



Piotr Szczuko

UKRYTE MODELE MARKOWA

HMM - HIDDEN MARKOV MODELS

Ukryte modele Markowa

- Ukryte modele Markowa są statystyczną metodą klasyfikacji **sekwencji zdarzeń**.
- Do celów rozpoznawania mowy po raz pierwszy zostały użyte przez Bakera, Jelinka i Levinsona (firma IBM) (1975)
- Sygnał – ciąg „zdarzeń” które są **parametryzowane**
 - Segmenty 10-30ms, opisywane wektorami parametrów
 - Zakłada się, że w segmencie sygnał jest stacjonarny
 - Słowo (klasa) to ciąg **Obserwacji/zdarzeń/segmentów**

$$O = o_1, o_2, \dots, o_T$$

Gdzie T=liczba segmentów, na które podzielono słowo

Podsumowanie (1)

- **Klasa** = pojedyncze słowo
- **Obiekt** = ciąg obserwacji, sposób wypowiedzenia słowa
- **Klasyfikacja** = porównanie ciągu obserwacji do zapamiętanego wzorca

Automat skończony

Każde słowo wzorcowe (klasa) jest osobnym automatem skończonym o N -stanach:

$$Q = \{q_1, q_2, \dots, q_N\}$$

Model markowa definiujemy jako $\lambda = \langle \pi, A, B \rangle$, gdzie:

$$\pi = [\pi_1, \pi_2, \dots, \pi_N]$$

rozkład prawdopodobieństw znalezienia się w stanie q_i w chwili $t = 0$,

$$A = [a_{ij}] \quad (i, j = 1.. N)$$

Macierz prawdopodobieństw przejść między stanami,

$B = [b_i(o_j)]$ ($i = 1.. N, j = 1.. M$; M – liczba możliwych zdarzeń generowanych przez dany stan)

macierz prawdopodobieństw pojawienia się
 j -tej obserwacji w stanie q_i :

$$b_i(o_j) = P(o_j | q_i)$$

Przykład

- Model słowa „to”

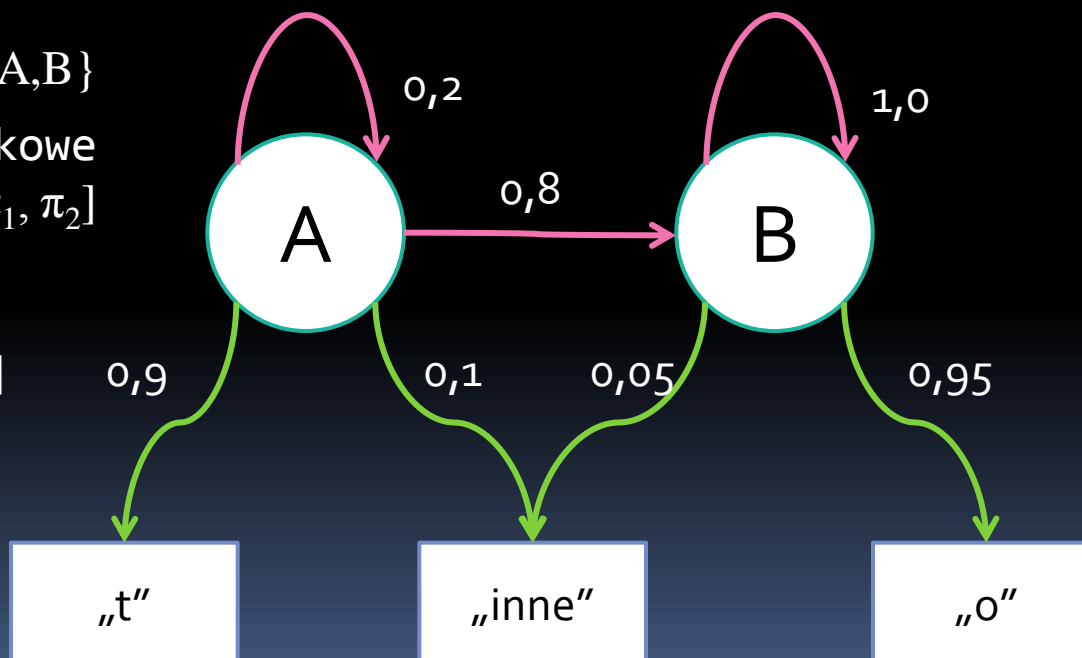
Przejścia $A = [a_{ij}]$

Stany $Q = \{q_1, q_2\} = \{A, B\}$

P-stwa początkowe

$\pi = [\pi_1, \pi_2]$

$B = [b_i(o_j)]$



Obserwacje:

Budowa klasyfikatora

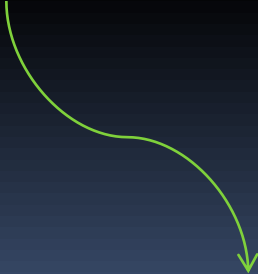
- Przygotowanie danych:
 - Rejestracja sygnałów, segmentacja, parametryzacja,
 - Słownik - transkrypcja słów na obserwacje (np. „wszy”, „ośem”)
 - Gramatyka – jakie słowa występują po sobie (np. „skasuj+to”)
- Trenowanie ukrytych modeli Markowa na podstawie każdej z reprezentacji danego słowa
 - Np. wszystkich powtórzeń słowa „to”
 - Określenie złożoności modelu (liczby stanów modelu),
 - Prowadzi do wyznaczenia $\lambda = \langle \pi, A, B \rangle$ dla każdego słowa
- Opracowanie procedury klasyfikacji (o tym dalej)

Trening

- Algorytmy:
 - Viterbiego,
 - Baum-Welcha,
 - „embedded training”.
- Problemy:
 - Segmentacja sygnału mowy
 - Stałe odcinki czasowe?
 - Segmentacja podyktowana maksymalizacją p-stwa generowania danej obserwacji
 - Konieczna kwantyzacja obserwacji (wyznaczanie p-stw występowania dowolnej obserwacji w dowolnym stanie jest praktycznie nierealizowalne).

Klasyfikacja

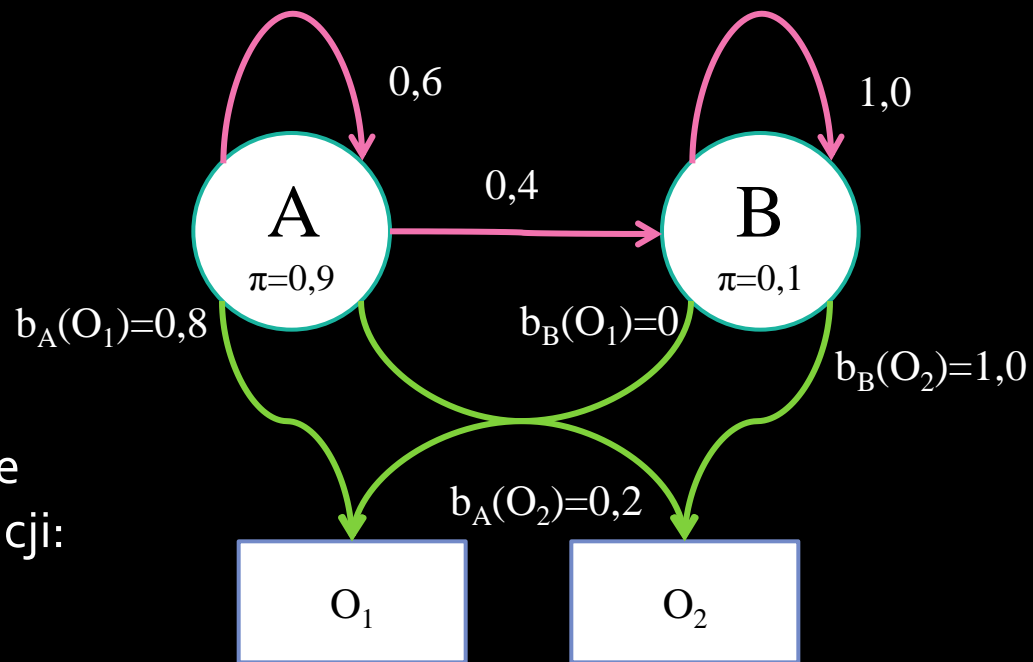
- Stwierdzenie, który model najlepiej pasuje do danego ciągu wejściowego.
 - tj. ma największe prawdopodobieństwo wygenerowania tego konkretnego ciągu zdarzeń.
 - obliczanie p-stwa (iteracyjne):

$$\alpha_1(i) = \pi_1 \cdot b_i(O_1)$$


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

Przykład

- Jakie dla tego modelu jest p-stwo zajścia ciągu obserwacji $O = \{O_1, O_1, O_1\}$
- Uwzględnić wszystkie stany, które mogą prowadzić do tych obserwacji: AAA, AAB, ~~ABA~~, ABB, BBB



$$P(AAA) = \pi_A \cdot \alpha_{AA} \cdot \alpha_{AA} = 0,9 \cdot 0,6 \cdot 0,6 = 0,324$$

$P(\dots) = \dots$ – p-stwo wystąpienia sekwencji stanów (dla wszystkich)

$$P(O/AAA) = b_A(O_2) \cdot b_A(O_2) \cdot b_A(O_2) = 0,2 \cdot 0,2 \cdot 0,2 = 0,008$$

$P(O/\dots) = \dots$ – p-stwo obserwacji $O = \{O_2, O_2, O_2\}$ dla sekwencji (dla wszystkich)

$$P(O/AAA) \cdot P(AAA) = 0,008 \cdot 0,324 = 0,002592$$

$P(O/\dots) \cdot P(\dots) = \dots$ - p-stwo całkowite

$$P(O/M) = P(O/AAA) \cdot P(AAA) + P(O/AAB) \cdot P(AAB) + P(O/ABB) \cdot P(ABB) + P(O/BBB) \cdot P(BBB)$$

$P(O/M)$ – p-stwo zajścia obserwacji O dla tego modelu M

Łącznie N^T obliczeń

N-stanów

T-długość obserwacji

Przykład

$$\alpha_1(i) = \pi_i \cdot b_i(O_1)$$

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

$$\alpha_1(A) = \pi_A \cdot b_A(O_2) = 0,9 \cdot 0,2 = 0,18$$

$$\alpha_1(B) = \pi_B \cdot b_B(O_2) = 0,1 \cdot 1,0 = 0,10$$

$$\alpha_2(A) = (\alpha_1(A) \cdot a_{AA} + \alpha_1(B) \cdot a_{BA}) \cdot b_A(O_2) = (0,18 \cdot 0,6 + 0,1 \cdot 0,0) \cdot 0,2 = 0,0216$$

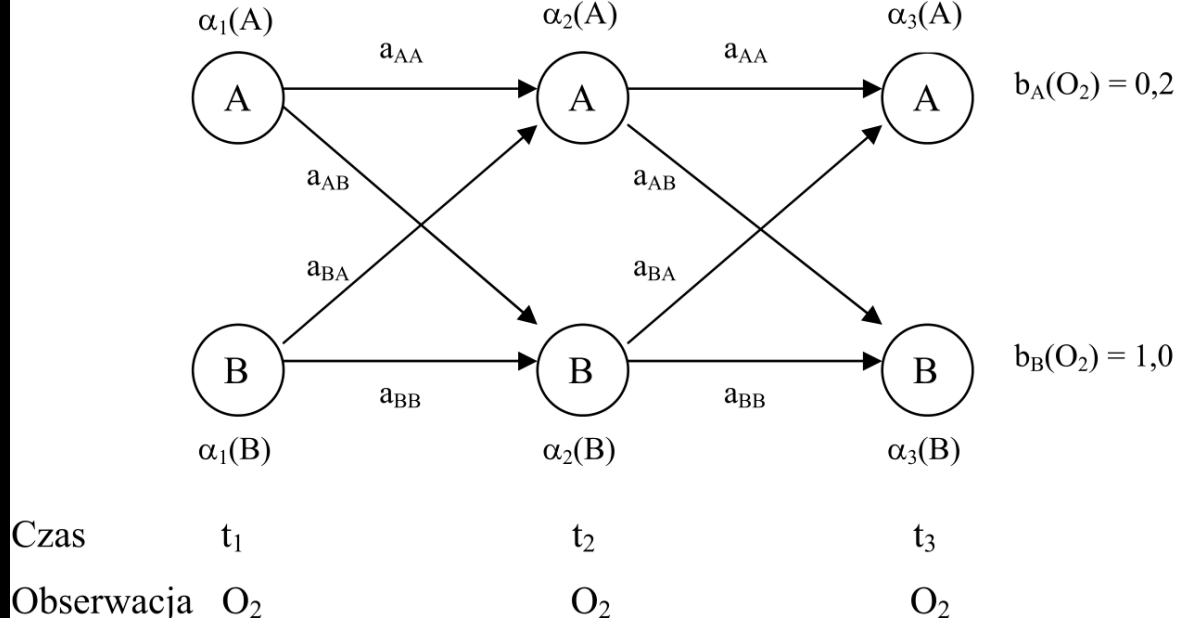
$$\alpha_2(B) = (\alpha_1(A) \cdot a_{AB} + \alpha_1(B) \cdot a_{BB}) \cdot b_B(O_2) = (0,18 \cdot 0,4 + 0,1 \cdot 1,0) \cdot 1,0 = 0,172$$

$$\alpha_3(A) = (\alpha_2(A) \cdot a_{AA} + \alpha_2(B) \cdot a_{BA}) \cdot b_A(O_2) = (0,0216 \cdot 0,6 + 0,172 \cdot 0,0) \cdot 0,2 = 0,002592$$

$$\alpha_3(B) = (\alpha_2(A) \cdot a_{AB} + \alpha_2(B) \cdot a_{BB}) \cdot b_B(O_2) = (0,0216 \cdot 0,4 + 0,172 \cdot 1,0) \cdot 1,0 = 0,18064$$

otrzymujemy:

$$P(O/M) = \alpha_3(A) + \alpha_3(B) = 0,183232$$



Łącznie N·T obliczeń

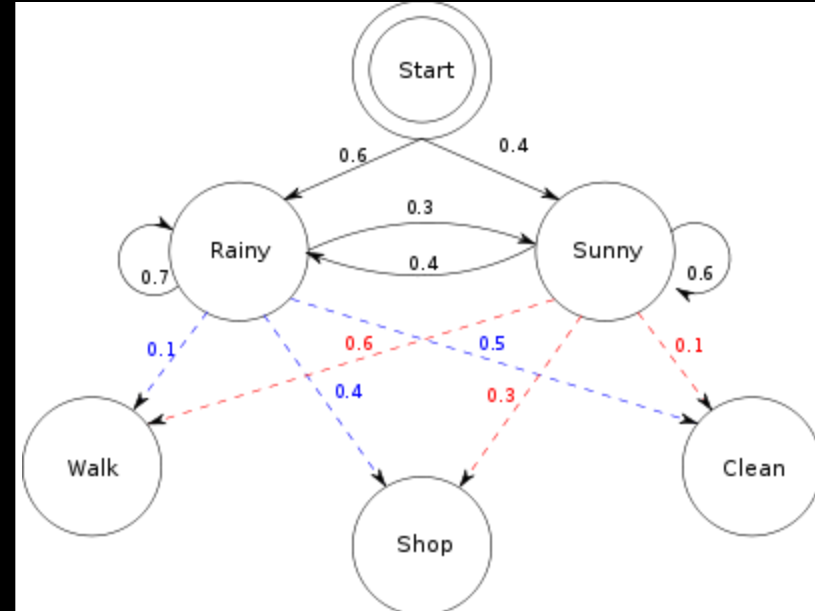
N-stanów

T-długość obserwacji

Przykład – rozmowa telefoniczna

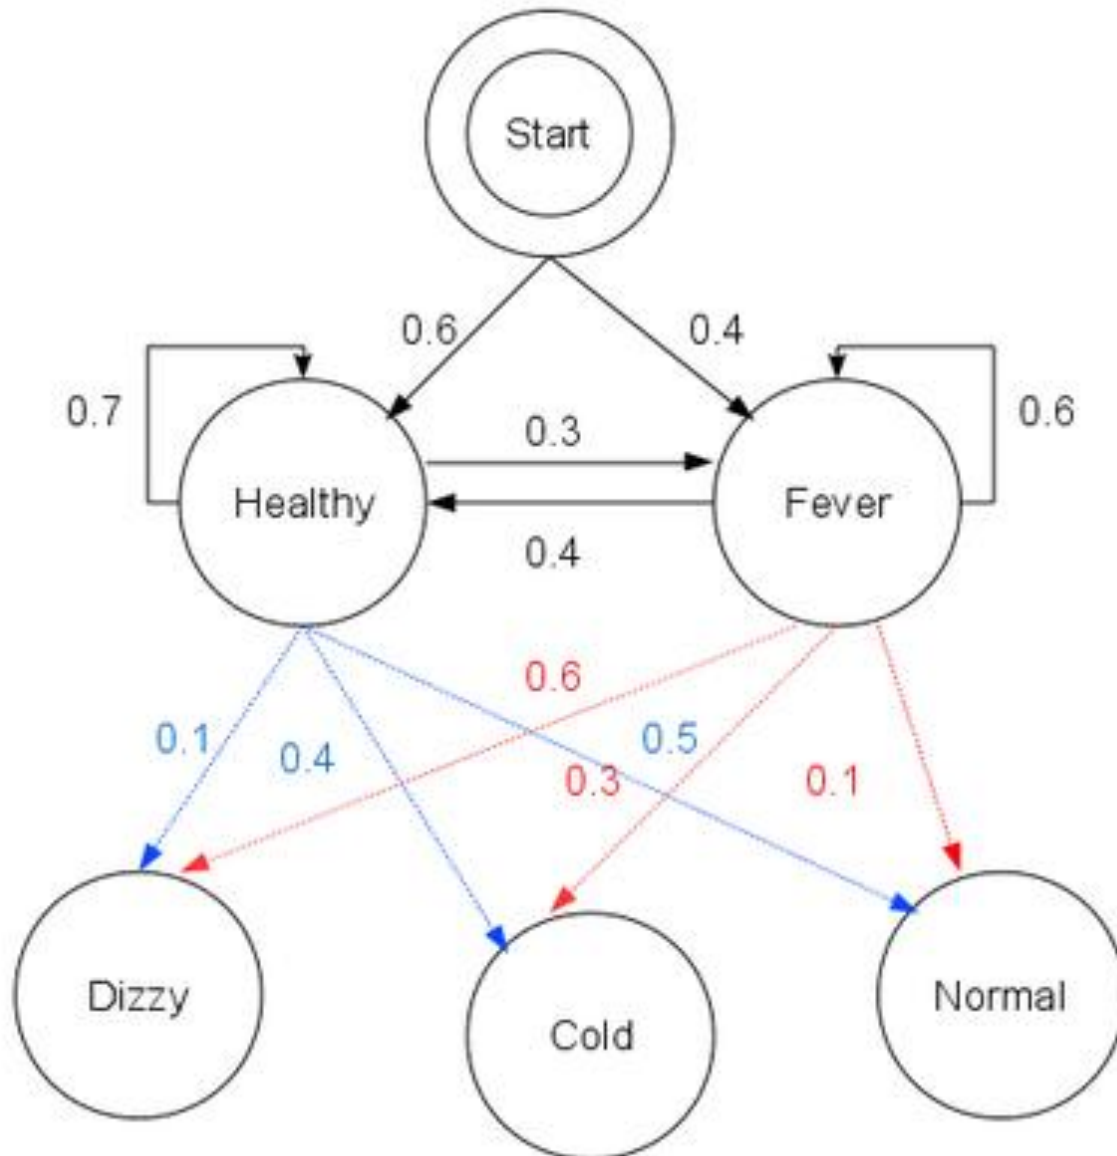
Bob do Alicji – „dzisiaj sprzątam”

Alicja do Boba – „a więc u Ciebie pada”



- Stany = ('Deszcz', 'Słońce')
- Obserwacje = ('Spacer', 'Zakupy', 'Sprząatanie')
- Pstwa_początkowe = {'Deszcz': 0.6, 'Słońce': 0.4}
- Pstwa_przejsć =
 - {'Deszcz': {'Deszcz': 0.7, 'Słońce': 0.3},
 - 'Słońce': {'Deszcz': 0.4, 'Słońce': 0.6}, }
- Pstwa_obserwacji =
 - {'Deszcz': {'Spacer': 0.1, 'Zakupy': 0.4, 'Sprząatanie': 0.5},
 - 'Słońce': {'Spacer': 0.6, 'Zakupy': 0.3, 'Sprząatanie': 0.1}, }

Przykład – symptomy choroby



Zastosowania

- Celem jest „odzyskanie” **sekwencji stanów**, które można obserwować tylko **pośrednio**, jako manifestację w postaci „**obserwacji**”
 - Kryptoanaliza
 - Rozpoznawanie mowy
 - Synteza mowy
 - Tłumaczenie maszynowe
 - Sekwencjonowanie genów
 - Rozpoznawanie czynności
 - Detekcja wirusów komputerowych
 - ...



DZIĘKUJĘ ZA UWAGĘ