

## Modele HMM pentru prelucrarea semnalului sonor

Lect.dr. Catalina-Lucia COCIANU  
Catedra de Informatica Economica, A.S.E. Bucuresti

*The research reported in the paper focused on the HMM modeling in pattern recognition, with application in speech processing. A speech recognizer is a device that automatically transcribes speech into text and can be thought of as a voice-actuated "typewriter". The recognizer is usually based on some finite vocabulary that restricts words that can be printed out. The mathematical formulation of the speech recognizer design problem is based on a statistical approach, involving the hidden Markov model (HMM).*

**Keywords:** HMM, acoustic modeling, language modeling, speech recognition, vector quantization.

### Model matematic pentru recunoasterea semnalului sonor

Modelul matematic pentru recunoasterea automată a semnalului sonor poate fi descris astfel. Fie  $A$  data acustică analizată, definită prin intermediul secvenței de simboluri  $a_1, a_2, \dots, a_m$  din alfabetul  $A$ , în care indicele  $i$ ,  $1 \leq i \leq m$ , reprezintă momentul de timp la care este generat simbolul  $a_i$ .  $A = a_1, a_2, \dots, a_m$ ,  $\forall 1 \leq i \leq m, a_i \in A$ ,  $W = w_1, w_2, \dots, w_n$  o secvență de  $n$  cuvinte din vocabularul  $V$  și  $P(W/A)$  probabilitatea ca la pronunțarea datei acustice  $A$  să fie scris șirul de cuvinte  $W$ . Dispozitivul de recunoaștere automată asociază datei acustice  $A$  observată acea secvență de cuvinte  $\hat{W}$  cu proprietatea că

$$\hat{W} = \arg \max_w P(W/A) \quad (1)$$

Aplicând formula Bayes pentru calculul  $P(W/A)$  obținem,

$$P(W/A) = \frac{P(W)P(A/W)}{P(A)}, \quad (2)$$

unde  $P(W)$  este probabilitatea pronunțării șirului de cuvinte  $W$ ,  $P(A/W)$  este probabilitatea ca la pronunțarea șirului de cuvinte  $W$  semnalul acustic observat să fie  $A$  și  $P(A) = \sum_{W'} P(W')P(A/W')$  este probabilitatea medie ca  $A$  să fie observată. Deoarece în relația (1)  $A$  este fixată, din (2) rezultă,

$$\hat{W} = \arg \max_w P(W)P(A/W) \quad (3)$$

Proiectarea dispozitivului de recunoaștere a

vorbirii este realizată pe baza relației (3) și presupune parcurgerea următoarelor etape [Jeli, 1997]:

I. *Procesarea acustică*, prezentată schematic în figura 1;

II. *Determinarea unui model acustic pentru calculul valorilor  $P(A/W)$* ; o variantă des utilizată este modelarea HMM (Hidden Markov Model) pentru obținerea  $P(A/W)$

III. *Modelarea limbajului* Aplicarea relației (3) pentru calculul  $\hat{W}$  presupune calculul probabilității a priori  $P(W)$ ; alegerea cea mai utilizată este descompunerea pe baza formulei Bayes,

$$P(W) = \prod_{i=1}^n P(w_i / w_1, \dots, w_{i-1}) \quad (4)$$

În procesul de recunoaștere automată a vorbirii, datorită complexității ridicate (datorate dimensiunii vocabularului  $V$ ), probabilitățile  $P(w_i / w_1, \dots, w_{i-1})$  pot fi doar estimate. În plus, presupunerea că alegerea de către vorbitor a celui de-al  $i$ -lea cuvânt depinde de întreaga istorie  $w_1, \dots, w_{i-1}$  poate fi redusă în general la alegerea lui  $w_i$  depinzând de o istorie aleasă într-o clasă de echivalență  $\Phi(w_1, \dots, w_{i-1})$  [Ziem, 1995].

Rezultă că  $P(W)$  poate fi calculat prin,

$$P(W) = \prod_{i=1}^n P(w_i / \Phi(w_1, \dots, w_{i-1})) \quad (5)$$

și stabilirea unui model pentru limbajul utilizat revine la determinarea unui clasificator  $\Phi$  și la selectarea unor metode de estimare a

probabilitatilor  $P(w_i / \Phi(w_1, \dots, w_{i-1}))$ .

IV. Calculul  $\hat{W}$  pe baza relatiei (3), prin formularea unor ipoteze care sa determine restrângerea spatiului de cautare a candidaților  $W$ .

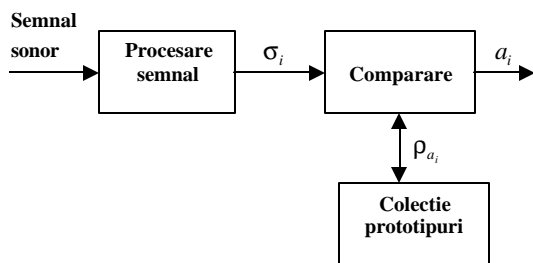


Fig.1. Procesarea acustica

Procesarea de semnal revine la generarea câte unui vector de numere reale  $\sigma_i$  la fiecare interval de timp prestabilit (în general de  $s/100$ ). Componentele vectorului  $\sigma_i$  sunt iesirile unui filtru band-pass aplicat semnalului sonor analizat. Colectia de prototipuri  $\mathfrak{R} = \{\rho_1, \rho_2, \dots, \rho_K\}$  contine vectori prototip de acelasi tip cu  $\sigma_i$ .

Etapă de comparare presupune calculul celui mai apropiat prototip de  $\sigma_i$  (în sensul distantei euclidiene) și selectarea indexului celui prototip drept simbolul acustic asociat semnalului sonor transmis. O modalitate de calcul al celui mai apropiat prototip este prin *cuantizare*. Fie  $L$  dimensiunea vectorilor prototip și  $d$  distanța euclidiană,

$d(\sigma, \rho) = \sqrt{\sum_{l=1}^L (\sigma(l) - \rho(l))^2}$ . Algoritmul de cuantizare (numit și K-means) este descris

$$P(X_1 = i_1, X_2 = i_2, \dots, X_n = i_n) = \prod_{j=1}^n P(X_j = i_j | X_1 = i_1, X_2 = i_2, \dots, X_{j-1} = i_{j-1}). \quad (6)$$

Variabilele aleatoare  $X_1, X_2, \dots, X_n, \dots$  formează un *lant Markov* dacă, pentru orice  $j \geq 1$  și  $\forall i_1, i_2, \dots, i_j \in \mathfrak{K}$ ,

$$P(X_j = i_j | X_k = i_k, 1 \leq k \leq j-1) = P(X_j = i_j | X_{j-1} = i_{j-1}).$$

Utilizând (6), rezulta,

$$\forall n \geq 1 \text{ și } \forall i_1, i_2, \dots, i_n \in \mathfrak{K},$$

$$P(X_1 = i_1, X_2 = i_2, \dots, X_n = i_n) = \prod_{j=1}^n P(X_j = i_j | X_{j-1} = i_{j-1}). \quad (7)$$

Relatia (7) definește o clasă de procese stohastice care utilizează cantitatea minimă de

astfel [Jeli, 1997].

**Algoritmul K-means**

**Pas1.** selectează numărul de clustere  $K$  și numărul de iterații  $T$ ;

**Pas2.** calculează  $\sigma_i, 1 \leq i \leq N$ , vectorii obținuți în urma emiterii semnalului sonor pe un interval de timp cunoscut (în practică este utilizat  $N$  pentru transmisii de 5 min.);

**Pas 3.** pentru fiecare vector  $\sigma_i, 1 \leq i \leq N$ , este selectat aleator uniform un prototip  $\rho_j^0$ ,

$$P(\rho_j^0 = \sigma_i) = \frac{1}{N};$$

**Pas 4.** partitionează  $\{\sigma_1, \sigma_2, \dots, \sigma_N\}$  în  $K$  regiuni  $R_j^0, 1 \leq j \leq K$  definite prin,  $\sigma_i \in R_j^0$  dacă  $d(\sigma_i, \rho_j^0) \leq d(\sigma_i, \rho_h^0), \forall h \neq j$ ;

**Pas 5.** pentru  $t = 1, \dots, T$ :

**5.1.** calculează  $\rho_j^t$  centrul fiecărei regiuni  $R_j^{t-1}, 1 \leq j \leq K$ ,  $\rho_j^t = \arg \min_{\rho} \sum_{\sigma_i \in R_j^{t-1}} d(\sigma_i, \rho)$ ;

**5.2.** calculează  $R_j^t, 1 \leq j \leq K$  utilizând centrele de greutate  $\rho_j^t$ ,  $\sigma_i \in R_j^t$  dacă  $d(\sigma_i, \rho_j^t) \leq d(\sigma_i, \rho_h^t), \forall h \neq j$ .

**Modele HMM**

Fie  $X_1, X_2, \dots, X_n, \dots$  o secvență de variabile aleatoare cu valori în  $\mathfrak{K} = \{1, 2, \dots, c\}$ . În general, pentru orice  $n \geq 1$ , are loc formula Bayes,

$$\forall i_1, i_2, \dots, i_n \in \mathfrak{K},$$

memorie: valoarea procesului la momentul de timp  $i$  depinde numai de valoarea de la momentul  $i-1$  si nu de întreg istoricul procesului.

Un lant Markov se numeste *omogen* daca, pentru orice  $i > 1$  si orice  $x, x' \in \mathfrak{X}$ ,

$$P(X_i = x' / X_{i-1} = x) = p(x'/x).$$

Functia  $p$  este numita *functie de tranzitie* si poate fi reprezentata prin intermediul unei matrice  $c \times c$ -dimensionala care îndeplineste conditiile:

$$\forall x \in \mathfrak{X}, \sum_{x' \in \mathfrak{X}} p(x'/x) = 1 \text{ si}$$

$$\forall x, x' \in \mathfrak{X}, p(x'/x) \geq 0.$$

Elementele multimii  $\mathfrak{X}$  se numesc *stari*. Lantul Markov  $X_1, X_2, \dots, X_n, \dots$  este un proces cu un numar finit de stari, tranzitiile dintre stari fiind specificate prin intermediul functiei  $p$ . Modelul de lant Markov este *observabil*, în sensul ca, la fiecare moment de timp, iesirea procesului este o multime de stari, fiecare stare fiind corespunzatoare unui eveniment observabil.

### Conceptul de HMM

Modelele Markov au proprietatea ca fiecare stare corespunde unui eveniment determinist observabil. Rezulta ca, pentru fiecare stare din model, iesirea este fixata (nu este aleatoare). În scopul eliminarii acestei restrictii, modelul Markov este extins la cazul în care observarea unui eveniment este o functie probabilistica definita pe multimea starilor.

Conceptul de *model Markov ascuns* (Hidden Markov Model) este definit astfel încât stările lantului Markov genereaza date observabile, în timp ce secventa de stari ramâne ascun-

$$P(y_1, y_2, \dots, y_k) = \sum_{s_1, s_2, \dots, s_k} \prod_{i=1}^k p(s_i / s_{i-1}) q(y_i / s_{i-1}, s_i). \quad (8)$$

O modalitate alternativa de definire a unui HMM presupune evidentierea multimii tranzitiilor de la o stare la alta, fiecarei tranzitii  $t$  asociindu-se un simbol de iesire generat cu probabilitate 1 la efectuarea lui  $t$ . Fie  $L(t)$  si  $R(t)$  starea sursa, respectiv starea destinatie a tranzitiei  $t$  si  $Y(t)$  simbolul de iesire asociat

$$P(y_1, y_2, \dots, y_k) = \sum_{S(y_1, y_2, \dots, y_k)} \prod_{i=1}^k p(t_i), \quad (9)$$

sa. Astfel, vor fi definite:

- alfabetul de iesire  $Y = \{0, 1, \dots, b-1\}$ ;
- spatiul starilor  $\mathfrak{X} = \{1, 2, \dots, c\}$  si  $s_0$  stare initiala unica;
- distributia de probabilitate a tranzitiilor dintre stari,  $p(s'/s)$ ; procesul determinat de multimea starilor si probabilitatea tranzitiilor între stari este un lant Markov;
- probabilitatea de distributie a iesirilor, asociata fiecarei tranzitii de la o starea  $s$  la o starea  $s'$ ,  $q(y/s, s')$ , pentru orice  $s, s' \in \mathfrak{X}$ ; procesul astfel obtinut este un lant Markov.

În cadrul unui HMM, principalele probleme care trebuie rezolvate sunt urmatoarele.

- Fiind data o secventa observata  $\mathbf{y}$  într-un model  $M$ , determinati o modalitate eficienta pentru calculul  $P(\mathbf{y})$ .
- Fie  $\mathbf{y}$  o secventa de iesire observata într-un model  $M$ . Calculati cea mai probabila secventa de stari  $\mathbf{S}$  cu proprietatea ca determina generarea sirului  $\mathbf{y}$ .
- Fie  $\mathbf{y}$  o secventa de iesire observata. Determinati modelul Markov ascuns  $M$  cu proprietatea ca, în cadrul lui,  $P(\mathbf{y})$  este maxima. În continuare este solutionata prima dintre problemele enuntate mai sus. Probabilitatea observarii sirului de iesire HMM  $y_1, y_2, \dots, y_k$  este calculata prin:

unic lui  $t$ . Vom nota cu  $p(t)$  probabilitatea ca  $L(t)$  sa constituie sursa tranzitiei  $t$ : pentru orice  $s \in \mathfrak{X}$ ,  $\sum_{t/L(t)=s} p(t) = 1$ . Obtinem,

$$p(t) = q(Y(t) / L(t), R(t)) p(R(t) / L(t))$$

În aceste conditii, relatia (8) este echivalenta cu,

unde

$$S(y_1, y_2, \dots, y_k) = \{t_1, t_2, \dots, t_k / L(t_1) = s_0, Y(t_i) = y_i, R(t_i) = L(t_{i+1}) \forall i = 1, \dots, k\}.$$

Calculul probabilitatii  $P(y_1, y_2, \dots, y_k)$  poate fi realizat recursiv, pe baza notiunii de *latice a drumurilor*. O latice a drumurilor unui HMM evidentiaza evolutia în timp a procesului care a generat secventa  $y_1, y_2, \dots, y_k$  si es-

te definit ca o multime de siruri de stari elementare, fiecare sir de stari fiind determinat de simbolul de iesire particulara  $y_i$ .

Pentru orice stare  $s \in \mathfrak{X}$ , sunt definite probabilitatile:

$$\alpha_i(s) = P(y_1, y_2, \dots, y_i, s_i = s), \text{ cu } \alpha_0(s) = \begin{cases} 1, & s = s_0 \\ 0, & s \neq s_0 \end{cases}. \tag{10}$$

Rezulta ca  $P(y_1, y_2, \dots, y_k) = \sum_{s \in \mathfrak{X}} \alpha_k(s)$ , unde probabilitatile  $\alpha_i$  sunt calculate recursiv prin,

$$\alpha_i(s) = \sum_{s' \in \mathfrak{X}} p(y_1, s / s') \alpha_{i-1}(s'), \tag{11}$$

$$p(y, s | s') \underline{\text{not.}} q(y | s', s) p(s | s').$$

**Algoritmul Viterbi**

Fie  $y_1, y_2, \dots, y_k$  o secventa de iesire observata. Problema este de a calcula cea mai proba-

bila secventa de stari  $s_1, s_2, \dots, s_k$  cu proprietatea ca a determinat generarea sirului  $y_1, y_2, \dots, y_k$ . Deoarece

$$P(s_1, s_2, \dots, s_k / y_1, y_2, \dots, y_k, s_0) = \frac{P(s_1, s_2, \dots, s_k, y_1, y_2, \dots, y_k / s_0)}{P(y_1, y_2, \dots, y_k / s_0)},$$

secventa  $s_1, s_2, \dots, s_k$  rezulta prin maximizarea  $P(s_1, s_2, \dots, s_k, y_1, y_2, \dots, y_k / s_0)$ . În plus,

datorita faptului ca procesul starilor este Markov, obtinem ca, pentru orice  $i$ ,

$$P(s_1, s_2, \dots, s_i, s_{i+1}, \dots, s_k, y_1, y_2, \dots, y_i, y_{i+1}, \dots, y_k / s_0) = P(s_1, s_2, \dots, s_i, y_1, y_2, \dots, y_i / s_0) \times P(s_{i+1}, \dots, s_k, y_{i+1}, \dots, y_k / s_i)$$

deci

$$\begin{aligned} & \max_{s_1, s_2, \dots, s_k} P(s_1, s_2, \dots, s_i, s_{i+1}, \dots, s_k, y_1, y_2, \dots, y_i, y_{i+1}, \dots, y_k / s_0) = \\ & = \max_{s_1, s_2, \dots, s_{i-1}} P(s_1, s_2, \dots, s_{i-1}, s_i, y_1, y_2, \dots, y_i / s_0) \times \max_{s_i, s_{i+1}, \dots, s_k} P(s_{i+1}, \dots, s_k, y_{i+1}, \dots, y_k / s_i) \end{aligned} \tag{12}$$

Fie  $\gamma_i(s_i) = \max_{s_1, s_2, \dots, s_{i-1}} P(s_1, s_2, \dots, s_{i-1}, s_i, y_1, y_2, \dots, y_i / s_0)$ . Din (12) rezulta,

$$\begin{aligned} & \max_{s_1, s_2, \dots, s_k} P(s_1, s_2, \dots, s_i, s_{i+1}, \dots, s_k, y_1, y_2, \dots, y_i, y_{i+1}, \dots, y_k / s_0) = \\ & = \max_s \left\{ \max_{s_{i+1}, \dots, s_k} P(s_{i+1}, \dots, s_k, y_{i+1}, \dots, y_k / s) \gamma_i(s) \right\} \end{aligned} \tag{13}$$

În consecinta, secventa de stari  $s_1, \dots, s_{i-1}, s_i, s_{i+1}, \dots, s_k$  poate fi calculata prin aplicarea urmatorelui algoritm. [Rabi, 1989] Pentru fiecare  $s$  din al  $i$ -lea nivel al laticeii drumurilor

cea mai probabila de stari care porneste din  $s$ ; **Pas3.** calculeaza starea  $s$  de la nivelul  $i$  astfel încât secventa completa  $s_1(s), \dots, s_{i-1}(s), s_i = s, s_{i+1}(s), \dots, s_k(s)$  sa fie cu probabilitate maxima.

**Pas1.** determina  $s_1(s), \dots, s_{i-1}(s)$ , secventa cea mai probabila de stari care a condus la  $s$ ;

Algoritmul poate fi definit recursiv, pe baza urmatoarelor observatii.

**Pas2.** calculeaza  $s_{i+1}(s), \dots, s_k(s)$ , secventa

$$1. \gamma_i(s_i) = \max_{s_1, s_2, \dots, s_{i-1}} P(s_1, s_2, \dots, s_{i-1}, s_i, y_1, y_2, \dots, y_i / s_0) =$$

$$\begin{aligned}
&= \max_{s_{i-1}} p(y_i, s_i / s_{i-1}) \max_{s_1, s_2, \dots, s_{i-2}} P(s_1, s_2, \dots, s_{i-2}, s_{i-1}, y_1, y_2, \dots, y_{i-1} / s_0) = \\
&= \max_{s_{i-1}} p(y_i, s_i / s_{i-1}) \gamma_{i-1}(s_{i-1}) \\
&2. \max_{s_1, s_2, \dots, s_k} P(s_1, s_2, \dots, s_k, y_1, y_2, \dots, y_k / s_0) = \max_s \gamma_k(s)
\end{aligned} \tag{14}$$

Din (14) rezulta algoritmul Viterbi pentru determinarea secventei de probabilitate maxima  $s_1, s_2, \dots, s_k$  prin calculul secventelor de probabilitate maxima  $s_1(s), s_2(s), \dots, s_{i-1}(s), s = s_i$ , pentru fiecare stare  $s$  de la nivelul  $i$  si selectarea finala (de la nivelul  $k$ ) a unei secvente din multimea  $\{s_1(s), s_2(s), \dots, s_{k-1}(s), s = s_k / s \in \mathfrak{K}\}$  care maximizeaza  $\gamma_k(s)$ . [Jeli, 1997]

Algoritmul Viterbi contine urmatoorii pasi:

**Pas1.**  $\gamma_0(s_0) = 1$ ;

**Pas2.** pentru toate starile  $s$  ale primei coloane din laticia drumurilor, calculeaza  $\gamma_1(s)$  prin (14),  $\gamma_1(s) = \max_{s'} p(y_1, s / s') \gamma_0(s') = p(y_1, s / s_0)$ ,  $\forall s' \neq s_0, \gamma_0(s') = 0$

**Pas3.** pentru orice  $2 \leq i < k$ , calculeaza  $\gamma_i(s)$  pe baza relatiei (14), pentru toate starile  $s$  din cea de-a  $i$ -a coloana a laticiei. Elimina toate tranzitiile din starile  $s'$  din cea de-a  $i-1$ -a coloana în starile  $s$  din cea de-a  $i$ -a coloana pentru care  $\gamma_i(s) > p(y_i, s / s') \gamma_{i-1}(s')$ . Daca dupa eliminare ramân mai multe tranzitii, selecteaza arbitrar o tranzitie catre  $s$ .

**Pas4.** calculeaza starea  $s$  din cea de-a  $k$ -a coloana a laticiei, care maximizeaza  $\gamma_k(s)$ . Prin deplasarea inversa de la starea  $s$  la starea  $s_0$  pe baza tranzitiilor calculate, rezulta secventa de stari de probabilitate maxima,

$$s_1, \dots, s_{k-1}, s = s_k.$$

## Bibliografie

- [Char, 1994] Charniak, E., Statistical Language Learning, The MIT Press, 1994
- [Gray, 1991] Gray, R., M., Gersho, A., Vector Quantization and Signal Compression, Kluwer, Boston, MA, 1991
- [Jeli, 1997] Jelinek, F., Statistical Methods for Speech Recognition, The MIT Press, 1997
- [Juan, 1992] Juang, B., H., Rabiner, L., R., Issues in Using Hidden Markov Models for Speech Recognition, Advances in Signal Processing, 1992
- [Pico, 1994] Picone, J., W., Signal Modeling Techniques in Speech Recognition, Proceedings of IEEE, vol. 81, no. 9, 1994
- [Rabi, 1989] Rabiner, L., R., A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition, Proceedings of the IEEE, vol. 37, no. 2, 1989
- [Youn, 1990] Young, S., J., Competitive Training in Hidden Markov Models, Proceedings of IEEE International Conference on Acoustic, Speech and Signal Processing, Albuquerque, 1990
- [Ziem, 1995] Ziemer, R., E., Tranter, W., H., Principles of Communications, John Wiley, New York, 1995