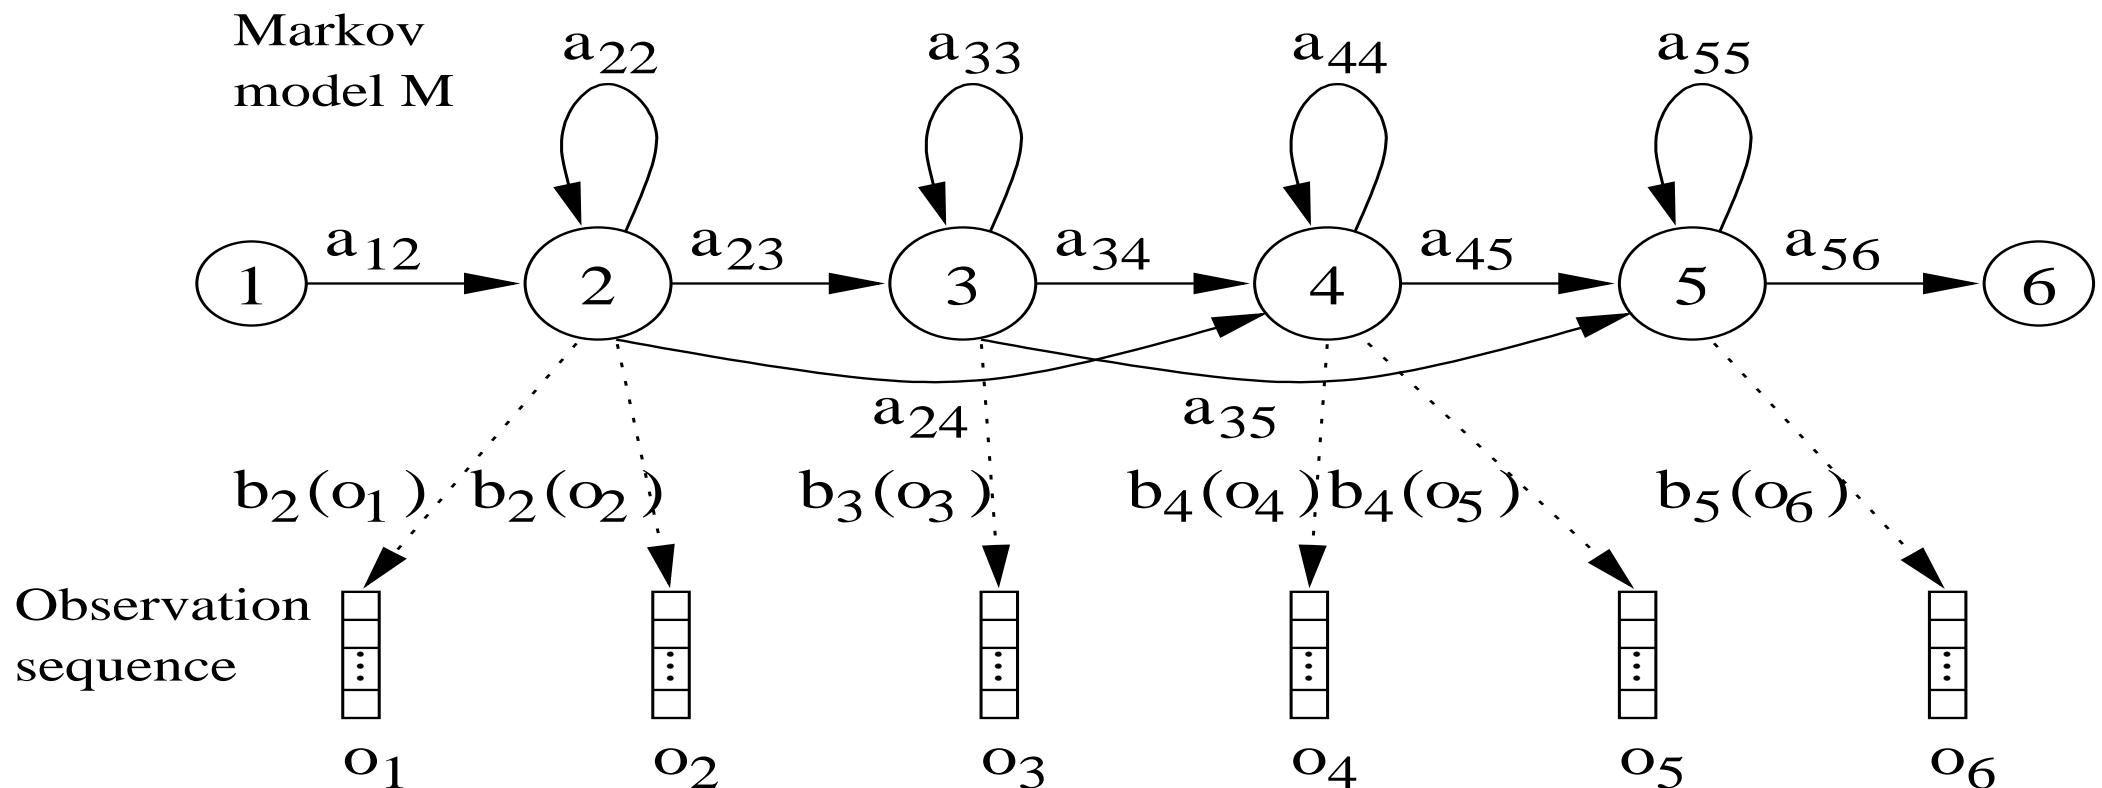
časování – lidé nikdy neřeknou jednu věc se stejným časováním.



## Časování č.1 - Dynamické borcení času - cesta

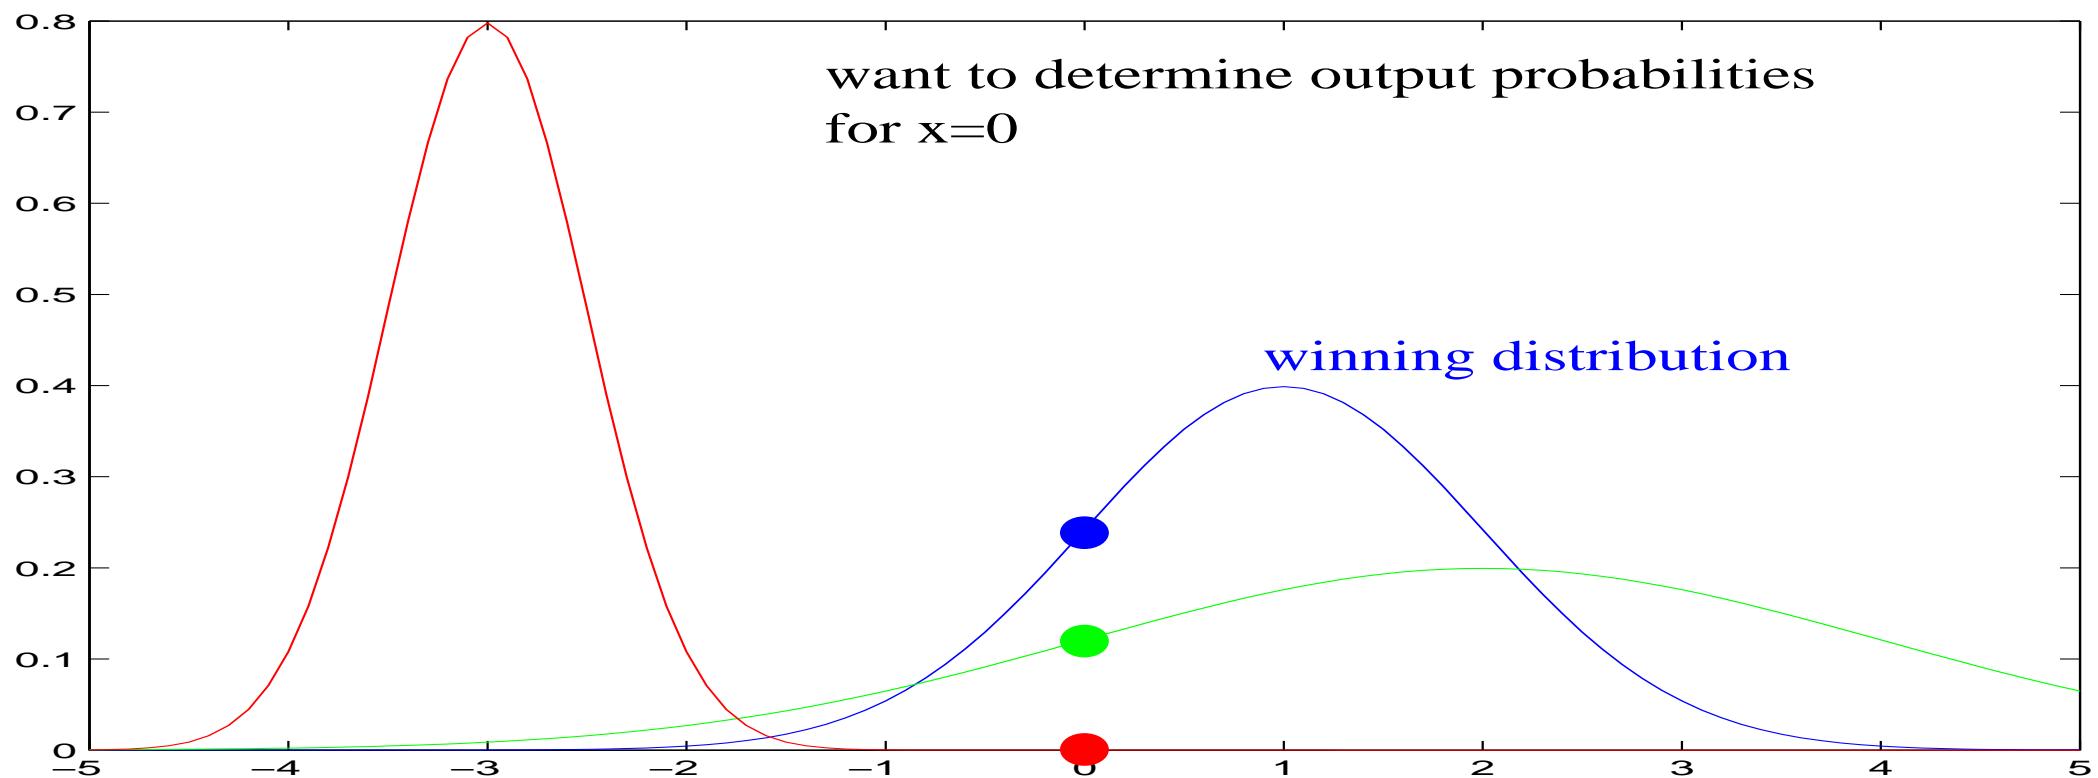


## Časování č.2 - Skryté Markovovy modely - sekvence stavů



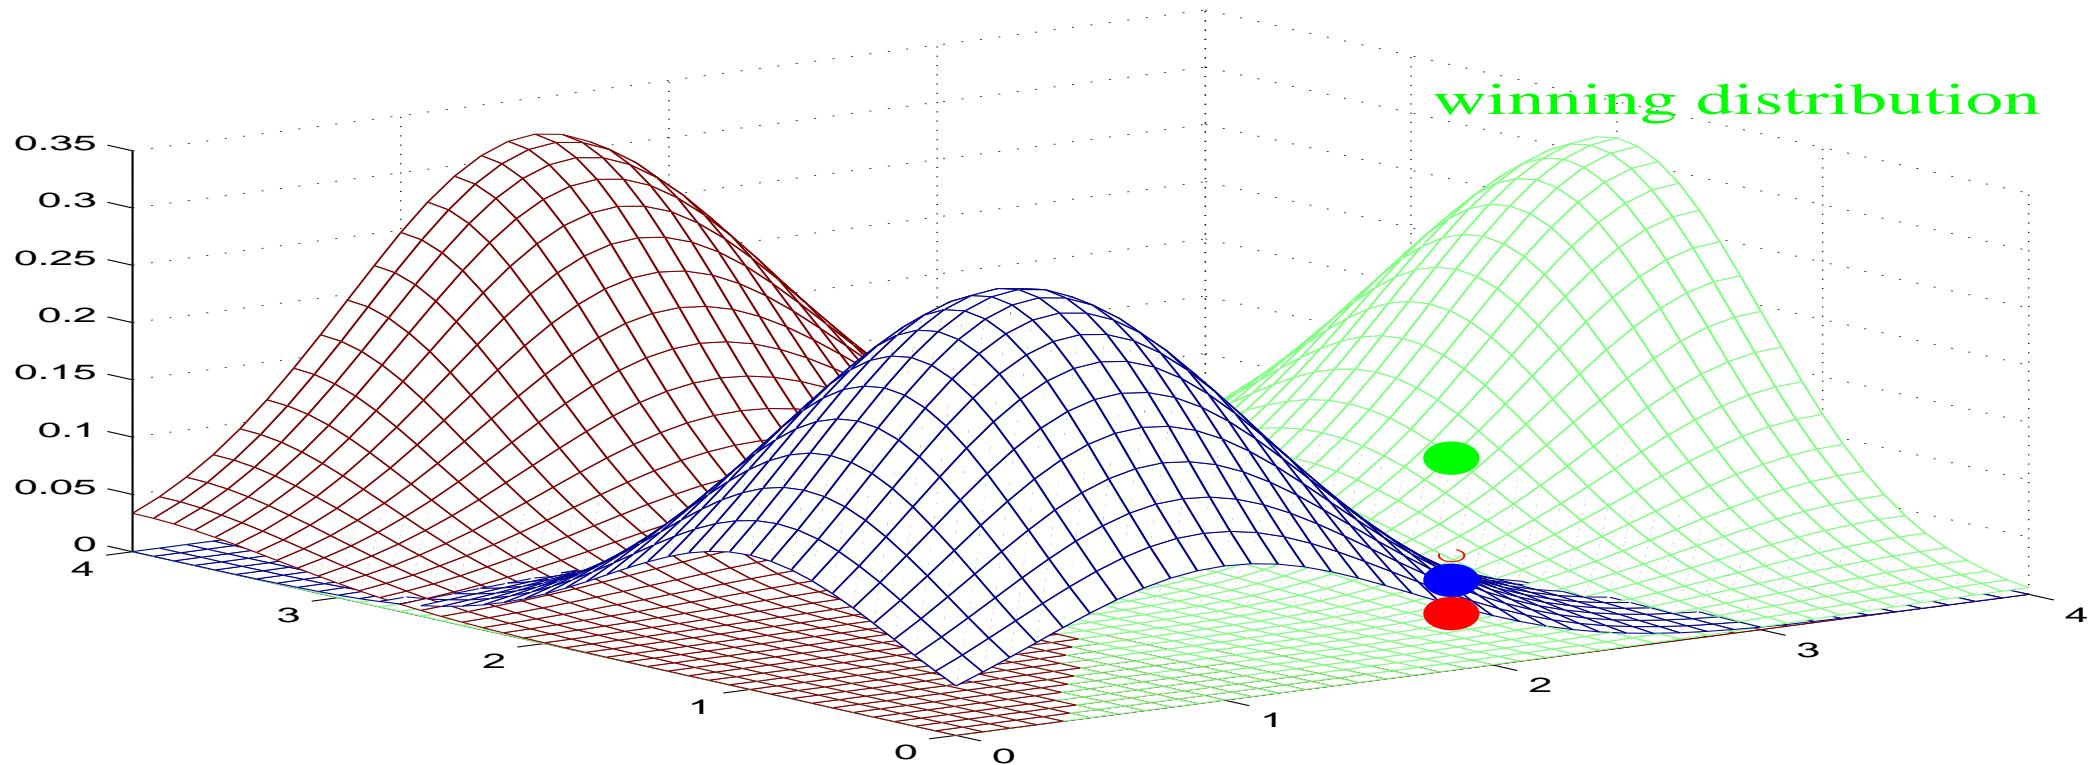
## Skryté Markovovy modely (Hidden Markov Models) - HMM

Kdyby byla slova reprezentována jedním **skalárem** a slova byla representována Gaussovskými rozloženími...



- Hodnota  $p(x)$  funkce hustoty rozdělení pravděpodobností **není pravděpodobnost** (pozor na statistiky se sekýrkou ☺). Pravděpodobnost je pouze  $\int_a^b p(x)dx$ . My tomu ale **budeme říkat pravděpodobnost**.
- Hodnotě  $p(x)$  se někdy říká **vysílací pravděpodobnost** (emission probability), protože kdyby náhodný proces dokázal generovat hodnoty, vygeneroval by  $x$  s  $p(x)$ . Naše procesy nic generovat nebudou, ale budeme tomu “vysílací pravděpodobnost” říkat (odlišení od přechodových – viz dále).

...jenž slova nejsou representována skaláry, ale **vektory**  $\Rightarrow$  vícerozměrná Gaussovská rozložení.



V reálu jsou gaussovky mnoharozměrné (např. 39-rozměrné), to se špatně představuje a kreslí, ale můžeme si vždy udělat *průmět* do 1D, 2D nebo 3D.

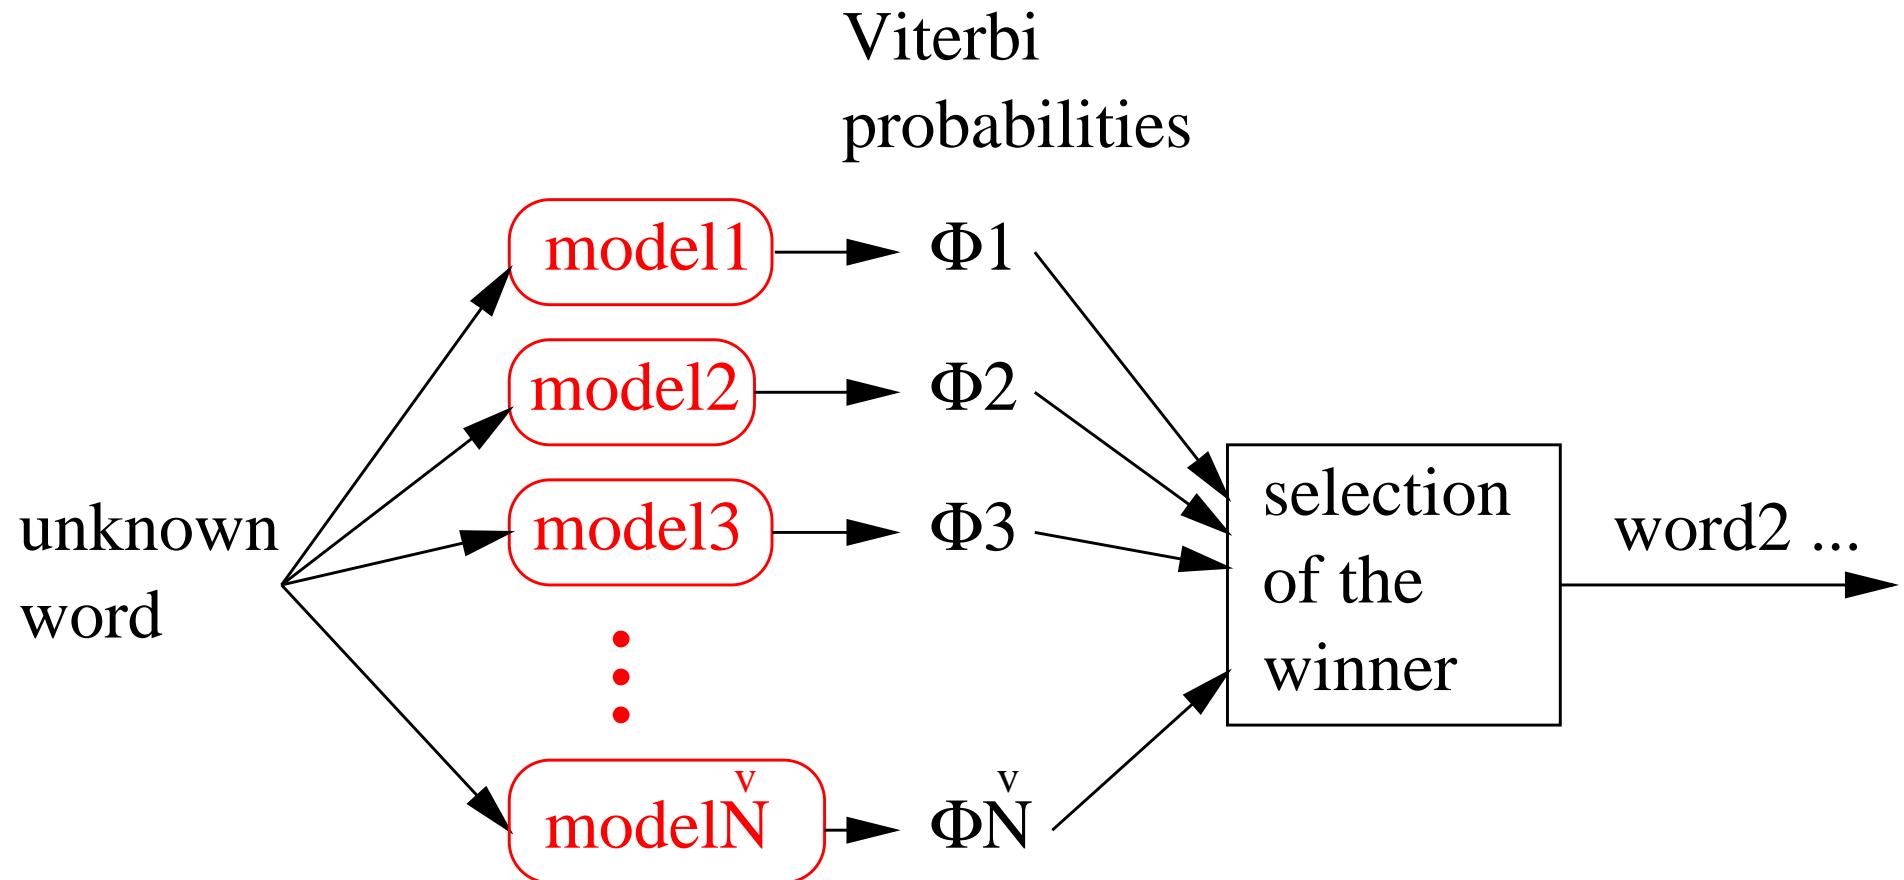
. . . jenž slova nemají jen jeden vektor, ale více. . .

- Nápad 1: mít 1 gaussovku na slovo, postupně jí předkládat vektory a hodnoty sčítat  
⇒ BLBÝ NÁPAD (“paří” = “řípa” ???)
- Nápad 2: každé slovo budeme muset reprezentovat **sekvencí více Gaussovek**.
  - jedna nezávislá Gaussovka na každý vektor ? Aj aj, vektorů je pokaždé jiný počet !
  - **model, kde se Gaussovky budou moci opakovat !**

## Modely, kde se Gaussovky mohou opakovat, se jmenují HMM

trochu přesněji – výklad pro **izolovaná slova**

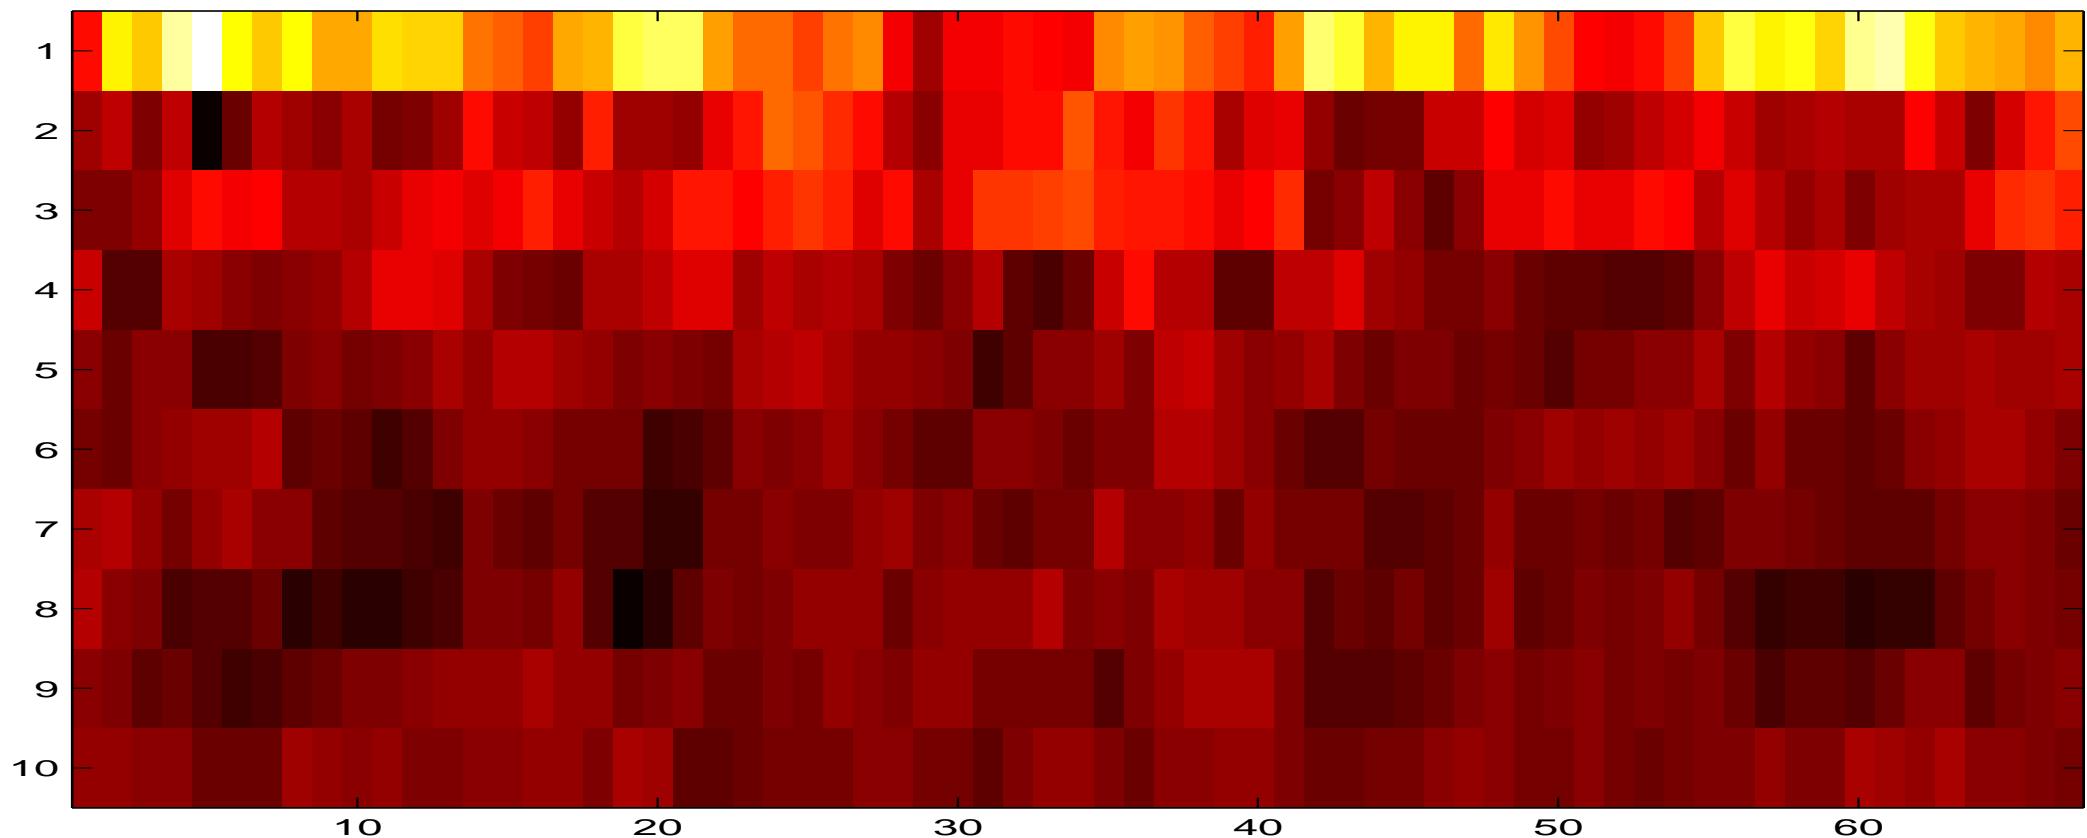
⇒ Pro každé slovo, které budeme chtít rozpoznávat, budeme potřebovat jeden model.



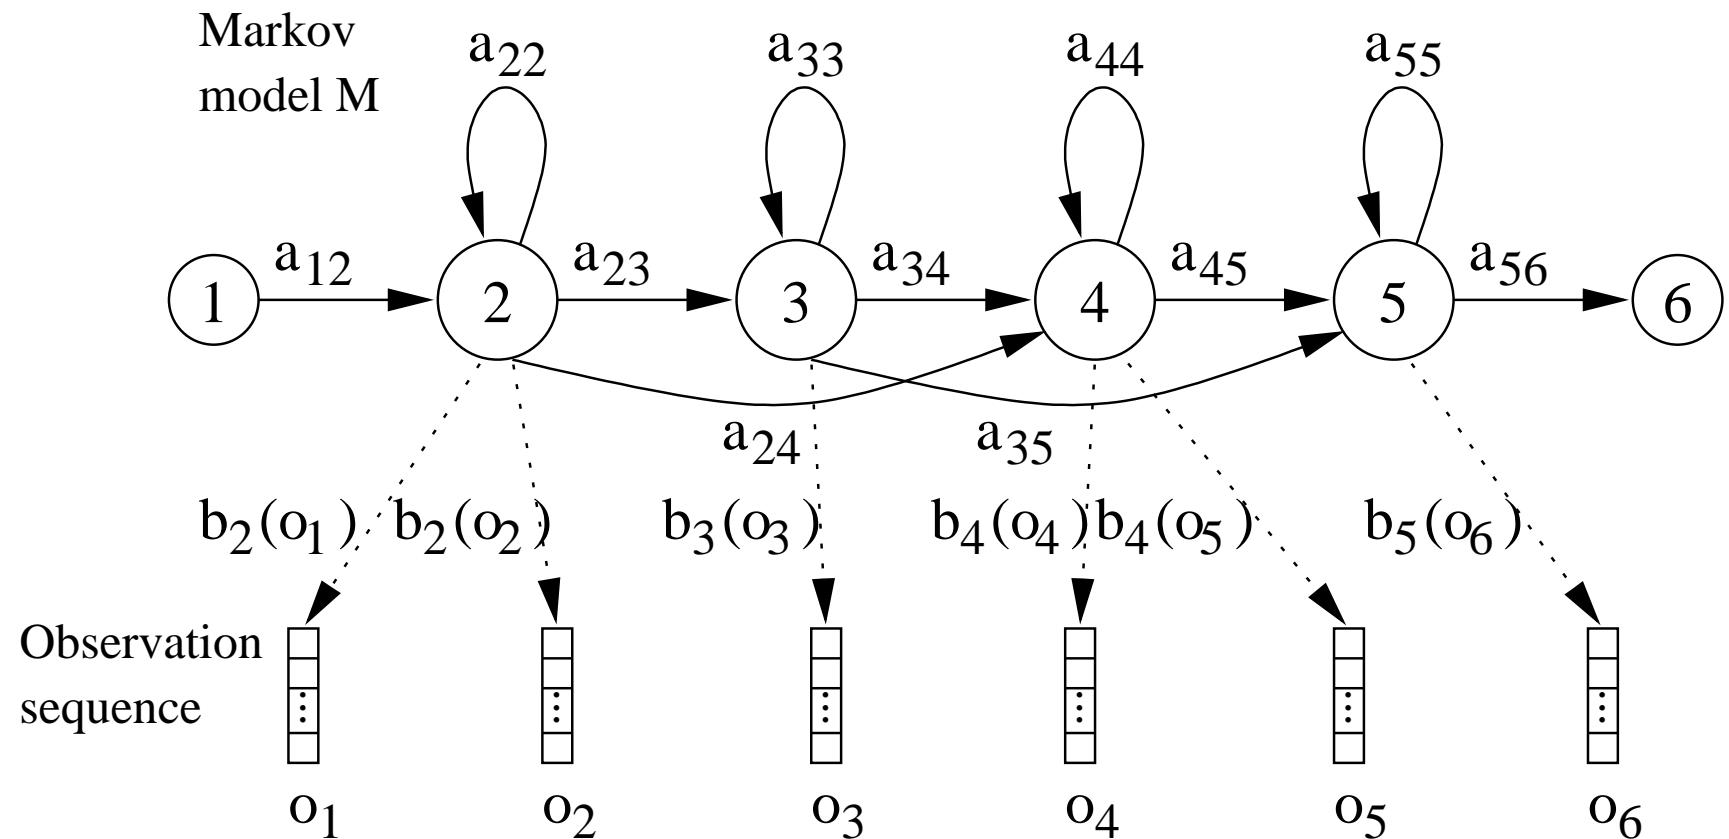
Teď už musí nastoupit trocha matematiky. Vše budeme ukazovat na **jednom modelu**, ale uvědomme si, že aby rozpoznávač rozpoznával, musí jich v něm být **několik** – pro každé slovo.

## Vstupní sekvence vektorů

$$\mathbf{O} = [\mathbf{o}(1), \mathbf{o}(2), \dots, \mathbf{o}(T)], \quad (1)$$



## Konfigurace HMM



## Přechodové pravděpodobnosti $a_{ij}$

Zde: pouze tři typy:

- $a_{i,i}$  pravděpodobnost setrvání ve stavu.
- $a_{i,i+1}$  pravděpodobnost přechodu do následujícího stavu.
- $a_{i,i+2}$  pravděpodobnost přeskočení následujícího stavu (*nepoužívá se*, pouze někdy pro modely "krátkého ticha").

$$\mathbf{A} = \begin{bmatrix} 0 & a_{12} & 0 & 0 & 0 & 0 \\ 0 & a_{22} & a_{23} & a_{24} & 0 & 0 \\ 0 & 0 & a_{33} & a_{34} & a_{35} & 0 \\ 0 & 0 & 0 & a_{44} & a_{45} & 0 \\ 0 & 0 & 0 & 0 & a_{55} & a_{56} \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (2)$$

... matice má prvky pouze na diagonále a nadní (musíme se v modelu zastavit nebo jít dál, nelze jít dozadu. DTW: cesta také nesměla jít dozadu!)

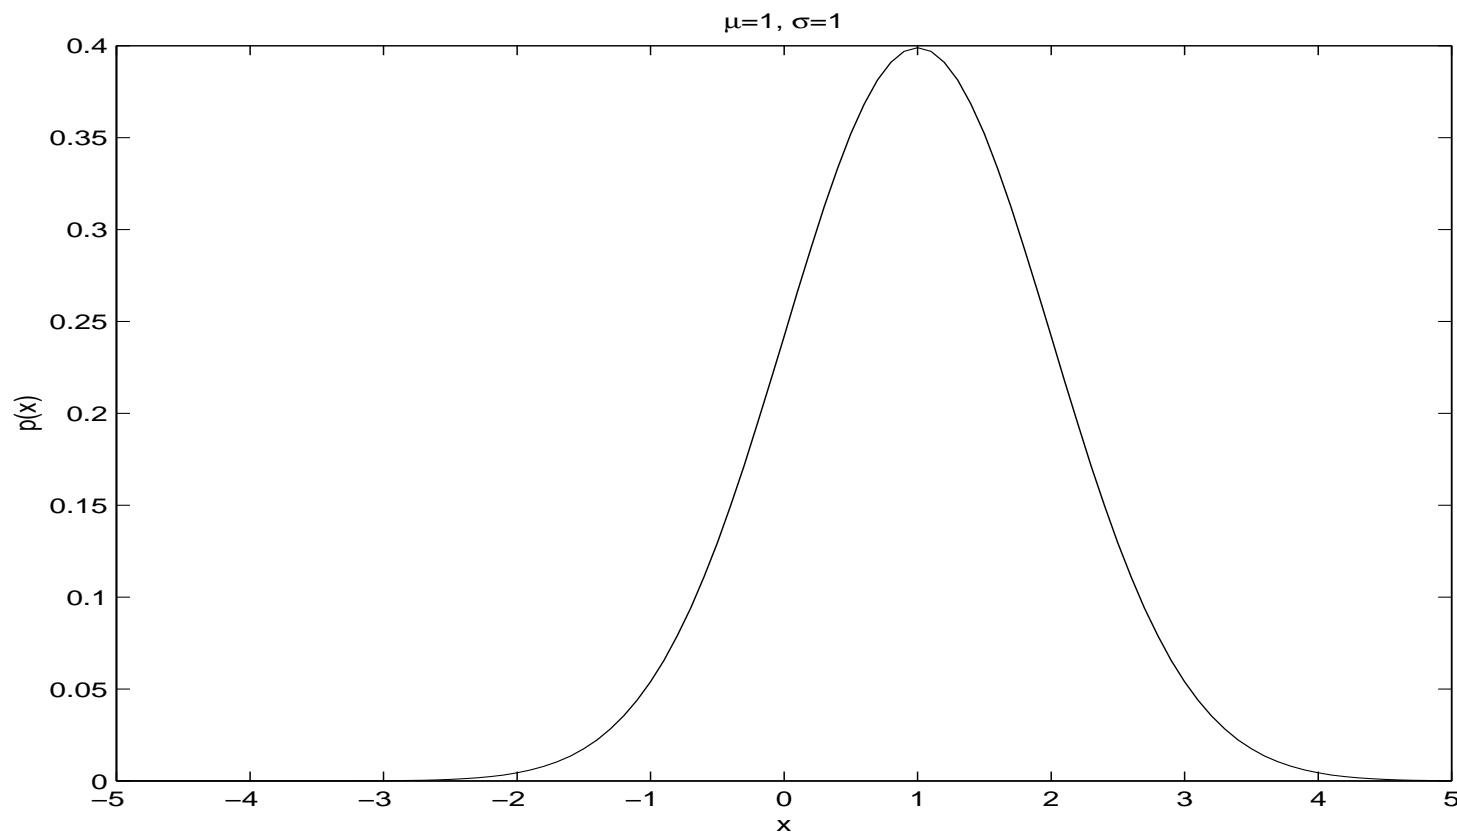
## Funkce hustoty rozložení vysílacích pravděpodobností (pdfs)

“pravděpodobnost” (pozor na statistiky!) vyslání vektoru  $\mathbf{o}(t)$   $i$ -tým stavem modelu:  $b_i[\mathbf{o}(t)]$ .

- **diskrétní:** vektory jsou pomocí VQ “předkvantovány” na symboly, stavy pak obsahují tabulky vysílacích pravděpodobností jednotlivých symbolů – nebudeme probírat.
- spojité **funkce hustoty rozložení vysílacích pravděpodobností (continuous density – CDHMM)** Funkce je definována gaussovským rozdělením pravděpodobností nebo sumou několika rozdělení.

Kdyby měl vektor  $\mathbf{o}$  jen jeden prvek:

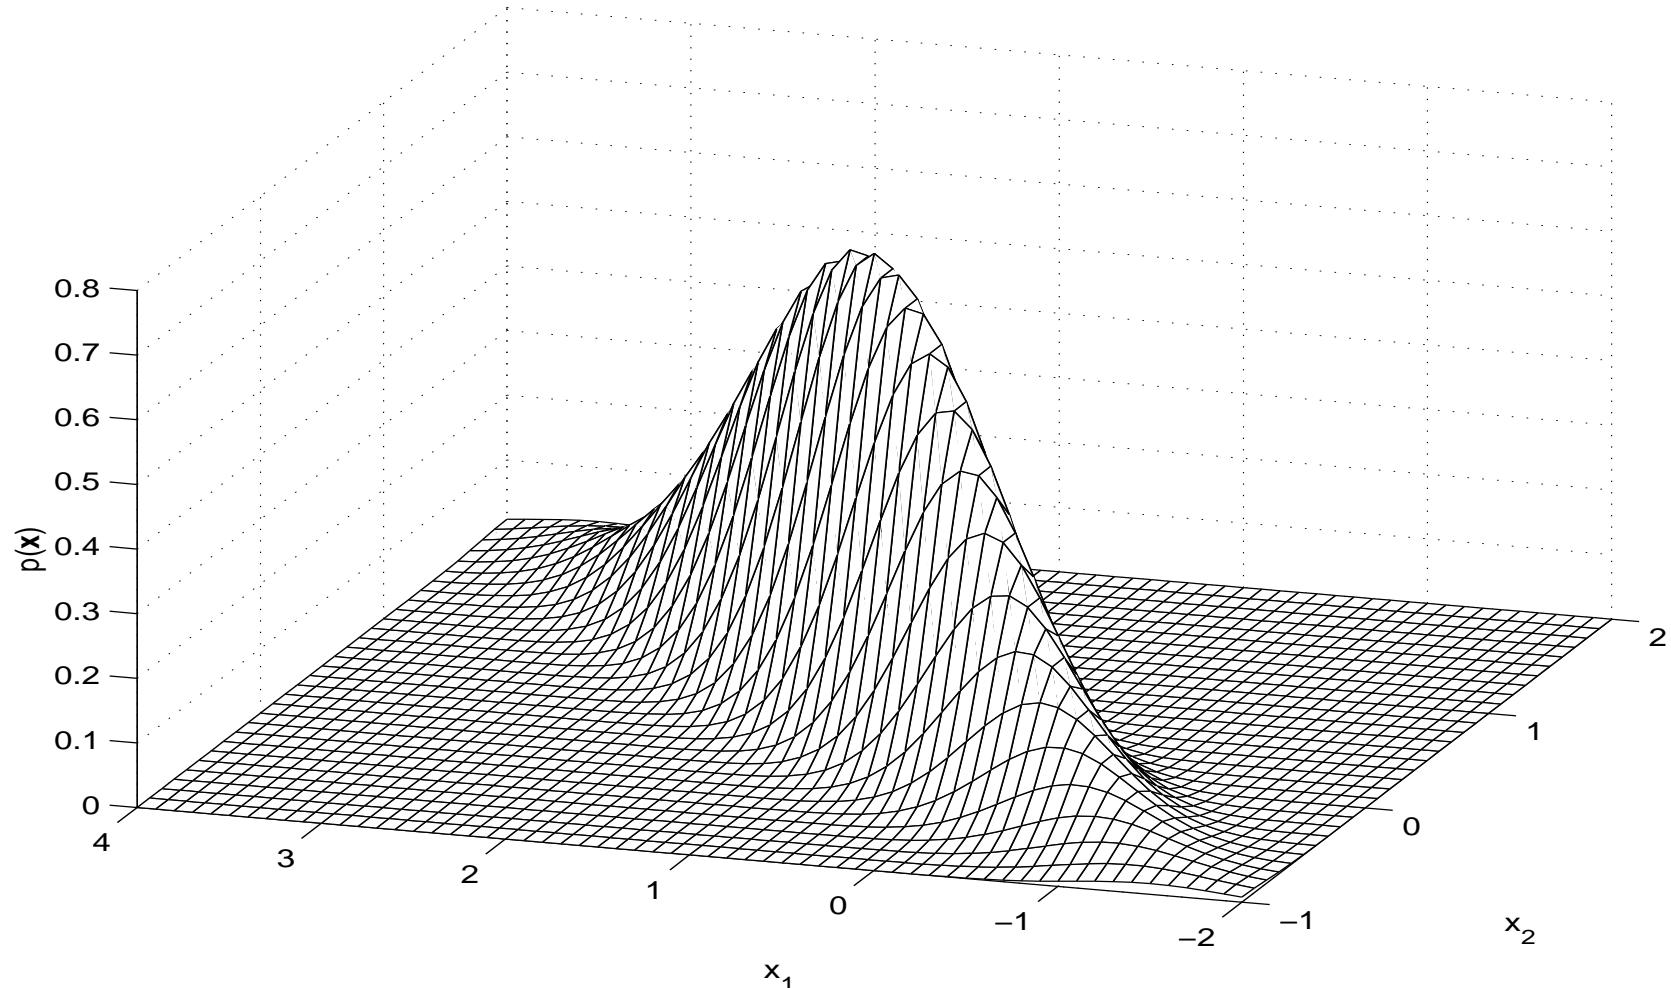
$$b_j[o(t)] = \mathcal{N}(o(t); \mu_j, \sigma_j) = \frac{1}{\sigma_j \sqrt{2\pi}} e^{-\frac{[o(t) - \mu_j]^2}{2\sigma^2}} \quad (3)$$



jenž vektor  $\mathbf{o}(t)$  je  $P$ -rozměrný (klasicky 39):

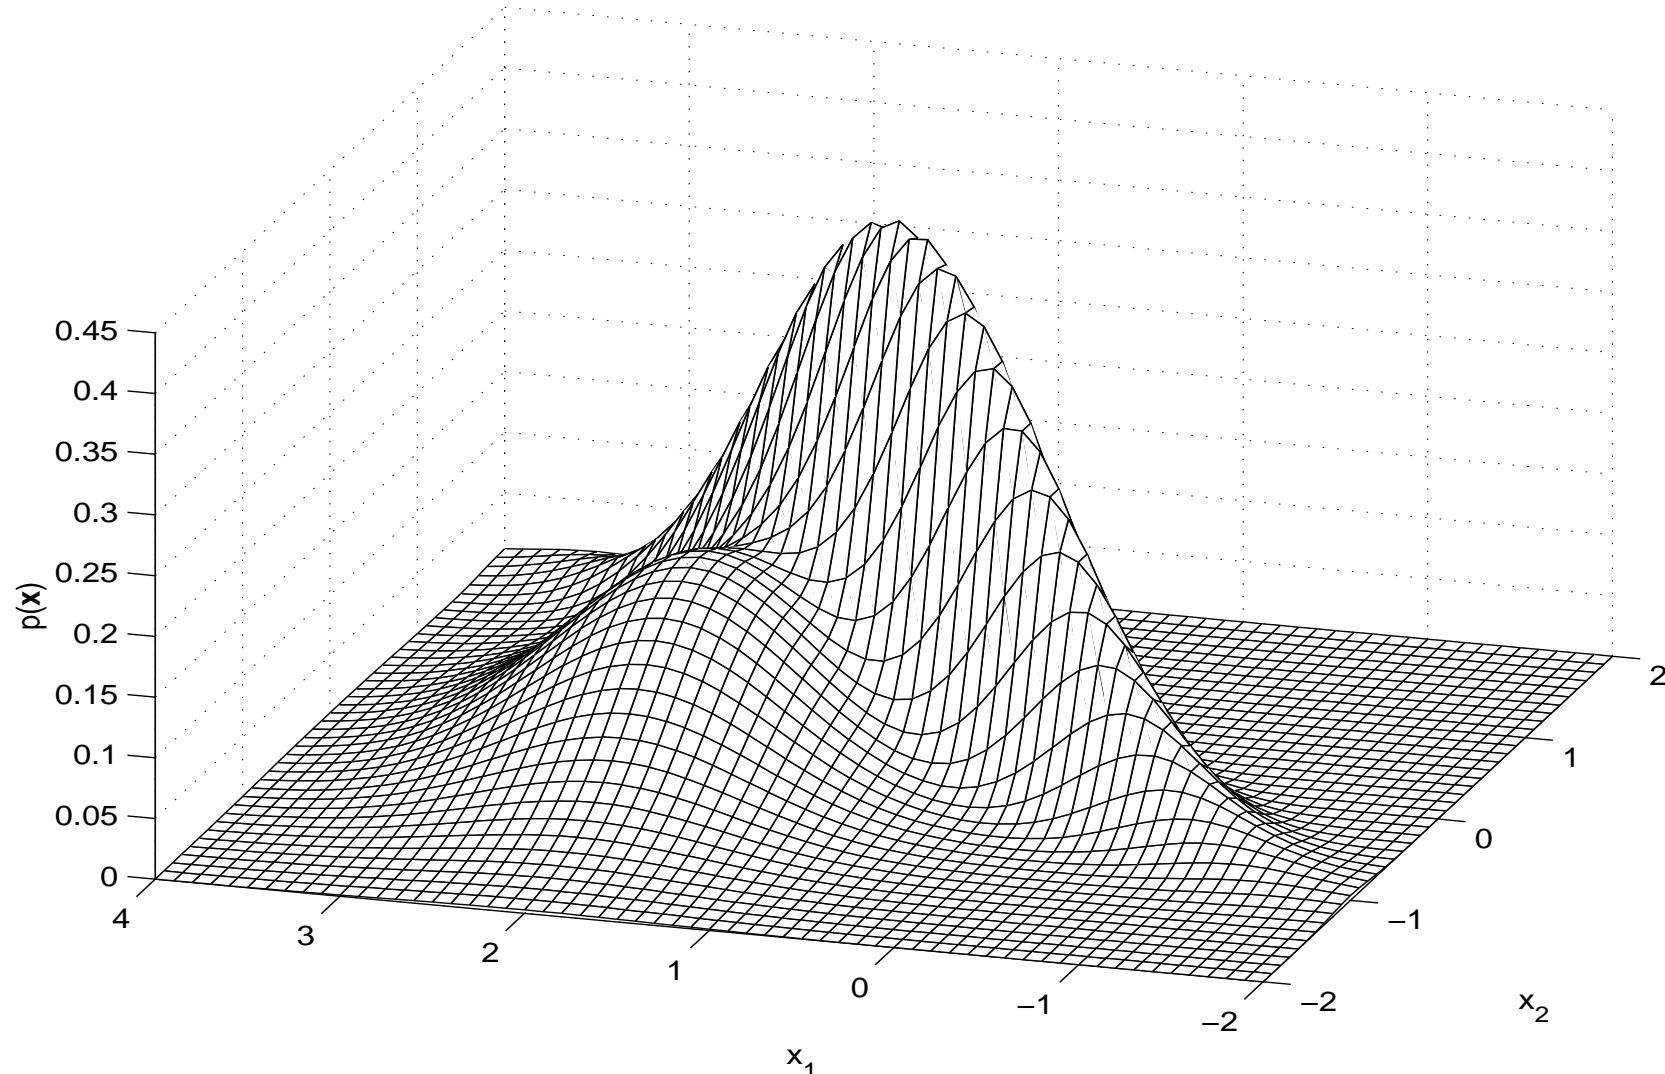
$$b_j[\mathbf{o}(t)] = \mathcal{N}(\mathbf{o}(t); \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j) = \frac{1}{\sqrt{(2\pi)^P |\boldsymbol{\Sigma}_j|}} e^{-\frac{1}{2}(\mathbf{o}(t) - \boldsymbol{\mu}_j)^T \boldsymbol{\Sigma}_j^{-1} (\mathbf{o}(t) - \boldsymbol{\mu}_j)}, \quad (4)$$

$$\boldsymbol{\mu} = [1; 0.5]; \boldsymbol{\Sigma} = [1 \ 0.5; 0.5 \ 0.3]$$



... definice směsí Gaussových rozdělení (bez rovnice):

$$\mu_1 = [1; 0.5]; \Sigma_1 = [1 \ 0.5; 0.5 \ 0.3]; w_1 = 0.5; \mu_2 = [2; 0]; \Sigma_2 = [0.5 \ 0; 0 \ 0.5]; w_2 = 0.5;$$



## Zjednodušení rozdělení pravděpodobnosti:

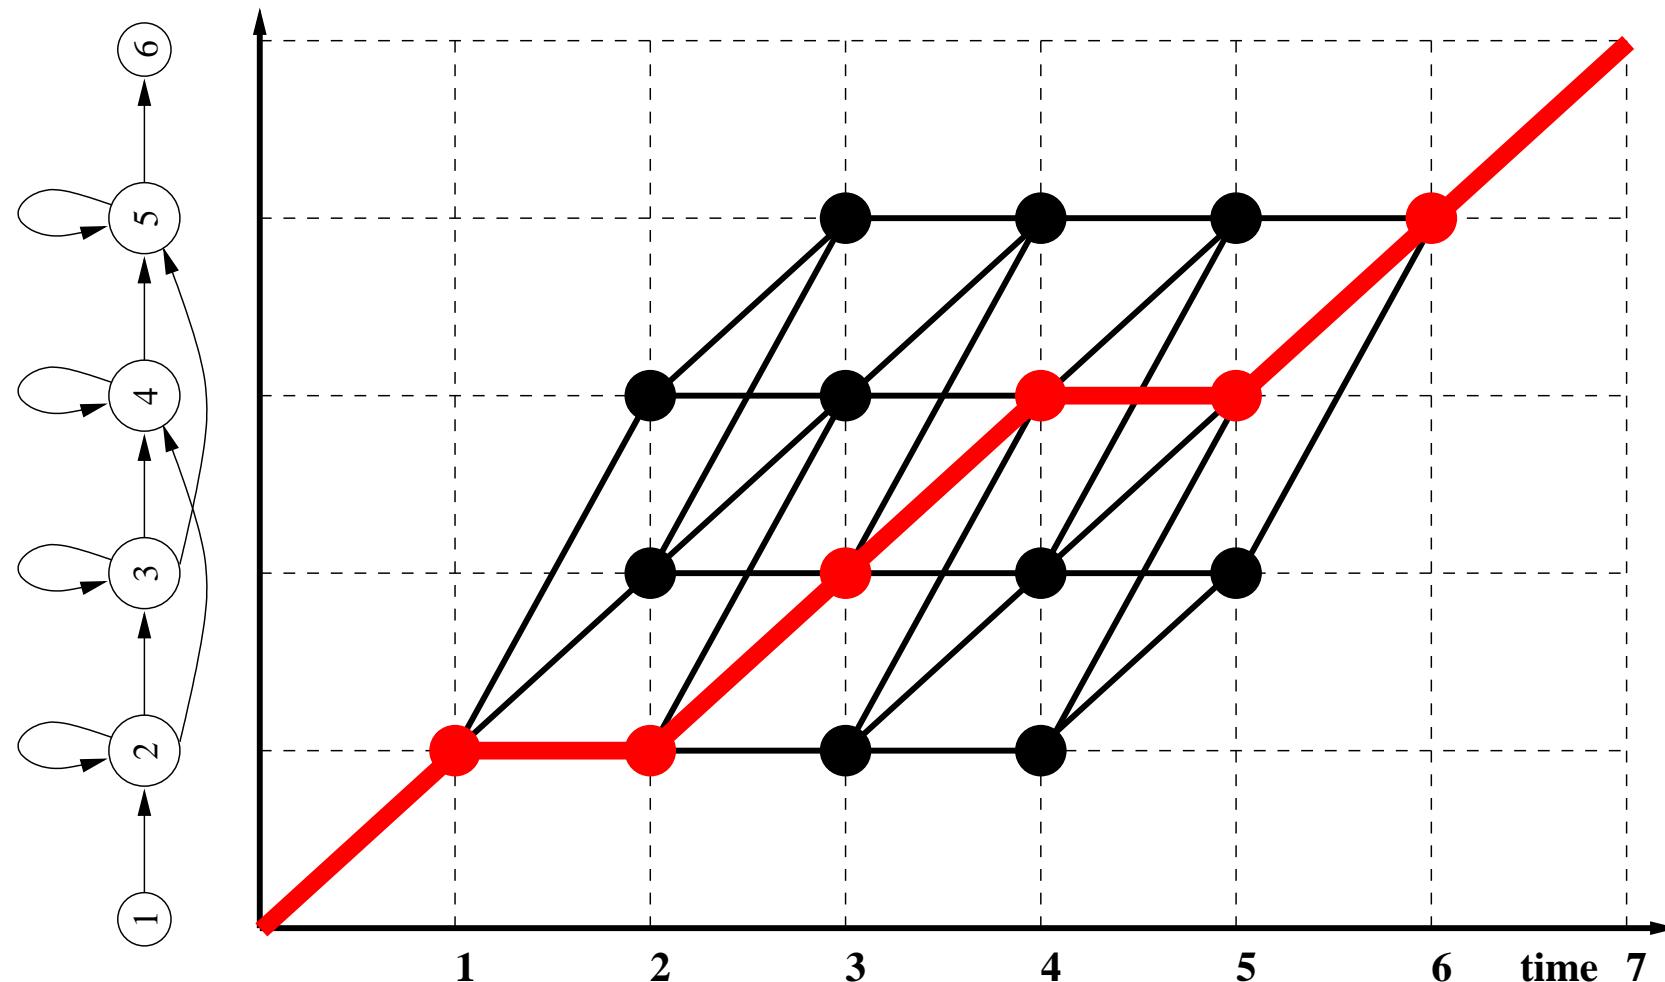
- pokud nejsou parametry korelovány (nebo doufáme, že nejsou), jejich kovarianční matice je diagonální  $\Rightarrow$  namísto  $P \times P$  kovariančních koeficientů stačí odhadnout  $P$  směrodatných odchylek (rozptylů)  $\Rightarrow$  jednodušší modely, dostatek dat k odhadu, hodnota rozdělení dána pouze součinem 1-rozměrných Gauss. rozdělení (bez determinantu a inverze):

$$b_j[o(t)] = \prod_{i=1}^P \mathcal{N}(o(t); \mu_{ji}, \sigma_{ji}) = \prod_{i=1}^P \frac{1}{\sigma_{ji} \sqrt{2\pi}} e^{-\frac{[o(t) - \mu_{ji}]^2}{2\sigma_{ji}^2}} \quad (5)$$

- sady parametrů nebo celé *stavy* mohou být sdílené mezi modely  $\Rightarrow$  méně parametrů, spolehlivější odhad, méně paměti.

## Pravděpodobnosti, že model $M$ generuje sekvenci $O$

**Stavová sekvence:** stavy přiřadíme vektorům, např:  $X = [1 \ 2 \ 2 \ 3 \ 4 \ 4 \ 5 \ 6]$ .  
state



pravděpodobnost generování  $\mathbf{O}$  po cestě  $X$ :

$$\mathcal{P}(\mathbf{O}, X|M) = a_{x(o)x(1)} \prod_{t=1}^T b_{x(t)}(\mathbf{o}_t) a_{x(t)x(t+1)}, \quad (6)$$

Jak definovat *jednu* pravděpodobnost generování sekvence vektorů modelem ?

a) BAUM-WELCH:

$$\mathcal{P}(\mathbf{O}|M) = \sum_{\{X\}} \mathcal{P}(\mathbf{O}, X|M), \quad (7)$$

bereme sumu přes všechny stavové sekvence délky  $T + 2$ .

b) VITERBI:

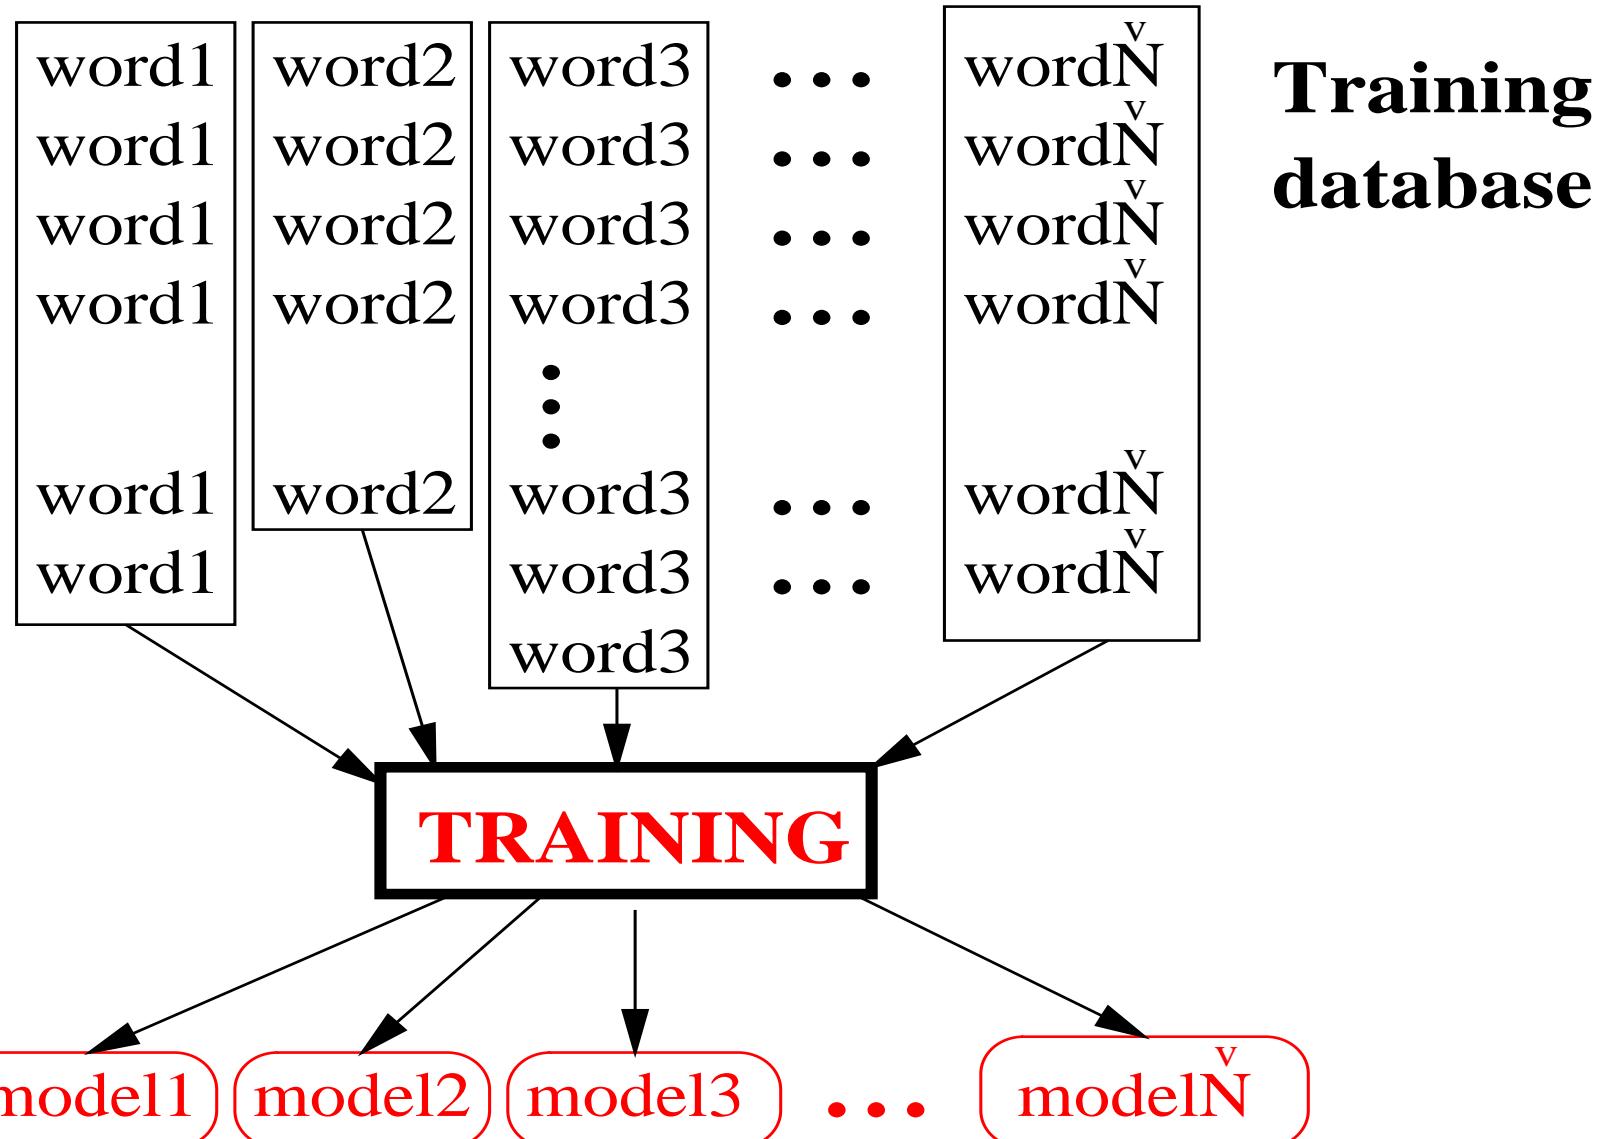
$$\mathcal{P}^*(\mathbf{O}|M) = \max_{\{X\}} \mathcal{P}(\mathbf{O}, X|M), \quad (8)$$

je pravděpodobnost optimální cesty.

## Poznámky

1. U DTW jsme hledali *minimální vzdálenost*. Zde hledáme *maximální pravděpodobnost*, někdy též *věrohodnost*  $\mathcal{L}$ .
2. Rychlé algoritmy pro implementaci výpočtu jak BAUM-WELCHE, tak VITERBIHO: není nutné vyhodnocovat všechny možné stavové sekvence  $X$ .

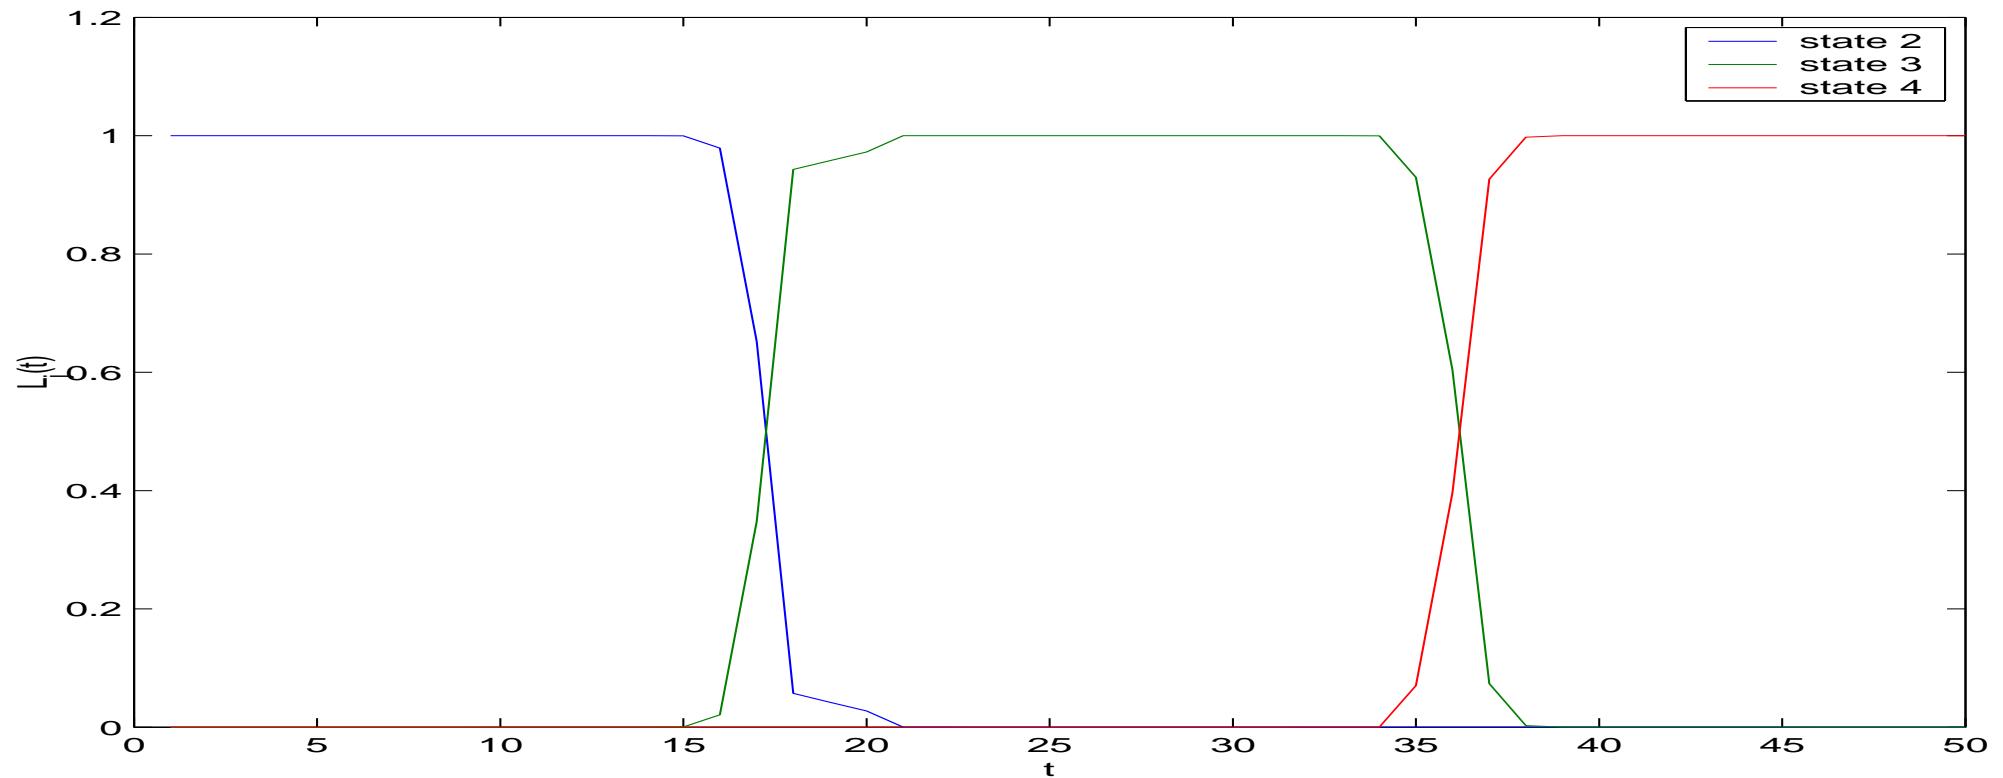
## Trénování parametrů (nejsou v tabulkách :-)) ...)



1. parametry modelu jsou **zhruba odhadnuty**:

$$\hat{\boldsymbol{\mu}} = \frac{1}{T} \sum_{t=1}^T \mathbf{o}(t) \quad \hat{\boldsymbol{\Sigma}} = \frac{1}{T} \sum_{t=1}^T (\mathbf{o}(t) - \hat{\boldsymbol{\mu}})(\mathbf{o}(t) - \hat{\boldsymbol{\mu}})^T \quad (9)$$

2. vektory jsou **přiřazeny stavům**: "natvrdo" nebo "měkce" pomocí funkce  $L_j(t)$  (state occupation function).



### 3. nové odhadы параметрů:

$$\hat{\boldsymbol{\mu}}_j = \frac{\sum_{t=1}^T L_j(t) \mathbf{o}(t)}{\sum_{t=1}^T L_j(t)} \quad \hat{\boldsymbol{\Sigma}}_j = \frac{\sum_{t=1}^T L_j(t) (\mathbf{o}(t) - \hat{\boldsymbol{\mu}}_j)(\mathbf{o}(t) - \hat{\boldsymbol{\mu}}_j)^T}{\sum_{t=1}^T L_j(t)}. \quad (10)$$

... podobné vzorce pro odhad přechodových pravděpodobností  $a_{ij}$ .

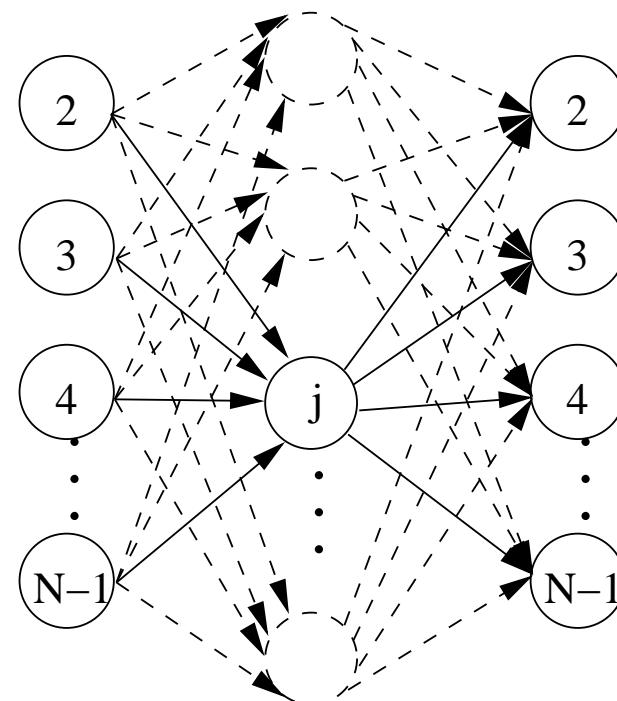
Kroky 2) a 3) se opakují: kritérium pro stop je fixní počet iterací nebo moment, kdy už se nezvětšují pravděpodobnosti.

- algoritmus se označuje jako EM (Expectation Maximization): dá se odvodit tak, že počítáme  $\sum p(\text{každého vektoru}|\text{staré parametry}) \times \log p(\text{každého vektoru}|nove parametry)$ , což je vlastně očekávání (průměr na datech) celkové likelihood. Toto je kriteriální funkce, kterou maximalizujeme  $\Rightarrow$  vede ke zvyšování likelihood.
- maximalizujeme věrohodnost, že data budou "vyslána" modelem  $\Rightarrow$  LM (likelihood maximization) - trochu problém, protože modely učíme tak, aby nejlépe reprezentovaly jednotlivá slova, ale ne aby mezi němi **diskriminovaly**.

## Jak na state occupation functions

Pravděpodobnost  $L_j(t)$  "bytí ve stavu  $j$  v čase  $t$ " můžeme spočítat jako sumu všech cest, které v čase  $t$  projdou stavem  $j$ :  $P(\mathbf{O}, x(t) = j | M)$

TIME:  $t-1$   $t$   $t+1$



Potřebujeme ale zajistit, aby to byly opravdové pravděpodobnosti, tedy:

$$\sum_{j=1}^N L_j(t) = 1, \quad (11)$$

jinými slovy: příspěvek jednoho vektoru všem stavům musí být přesně 100%. Musíme normalizovat sumou pravděpodobností (ne ! správně věrohodností !) všech cest, které projdou čímkoliv v čase  $t$

$$L_j(t) = \frac{P(\mathbf{O}, x(t) = j | M)}{\sum_j P(\mathbf{O}, x(t) = j | M)}. \quad (12)$$

... jenže to už jsou opravdu všechny cesty modelem, takže můžeme normalizovat BAUM-WELCHOVOU pravděpodobností:

$$L_j(t) = \frac{P(\mathbf{O}, x(t) = j | M)}{P(\mathbf{O} | M)}. \quad (13)$$

## Jak na $P(\mathbf{O}, x(t) = j|M)$

1. Výpočet částečných dopředných pravděpodobností (začal jsem na začátku modelu a v čase  $t$  jsem ve stavu  $j$ ):

$$\alpha_j(t) = \mathcal{P}(\mathbf{o}(1) \dots \mathbf{o}(t), x(t) = j | M) \quad (14)$$

2. Výpočet částečných zpětných pravděpodobností (začal jsem na konci modelu a v čase  $t$  jsem ve stavu  $j$ ):

$$\beta_j(t) = \mathcal{P}(\mathbf{o}(t+1) \dots \mathbf{o}(T) | x(t) = j, M) \quad (15)$$

3. state occupation function je pak definována:

$$L_j(t) = \frac{\alpha_j(t)\beta_j(t)}{P(\mathbf{O}|M)} \quad (16)$$

... více v HTK Book.

## Algoritmus trénování modelů

1. Alokuj akumulátor pro každý odhadovaný vektor/matici.
2. Spočítej dopředné a zpětné pravd.  $\alpha_j(t)$  a  $\beta_j(t)$  pro všechny časy  $t$  a všechny stavy  $j$ .  
Spočítej state occupation functions  $L_j(t)$ .
3. Ke každému akumulátoru přidej příspěvek od vektoru  $\mathbf{o}(t)$  vážený příslušnou  $L_j(t)$ .
4. Použij konečnou hodnotu akumulátoru pro odhad vektoru/matice pomocí rovnice 10  
— nesmíme zapomenout na normování výrazem  $\sum_{t=1}^T L_j(t)$ .
5. Pokud se hodnota  $\mathcal{P}(\mathbf{O}|M)$  od minulé iterace podstatně nezměnila, stop, jinak Goto 1.

## Rozpoznávání – Viterbiho algoritmus

- máme rozpozнат neznámou sekvenci  $\mathbf{O}$ .
- ve slovníku máme  $\check{N}$  slov  $w_1 \dots w_{\check{N}}$ .
- pro každé máme natrénovaný model  $M_1 \dots M_{\check{N}}$ .
- Otázka zní: "Který model by generoval  $\mathbf{O}$  s největší pravděpodobností ?"

$$i^* = \arg \max_i \{\mathcal{P}(\mathbf{O}|M_i)\} \quad (17)$$

použijeme VITERBIHO pravd. pro nejpravděpodobnější stavovou sekvenci:

$$\mathcal{P}^*(\mathbf{O}|M) = \max_{\{X\}} \mathcal{P}(\mathbf{O}, X|M). \quad (18)$$

takže:

$$i^* = \arg \max_i \{\mathcal{P}^*(\mathbf{O}|M_i)\}. \quad (19)$$

## Výpočet VITERBIHO pravd.:

– podobné jako BAUM-WELCH.

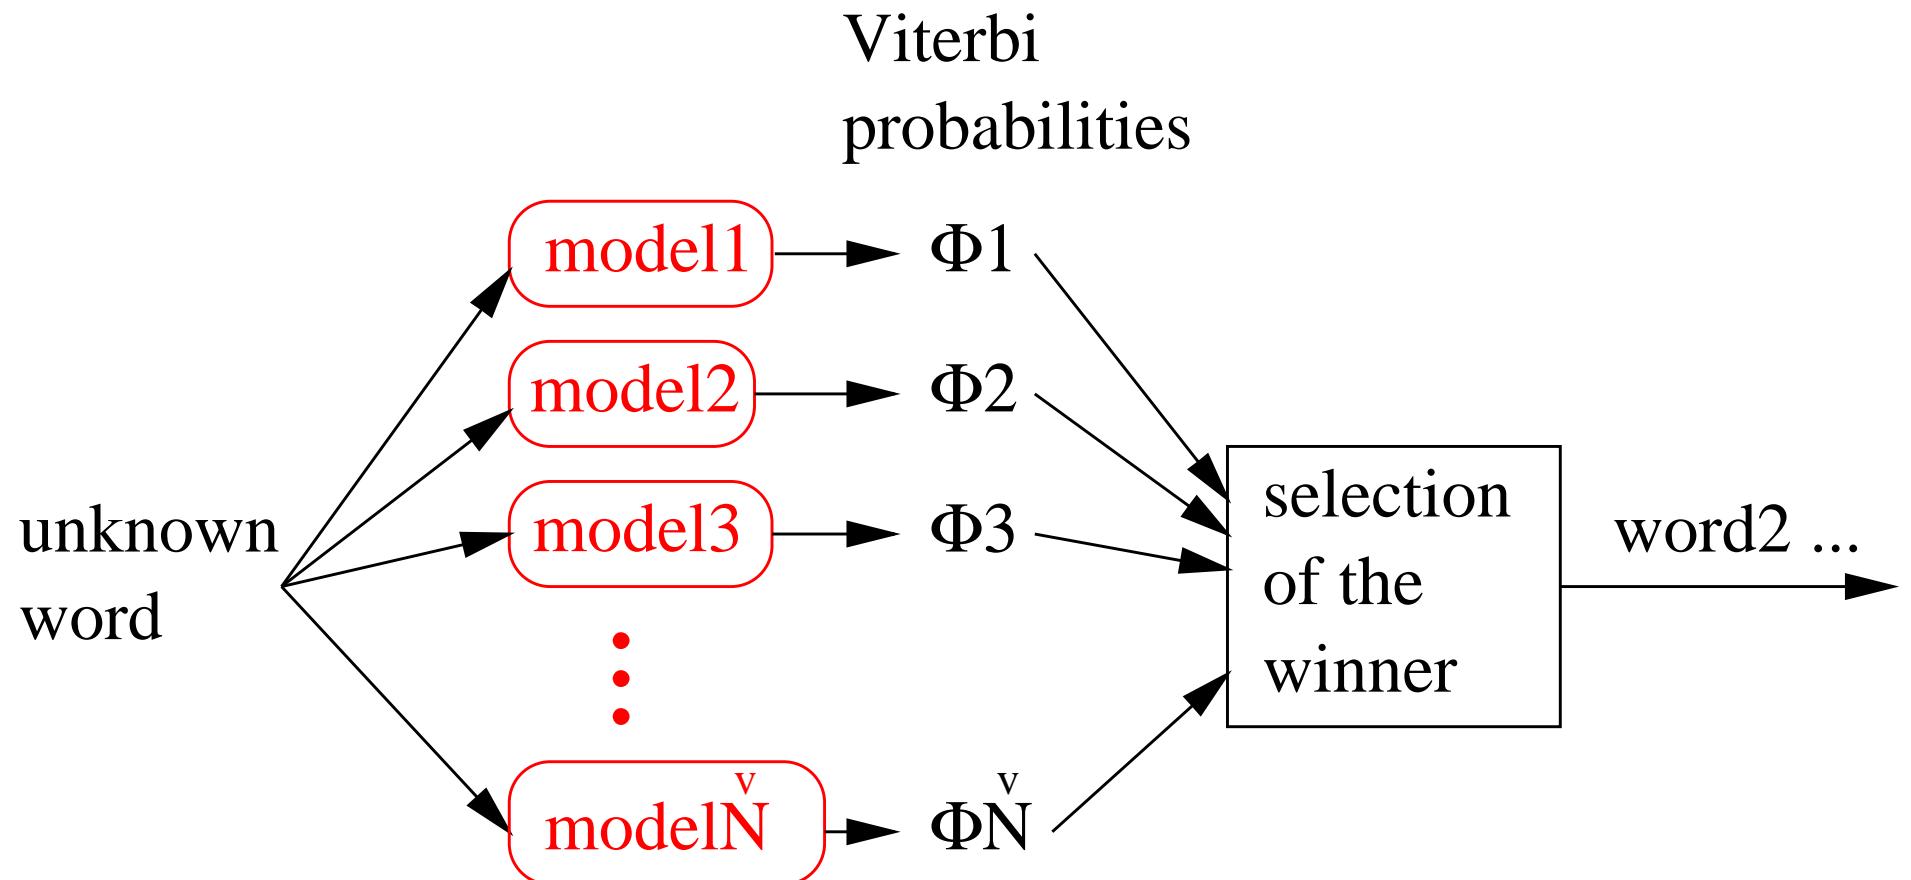
Částečná VITERBIHO pravd.:

$$\Phi_j(t) = \mathcal{P}^{\star} (\mathbf{o}(1) \dots \mathbf{o}(t), x(t) = j | M) . \quad (20)$$

Pro  $j$ -tý stav a čas  $t$ . Žádaná VITERBIHO pravd je:

$$\mathcal{P}^{\star}(\mathbf{O}|M) = \Phi_N(T) \quad (21)$$

## Rozpoznávání izolovaných slov pomocí HMM



## Viterbi jinak: Token passing – předávání půllitrů

každý stav modelu může obsahovat půllitr s pivem. Pracujeme s log pravděpodobnostmi, součiny  $\Rightarrow$  součty. Budeme dolévat pravděpodobnosti.

**Inicialisace:** vlož prázdný půllitr do každého vstupního stavu modelu (běžně pouze stav 1.).

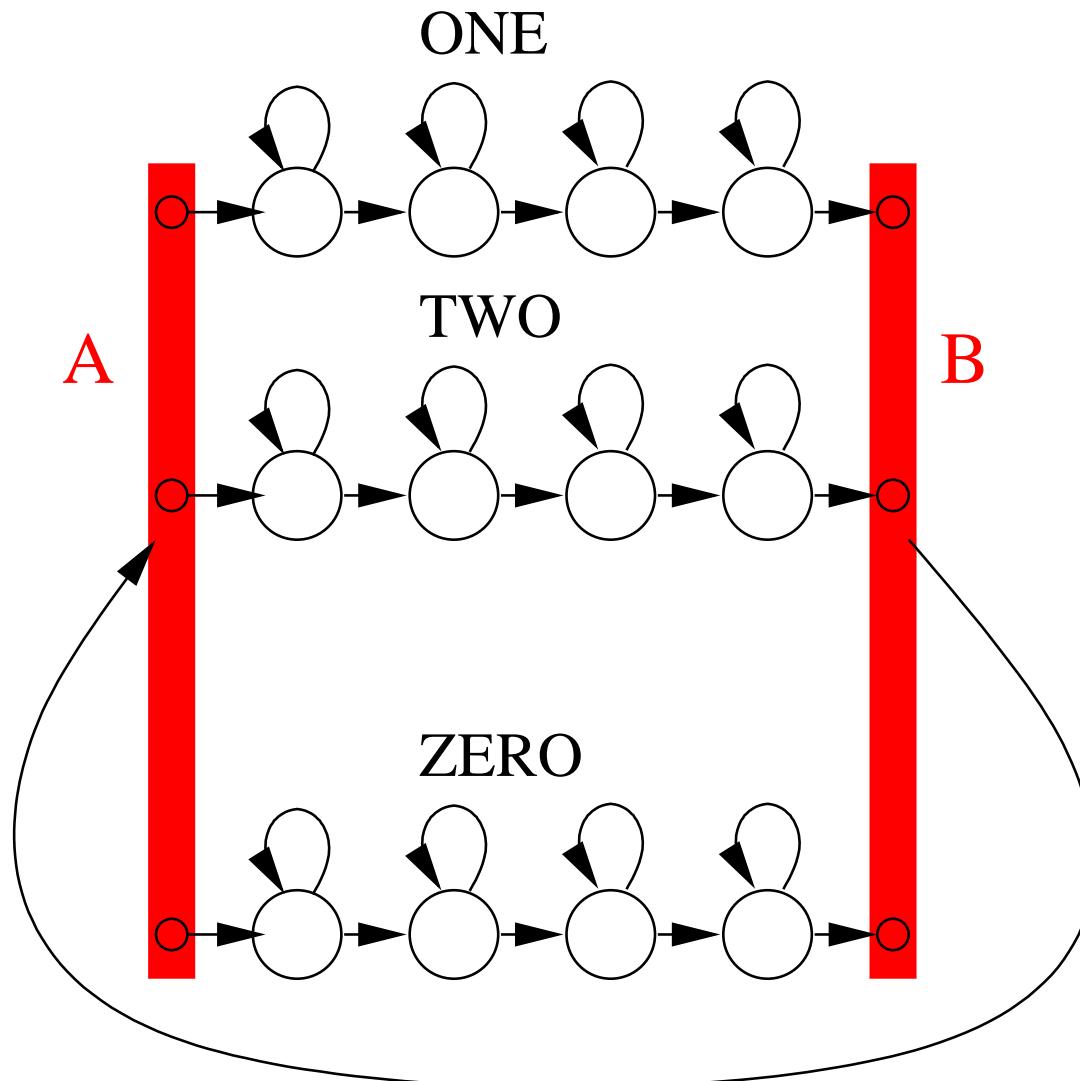
**Iterace:** pro časy  $t = 1 \dots T$ :

- v každém stavu  $i$ , který obsahuje půllitr, tento naklonuj a pošli kopii do všech napojených stavů  $j$ . Po cestě dolej  $\log a_{ij} + \log b_j[\mathbf{o}(t)]$ .
- pokud se v nějakém stavu nachází více než jeden půllitr, nechej jen ten nejplnější, zahod zbytek.

**Konec:** ze všech stavů  $i$  spojených s výstupním stavem  $N$ , které obsahují půllitr, pošli jej do  $N$  a dolej  $\log a_{iN}$ . V posledním stavu  $N$ , vyber jen nejplnější půllitr a zahod ostatní. Hladinka piva ve stavu  $N$  odpovídá log Viterbiho pravděpodobnosti:  $\log \mathcal{P}^*(\mathbf{O}|M)$ .

## Pivo passing pro rozpoznávání spojených slov

postavíme mega-model ze všech slov, "slepíme" první a poslední stavy.



**Rozpoznávání** – podobně jako pro izolovaná slova, musíme si však pamatovat slova, kterými optimální půllitr prošel.



## Další čtení

- HTK Book - <http://htk.eng.cam.ac.uk/>
- Gold and Morgan: v knihovně FIT.
- Černocký - staré texty o HMM na  
<http://www.fit.vutbr.cz/~cernocky/oldspeech/>
- Počítačové cvičení HMM-HTK, staré poč. cvičení HMM-Matlab (na oldspeech).