

Hidden Markov Models

według **Bonnie Dorr** **Christof Monz**

Hidden Markov Model (HMM)

- HMM pozwala określić prawdopodobieństwo nieobserwowanej bezpośrednio sekwencji zdarzeń

$$w_1, w_2, \dots, w_n$$

- Np., obserwujemy sygnał akustyczny a ukryte są wypowiedane słowa

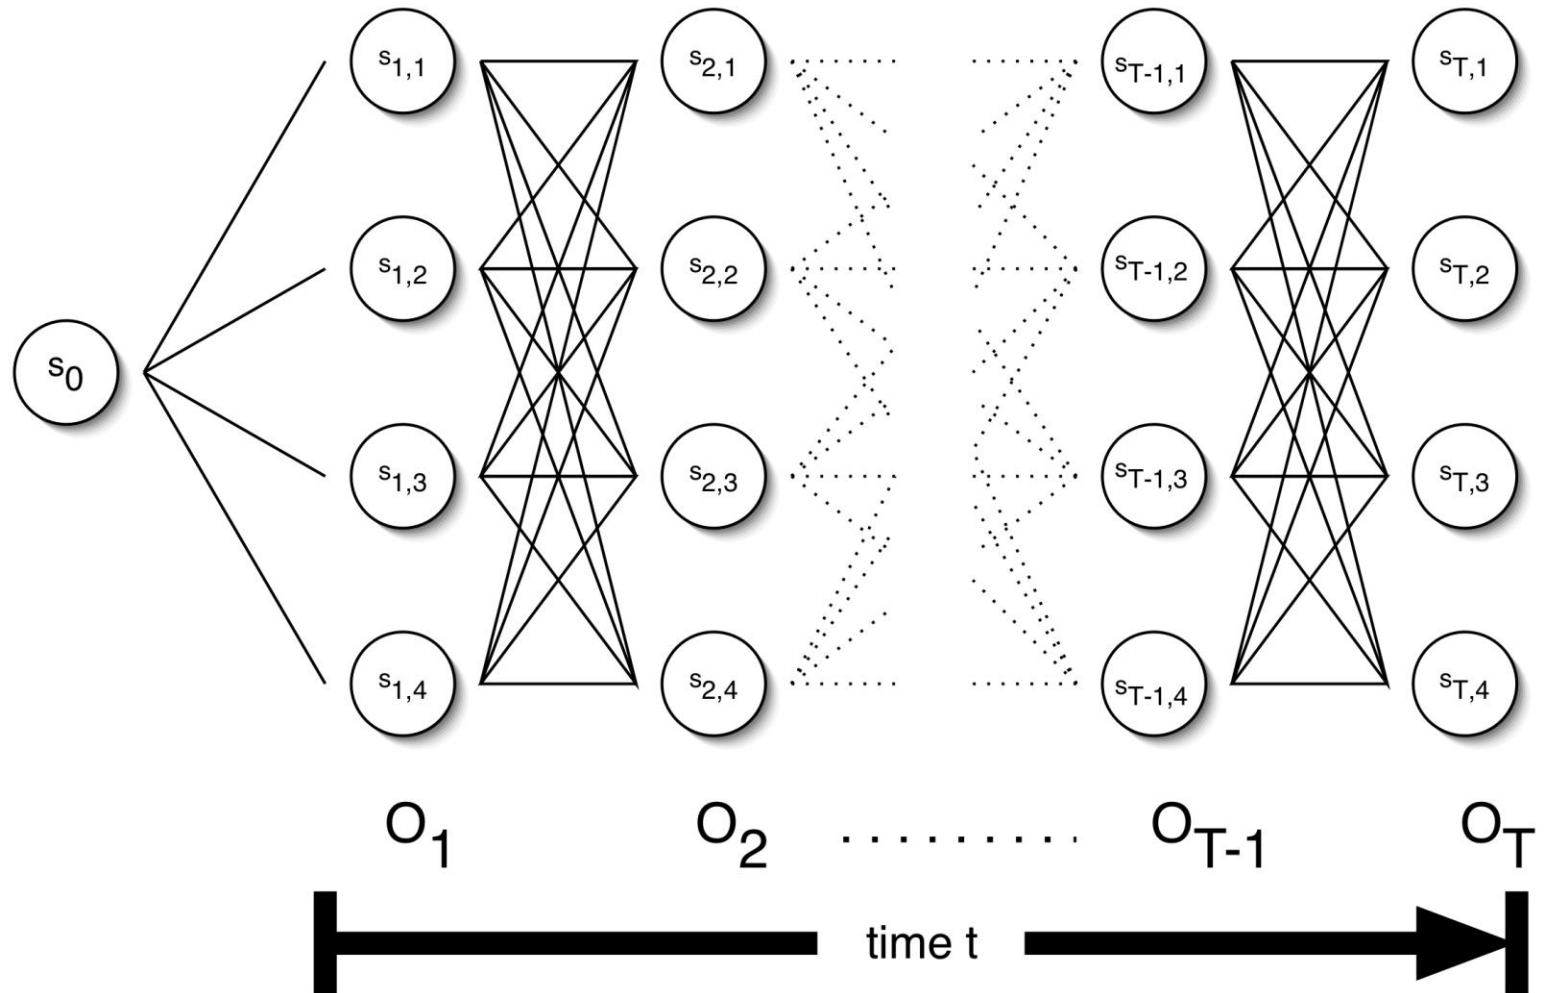
Założenie Markowa

- Prawdopodobieństwo zdarzenia w_i w czasie t zależy tylko od zdarzenia w_{i-1} w czasie $t-1$

- Ogólnie:
$$P(w_1, \dots, w_n) = \prod_{i=2}^n P(w_i | w_1, \dots, w_{i-1})$$

- Założenie Markowa:
$$P(w_1, \dots, w_n) \approx \prod_{i=2}^n P(w_i | w_{i-1})$$

The Trellis (krata)



Parametry HMM

- Stany: $S = s_1, \dots, s_n$
- Prawdopodobieństwa przejść:
 $A = a_{1,1}, a_{1,2}, \dots, a_{n,n}$.
 $a_{i,j}$ – prawdop. przejścia z s_i do s_j .
- Prawdop. emisji B: zbiór funkcji $b_i(o_t)$,
określających prawdop. (lub jego gęstość)
obserwacji o_t wyemitowanej w stanie s_i
- Prawdopop. początkowe: π_i jest
prawdopodobieństwem, że s_i jest stanem
początkowym

Trzy podstawowe problemy HMM

- Problem 1 (Ewaluacja): Mając daną sekwencję obserwacji $O=o_1, \dots, o_T$ i model HMM $\lambda = (A, B, \pi)$, obliczyć prawdopodobieństwo otrzymania tej obserwacji.
- Problem 2 (Dekodowanie): Mając daną sekwencję obserwacji $O=o_1, \dots, o_T$ i HMM $\lambda = (A, B, \pi)$, odnaleźć sekwencję stanów (najbardziej prawdopodobną ścieżkę)

Trzy podstawowe problemy HMM

- Problem 3 (Uczenie): Obliczyć HMM

$$\lambda = (A, B, \pi)$$

na maksimum $P(O | \lambda)$

Problem 1: Ewaluacja

- Jak obliczyć $P(O | \lambda)$?
- Trzeba posumować prawdopodobieństwa dla wszystkich możliwych sekwencji stanów
- Mając T obserwacji i N stanów, mamy N^T możliwych sekwencji stanów.
- Trzeba zastosować programowanie dynamiczne.


Forward Probabilities

- Mając HMM λ , czas t i stan j obliczyć prawdopodobieństwo wygenerowania częściowej sekwencji obserwacji $o_1 \dots o_t$

$$\alpha_t(j) = P(o_1 \dots o_t, q_t = s_j \mid \lambda)$$

Forward Probabilities

$$\alpha_t(j) = P(o_1 \dots o_t, q_t = s_j \mid \lambda)$$



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

Forward Algorithm

■ Inicjalizacja: $\alpha_1(i) = \pi_i b_i(o_1) \quad 1 \leq i \leq N$

■ Indukcja:

$$\alpha_t(j) = \left[\sum_{i=1}^N \alpha_{t-1}(i) a_{ij} \right] b_j(o_t) \quad 2 \leq t \leq T, 1 \leq j \leq N$$

■ Na końcu: $P(O | \lambda) = \sum_{i=1}^N \alpha_T(i)$
(N^2T operacji)

Backward Probabilities

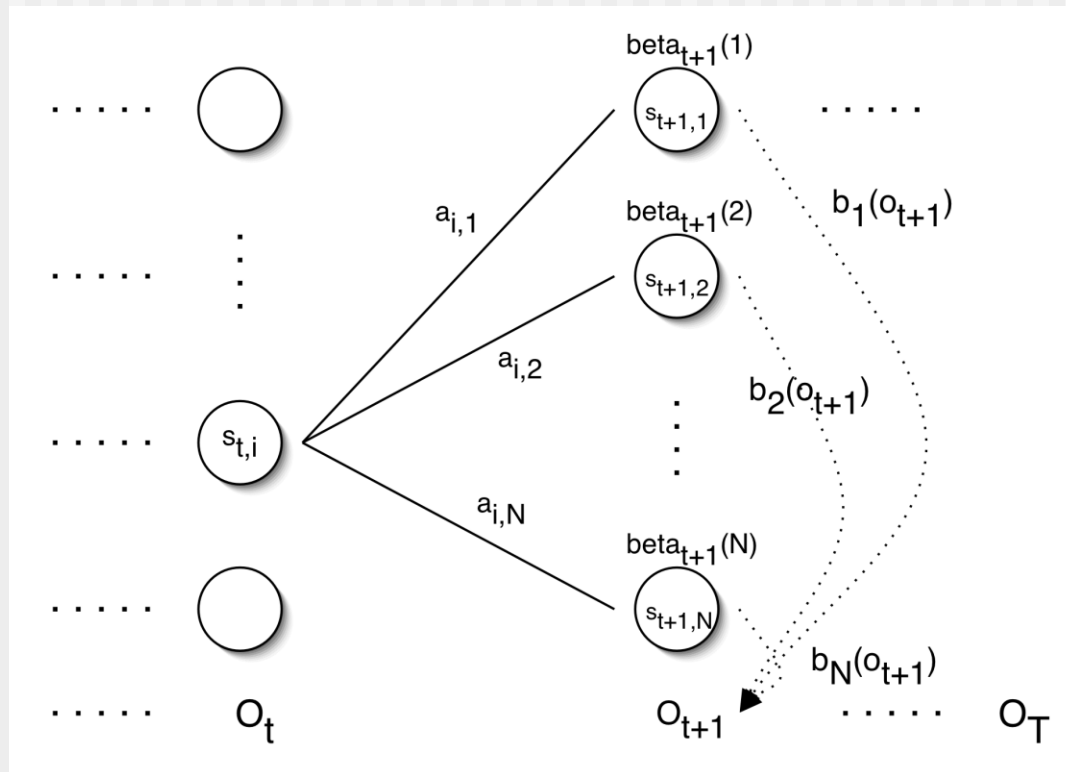
- Mając HMM λ , czas t i stan i obliczyć prawdopodobieństwo wygenerowania częściowej sekwencji obserwacji

$$O_{t+1} \cdots O_T$$

$$\beta_t(i) = P(o_{t+1} \cdots o_T \mid q_t = s_i, \lambda)$$

Backward Probabilities

$$\beta_t(i) = P(o_{t+1} \dots o_T \mid q_t = s_i, \lambda)$$



$$\beta_t(i) = \left[\sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j) \right]$$

Backward Algorithm

■ Inicjalizacja: $\beta_T(i) = 1, \quad 1 \leq i \leq N$

■ Indukcja:

$$\beta_t(i) = \left[\sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j) \right] \quad t = T-1 \dots 1, 1 \leq i \leq N$$

■ Na końcu:

$$P(O | \lambda) = \sum_{i=1}^N \pi_i \beta_1(i)$$

Problem 2: Dekodowanie

- Szukamy sekwencji stanów $Q=q_1\dots q_T$, dla których

$$Q = \arg \max_{Q'} P(Q' | O, \lambda)$$

Viterbi Algorithm

■ Inicjalizacja: $\delta_1(i) = \pi_i b_i(o_1) \quad 1 \leq i \leq N$

■ Indukcja:

$$\delta_t(j) = \left[\max_{1 \leq i \leq N} \delta_{t-1}(i) a_{ij} \right] b_j(o_t)$$

$$\psi_t(j) = \left[\arg \max_{1 \leq i \leq N} \delta_{t-1}(i) a_{ij} \right] \quad 2 \leq t \leq T, 1 \leq j \leq N$$

■ Na końcu: $p^* = \max_{1 \leq i \leq N} \delta_T(i) \quad q_T^* = \arg \max_{1 \leq i \leq N} \delta_T(i)$

■ Ścieżka: $q_t^* = \psi_{t+1}(q_{t+1}^*) \quad t = T-1, \dots, 1$

Problem 3: Uczenie

- Szukamy HMM λ' , dla którego

$$\lambda' = \operatorname{argmax}_{\lambda} P(O | \lambda)$$

gdzie $\lambda = (A, B, \pi)$

- Metoda Bauma-Welcha, EM: mając λ szukamy λ' , dla którego $P(O | \lambda') \geq P(O | \lambda)$
(algorytm lokalnie zbieżny)

Problem 3: Uczenie (alg. EM)

- Dany HMM, wykonujemy alg. Forward-Backward (Expectation)
- Estymujemy nowe parametry modelu (Maximization)

(powolna, lokalna zbieżność)