

Parameter Estimation with a Hidden Markov Model (HMM)

Lect.dr. Cătălina-Lucia COCIANU

Catedra de Informatică Economică, A.S.E. București

The research reported in the paper focused on the estimation of statistical parameters of HMMs. The parameter specification $\hat{\lambda}$ would, in an important statistical sense, allow the HMM of the given structure to account best for the observed data \mathbf{Y} . We will arrive at the required algorithms (Baum and Baum-Welch, or forward-backward algorithm) by intuitive reasoning and we will derive the Expectation-Maximization algorithm and use it to justify the convergence and optimality of the Baum-Welch algorithm. To derive the Baum-Welch algorithm for a discrete output alphabet, we will use the formulation of HMMs in which various transactions are deterministically related to the observed outputs.

Keywords: Hidden Markov Model (HMM), maximum likelihood estimation, Baum algorithm, Baum-Welch algorithm.

Introducere

Fie $X_1, X_2, \dots, X_n, \dots$ o secvență de variabile aleatoare cu valori în $\aleph = \{1, 2, \dots, c\}$. În

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

Variabilele aleatoare $X_1, X_2, \dots, X_n, \dots$ formează un lanț Markov dacă, pentru orice $j \geq 1$ și $\forall i_1, i_2, \dots, i_j \in \aleph$, $P(X_j = i_j | X_k = i_k, 1 \leq k \leq j-1) = P(X_j = i_j | X_{j-1} = i_{j-1})$.

Lanțul Markov $X_1, X_2, \dots, X_n, \dots$ este un proces cu un număr finit de stări, tranzițiile dintre stări fiind specificate prin intermediul funcției p . Modelul de lanț Markov este observabil, în sensul că, la fiecare moment de timp, ieșirea procesului este o mulțime de stări, fiecare stare fiind corespunzătoare unui eveniment observabil.

Conceptul de *model Markov ascuns* (Hidden Markov Model) este definit astfel încât stările lanțului Markov generează date observabile, în timp ce secvența de stări rămâne ascunsă. Astfel, vor fi definite:

- alfabetul de ieșire $\mathcal{Y} = \{0, 1, \dots, b-1\}$;
- spațiul stărilor $\aleph = \{1, 2, \dots, c\}$ și s_0 stare inițială unică;
- distribuția de probabilitate a tranzițiilor dintre stări, $p(s'|s)$; procesul determinat de mulțimea stărilor și probabilitatea tranzițiilor între stări este un lanț Markov;
- probabilitatea de distribuție a ieșirilor, asociată fiecărei tranziții de la o starea s la o sta-

general, pentru orice $n \geq 1$, are loc formula Bayes, $\forall i_1, i_2, \dots, i_n \in \aleph$,

rea s' , $q(y|s, s')$, pentru orice $s, s' \in \aleph$; procesul astfel obținut este un lanț Markov.

Pentru utilizarea HMM ca model de generare de date este necesară cunoașterea probabilității de tranziție între stări, a probabilității obținerii fiecărui simbol din alfabetul de ieșire, precum și a structurii tranzițiilor. Deoarece în cele mai multe situații sunt disponibile numai eșantioane de date, problema este de a construi un model astfel încât datele generate de acesta să fie "de același tip" cu datele observate.

Obținerea unor estimări "suficient de bune" a structurii interne și a probabilităților care caracterizează un HMM este imposibilă; problema care poate fi rezolvată este estimarea parametrilor modelului pe baza unei structuri a tranzițiilor considerată cunoscută.

Parametrii unui HMM vor fi estimați pe baza principiului verosimilității maxime. Pentru aceasta, fie $P_\lambda(\mathbf{Y})$ probabilitatea ca modelul definit prin parametrii λ să producă simbolurile de ieșire observate $\mathbf{Y} = (y_1, y_2, \dots, y_k)$;

estimarea parametrilor λ revine la rezolvarea problemei variaționale (1) $\hat{\lambda} = \arg \max_{\lambda} P_{\lambda}(\mathbf{Y})$.

Specificarea parametrilor $\hat{\lambda}$ pe baza relației (1) este realizată exclusiv utilizând datele observate $\mathbf{Y} = (y_1, y_2, \dots, y_k)$. Pentru ca estimările $\hat{\lambda}$ să fie suficient de bune (dar nu neapărat optime) este necesar ca datele \mathbf{Y} utilizate pentru învățare modelului să fie reprezentative pentru proces.

Algoritmul Baum

În continuare vom prezenta algoritmul Baum pentru calculul $\hat{\lambda}$ utilizând exclusiv argumente de natură intuitivă și empirică. Vom considera următoarea reprezentare a modelului ai cărui parametri sunt estimați. Între oricare două perechi de stări s, s' există cel puțin o tranziție nenulă t , $L(t) = s$ și $R(t) = s'$ și cel puțin o tranziție nulă t' , $L(t') = s$ și $R(t') = s'$. Vom nota cu $q(y | t) = q(y | s, s')$, unde $L(t) = s$ și $R(t) = s'$.

Fie $\mathbf{Y} = (y_1, y_2, \dots, y_k)$ simbolurile de ieșire observate și $P\{t^i = t\}$ probabilitatea ca, după i etape ale procesului, să fie considerată tranziția t (t este cea de-a i -a tranziție nenulă aplicată).

Vom defini contoarele, (2) $c(t) = \sum_{i=0}^{k-1} P\{t^i = t\}$,

pentru toate tranzițiile t și (3)

$c(y, t) = \sum_{i=0}^{k-1} P\{t^i = t\} \delta(y_{i+1}, y)$, pentru toate

tranzițiile nenule t' , unde δ este funcția Kronecker.

Pentru fiecare tranziție t , $c(t)$ este numărul de apariții ale tranziției t și, dacă t este

nenulă, $c(y, t)$ reprezintă numărul de efecte

$$\alpha_i(s) = \sum_{t \in N(s)} \alpha_{i-1}(L(t)) p(t) q(y_i | t) + \sum_{t \in N(s)} \alpha_i(L(t)) p(t) \quad (5)$$

unde $N(s)$ este mulțimea tuturor tranzițiilor nule t cu $R(t) = s$ și având starea inițială mai mică decât s ($L(t) < s$) și $\bar{N}(s)$ este mulțimea tuturor tranzițiilor nenule t cu $R(t) = s$.

Cu toate că relația (5) include $\alpha_i(s)$ în ambii membri ai egalității, poate fi evaluată în condițiile în care modelul nu include tranziții nu-

ări ale lui t cu generarea simbolului de ieșire y . Utilizând contoarele definite prin relațiile (2) și (3), rezultă că estimațiile "naturale" ale parametrilor modelului sunt,

$$\hat{q}(y | t) = \frac{c^*(y, t)}{c^*(t)}, \text{ pentru orice tranziție nenulă } t$$

$$\text{și } \hat{p}(t) = \frac{c^*(t)}{\sum_{t': L(t')=L(t)} c^*(t')}, \text{ pentru orice tranziție } t, \text{ unde } c^*(y, t) = c(y, t) P(y_1, y_2, \dots, y_k)$$

$$\text{și } c^*(t) = c(t) P(y_1, y_2, \dots, y_k).$$

Estimarea parametrilor modelului pe baza contoarelor definite prin (2) și (3) este posibilă dacă pot fi calculate probabilitățile

$$P^*\{t^i = t'\} = P\{t^i = t'\} P(y_1, y_2, \dots, y_k).$$

În acest scop vom defini,

- $P^*\{t^i = t\}$ - probabilitatea producerii șirului de simboluri de ieșire $\mathbf{Y} = (y_1, y_2, \dots, y_k)$ și astfel încât, după i etape ale procesului, să fie efectuată tranziția t , $i = 0, 1, \dots, k-1$;

- $\alpha_i(s) = P\{s^i = s\}$ - probabilitatea generării șirului y_1, y_2, \dots, y_i și starea atinsă la etapa i este s , $i = 0, 1, \dots, k$;

- $\beta_i(s) = P\{rest | s^i = s\}$ - probabilitatea generării șirului y_{i+1}, \dots, y_k , dacă starea atinsă la etapa i este s , $i = 0, 1, \dots, k$.

Deoarece tranziția t poate fi considerată după ce modelul a atins starea $L(t)$ și, după efectuarea lui t procesul continuă începând cu starea $R(t)$, rezultă (4)

$$P^*\{t^i = t\} = \begin{cases} \alpha_i(L(t)) p(t) q(y_{i+1} | t) \beta_{i+1}(R(t)), & t \text{ nenulă} \\ \alpha_i(L(t)) p(t) \beta_i(R(t)), & t \text{ nulă} \end{cases}$$

De asemenea, similar definiției recursive (18), obținem,

le care să formeze cicluri prin aplicarea unui algoritm de ordonare. Relația (5) poartă numele de *recursie înainte (forward)*.

Valorile $\beta_i(s)$ pot fi calculate recursiv prin,

$$\beta_i(s) = \sum_{t \in \bar{M}(s)} p(t)q(y_{i+1} | t)\beta_{i+1}(R(t)) + \sum_{t \in M(s)} p(t)\beta_i(R(t)) \quad (6) \text{unde,}$$

$$M(s) = \{t : L(t) = s, t \text{ este nulă}, R(t) > s\} \text{ și}$$

$$\bar{M}(s) = \{t : L(t) = s, t \text{ este nenulă}\}.$$

Relația (6) este referită drept *recursie înapoi (backward)*.

Algoritmul Baum [6] pentru estimarea parametrilor modelului este construit pe baza relațiilor (5) și (6), care permit evaluarea probabilităților $P^* \{t^i = t\}$ prin (4).

Pas 1. Pasul înainte: pentru $i = 0, 1, \dots, k$ calculează $\alpha_i(s)$ prin (5), pentru orice stare s a modelului; este utilizată inițializarea $\alpha_0(s_0) = 1$.

Pas 2. Pasul înapoi: pentru $i = k - 1, \dots, 0$ calculează $\beta_i(s)$ prin (6), pentru orice stare s a modelului; sunt folosite inițializările $\beta_k(s) = 1$, pentru orice $s \in \mathcal{S}$.

Pas 3. Evaluarea probabilităților de tranziție: pentru $i = k - 1, \dots, 0$ și orice tranziție t , calculează $P^* \{t^i = t\}$ utilizând relația (4).

Pas 4. Estimarea parametrilor:

Calculează contoarele $c^*(t) = \sum_{i=0}^{k-1} P^* \{t^i = t\}$,

pentru toate tranzițiile t și $c^*(y, t') = \sum_{i=0}^{k-1} P^* \{t^i = t'\} \delta(y_{i+1}, y)$, pentru toate tranzițiile nenule t' .

Calculează estimatorii, (7) $\hat{q}(y | t) = \frac{c^*(y, t)}{c^*(t)}$,

pentru orice tranziție nenulă t și (8)

$$\hat{p}(t) = \frac{c^*(t)}{\sum_{t': L(t')=L(t)} c^*(t')}, \text{ pentru orice tranziție } t.$$

În cadrul algoritmului Baum au fost utilizate valorile $p(t)$ și $q(y | t)$ în aplicarea relațiilor (4), (5) și (6), deci tocmai a parametrilor care sunt estimați. În scopul evitării acestui inconvenient, algoritmul pentru estimarea parametrilor HMM poate fi definit astfel [6]:

Pas 1. Setează arbitrar parametrii $p(t)$ și $q(y | t)$; alege $n \in \mathbb{N}$, numărul de iterații.

Pentru $l = 1, 2, \dots, n$, repetă

$$\alpha'_i(s) = \alpha_i^*(s) Q_i = \sum_{t \in \bar{N}(s)} \alpha_{i-1}^*(L(t)) p(t) q(y_i | t) + \sum_{t \in N(s)} \alpha'_i(L(t)) p(t) \quad (9)$$

Dacă vom considera

Pas 2. Aplică algoritmul Baum pentru calculul $\hat{p}(t)$ și $\hat{q}(y | t)$ utilizând ultimele valori calculate pentru $p(t)$ și $q(y | t)$.

Observații.

1. Algoritmul Baum determină obținerea unor estimatori $\hat{\lambda}$ care nu îndeplinesc neapărat (1); estimatorii calculați de algoritmul Baum sunt maxime locale: fie $P_{\lambda'}(\mathbf{Y})$ probabilitatea ca modelul definit prin parametrii λ să producă simbolurile de ieșire observate $\mathbf{Y} = (y_1, y_2, \dots, y_k)$, parametrii λ' parametrii calculați prin (7) și (8) și λ parametrii utilizați în aplicarea relațiilor (4), (5) și (6). Obținem că $P_{\lambda'}(\mathbf{Y}) > P_{\lambda}(\mathbf{Y})$.

2. În multe situații practice, nu poate fi cunoscut sau estimat numărul de pași, n , necesar obținerii estimatorilor $\hat{p}(t)$ și $\hat{q}(y | t)$. O variantă utilizată în implementarea algoritmului prezentat mai sus, este repetă pasul 2 cât timp modificările asupra $\hat{p}(t)$ și $\hat{q}(y | t)$ sunt superioare unei valori date, ε .

Normalizarea în algoritmul Baum

În multe situații practice în care este aplicat algoritmului Baum, calculul recursiv al valorilor $\alpha_i(s)$ și $\beta_i(s)$ prin relațiile (5) și respectiv (6) presupune un număr mare de etape k . În consecință, precizia cu care sunt calculate $\alpha_i(s)$ și $\beta_i(s)$ este mică pe măsură ce i crește (în cazul $\alpha_i(s)$), respectiv descrește (în cazul $\beta_i(s)$). În scopul evitării pierderii de precizie prin variația lui i , pot fi aplicate normalizări în procesul recursiv de calcul al valorilor $\alpha_i(s)$ și $\beta_i(s)$.

Fie Q_1, Q_2, \dots, Q_k numere pozitive și

$$\alpha_i^*(s) = \frac{\alpha_i(s)}{\prod_{j=0}^i Q_j}. \text{ Relația (5) implică,}$$

$$(10) Q_0 = 1 \text{ și } \forall 1 \leq i \leq k, Q_i = \sum_s \alpha'_i(s),$$

rezultă că $\forall 1 \leq i \leq k, \sum_s \alpha_i^*(s) = 1$ și pasul

înainte din algoritmul Baum este descris astfel [6].

1. Calculează valorile $\alpha'_i(s)$ conform ordonării stărilor, utilizând valorile normalizate $\alpha_{i-1}^*(s)$.

2. Calculează $Q_i = \sum_s \alpha'_i(s)$

$$\beta'_i(s) = \beta_i^*(s)Q_i = \sum_{t \in M(s)} p(t)q(y_{i+1} | t)\beta_{i+1}^*(R(t)) + \sum_{t \in M(s)} p(t)\beta'_i(R(t)) \quad (11)$$

Pasul înapoi al algoritmului Baum este modificat conform relației (11) similar pasului înainte prezentat mai sus.

3. Aplică normalizarea $\alpha_i^*(s) = \frac{\alpha'_i(s)}{Q_i}$ necesară calculului valorilor $\alpha'_{i+1}(s)$.

În scopul normalizării la pasul înapoi al algoritmului Baum sunt folosiți aceiași factori Q_1, Q_2, \dots, Q_k , $\beta_i^*(s) = \frac{\beta'_i(s)}{\prod_{j=i}^k Q_j}$. Rezultă,

Observații

1. Deoarece $\forall 1 \leq i \leq k, \sum_s \alpha_i^*(s) = 1$, din relația (10) rezultă,

$$P(y_1, y_2, \dots, y_k) = \sum_s \alpha_k(s) = \sum_s \left[\alpha_k^*(s) \prod_{i=1}^k Q_i \right] = \prod_{i=1}^k Q_i \quad 2.$$

Utilizând definițiile valorilor $\alpha_i^*(s)$ și $\beta_i^*(s)$, obținem,

$$\alpha_i(s)\beta_{i+1}(s) = \alpha_i^*(s)\beta_{i+1}^*(s) \prod_{j=1}^k Q_j = \alpha_i^*(s)\beta_{i+1}^*(s)P(y_1, y_2, \dots, y_k)$$

3. Din $P\{t^i = t'\} = P\{t^i = t'\}P(y_1, y_2, \dots, y_k)$, rezultă că probabilitatea $P\{t^i = t'\}$ poate fi calculată similar relației (4) prin, $P\{t^i = t'\} = \begin{cases} \alpha_i^*(L(t))p(t)q(y_{i+1} | t)\beta_{i+1}^*(R(t)), t \text{ nenulă} \\ \alpha_i^*(L(t))p(t)\beta_i^*(R(t))Q_i, t \text{ nulă} \end{cases}$

și este utilizată în evaluarea contoarelor $c(t)$ și $c(y, t)$ conform (2) și (3), evitând astfel calcularea explicită a valorii $\prod_{i=1}^k Q_i$.

Teorema EM. Algoritmul de maximizare a mediei

În continuare este prezentată teorema de maximizare a mediei, utilizată pentru construcția și demonstrarea convergenței și optimalității algoritmului Baum-Welch [6]. Teorema EM este bazată pe inegalitatea Jensen: pentru orice distribuții discrete de probabilitate, $p(x)$ și $q(x)$,

$$(12) \sum_x p(x) \log_b p(x) \geq \sum_x p(x) \log_b q(x).$$

Fie y data observabilă, $P_{\theta'}(y)$ distribuția de probabilitate a lui y în cadrul unui model caracterizat de parametrii θ' (θ' reprezintă totalitatea parametrilor ale căror valori intervin

în specificarea distribuției $P_{\theta'}$) și $P_{\theta}(y)$ distribuția de probabilitate corespunzătoare setului de parametri θ . Problema este de a determina condițiile în care apariția datei y este mai probabilă în modelul caracterizat de θ comparativ cu modelul specificat prin θ' (în acest caz, θ este o îmbunătățire a lui θ').

Fie t o variabilă aleatoare cu valori determinate în cadrul aceluiași proces care a determinat generarea datei y ; t este deci guvernată de valorile parametrilor θ' , respectiv θ (de exemplu, în cazul unui HMM, y corespunde unei secvențe de ieșire observate, iar t poate reprezenta o mulțime de stări sau o secvență de tranziții).

Deoarece $\sum_t P_{\theta'}(t | y) = 1$, rezultă,

$$\log_b P_\theta(y) - \log_b P_{\theta'}(y) = \sum_t P_\theta(t|y) \log_b P_\theta(y) - \sum_t P_{\theta'}(t|y) \log_b P_{\theta'}(y).$$

În continuare, obținem,

$$\begin{aligned} \log_b P_\theta(y) - \log_b P_{\theta'}(y) &= \sum_t P_\theta(t|y) \log_b \left(P_\theta(y) \frac{P_\theta(t,y)}{P_\theta(t,y)} \right) - \sum_t P_{\theta'}(t|y) \log_b \left(P_{\theta'}(y) \frac{P_{\theta'}(t,y)}{P_{\theta'}(t,y)} \right) = \\ &= \sum_t P_\theta(t|y) \log_b \frac{P_\theta(t,y)}{P_\theta(t|y)} - \sum_t P_{\theta'}(t|y) \log_b \frac{P_{\theta'}(t,y)}{P_{\theta'}(t|y)} = \\ &= \sum_t P_\theta(t|y) \log_b P_\theta(t,y) - \sum_t P_{\theta'}(t|y) \log_b P_{\theta'}(t,y) + \\ &+ \sum_t P_\theta(t|y) \log_b P_\theta(t|y) - \sum_t P_{\theta'}(t|y) \log_b P_{\theta'}(t|y) \geq \\ &\geq \sum_t P_\theta(t|y) \log_b P_\theta(t,y) - \sum_t P_{\theta'}(t|y) \log_b P_{\theta'}(t,y) \end{aligned}$$

inegalitatea rezultând din (12). Obținem următoarea teoremă.

Teorema EM (maximizarea mediei)

Dacă

$$(13) \quad \sum_t P_\theta(t|y) \log_b P_\theta(t,y) > \sum_t P_{\theta'}(t|y) \log_b P_{\theta'}(t,y),$$

rezultă (14) $P_\theta(y) > P_{\theta'}(y)$

Teorema de maximizare a mediei are următoarea interpretare. Dacă inițial parametrii modelului sunt setați pe θ' și sunt selectați parametrii θ astfel încât relația (13) să fie îndeplinită, atunci data y este observată cu o probabilitate mai mare în modelul caracterizat de parametrii θ comparativ cu modelul specificat prin θ' .

În scopul aplicării optime a teoremei EM, este necesară determinarea unei instanțe θ care să maximizeze membrul stâng al inegalității (13). Teorema este numită *maximizarea mediei* pentru că, media variabilei aleatoare $\log_b P_\theta(t,y)$ în raport cu distribuția inițială $P_\theta(t|y)$ este maximizată prin considerarea ei ca funcție de argument θ ,

$$\sum_t P_\theta(t|y) \log_b P_\theta(t,y) > \sum_t P_{\theta'}(t|y) \log_b P_{\theta'}(t,y).$$

Pe baza teoremei EM este obținut algoritmul de maximizare a mediei, astfel [6].

Pas1. Selectează θ' , valorile inițiale ale parametrilor modelului.

Repetă

Pas2. Calculează θ care maximizează membrul stâng al inegalității (13)

Pas3. $\theta' \leftarrow \theta$

cât timp C .

Condiția C este prestabilită și asigură încheierea calculului; specificarea condiției C poa-

te fi realizată utilizând următoarea observație. Pe măsură ce algoritmul calculează noi valori ale parametrilor θ' , probabilitatea $P_{\theta'}(y)$ crește până la o anumită valoare, datorită faptului că $P_{\theta'}(y) \leq 1$. Rezultă C : la ultima iterație $P_{\theta'}(y)$ și-a modificat valoarea cu cel puțin ε , unde ε este un parametru fixat.

Observație. Aplicarea algoritmului de maximizare a mediei depinde esențial de alegerea variabilei aleatoare auxiliare t , care trebuie să permită calcularea mediei maxime în membrul stâng al relației (13). În cazul HMM, determinarea unei astfel de variabile este posibilă.

Algoritmul Baum-Welch

Algoritmul Baum-Welch este derivat pe baza teoremei de maximizare a mediei și este aplicat unui alfabet discret de simboluri de ieșire Y [6]. În continuare vom utiliza definiția unui HMM în care tranzițiile sunt caracterizate în mod determinist de simbolurile de ieșire observate; fiecărei tranziții nenule t îi este asociat simbolul de ieșire $Y(t) = y$.

Fie $\mathbf{y} = y_1 y_2 \dots y_n$ secvența de simboluri observată și $\mathbf{t} = t_{i_1 j_1} t_{i_2 j_2} \dots t_{i_k j_k}$, $k \geq n$ șirul de tranziții care a generat \mathbf{y} ; pentru orice $1 \leq l \leq k$, $t_{i_l j_l}$ reprezintă a $j_l - a$ tranziție, în care starea inițială este i_l . Deoarece \mathbf{t} este un drum, $\forall 1 \leq l < k, R(t_{i_l j_l}) = i_{l+1}$. Parametrii modelului, θ , reprezintă totalitatea probabilităților de tranziție, $p_{ij} = P(t_{ij})$.

Problema este de a calcula $\max_{\theta} \sum_{\mathbf{t}} P_{\theta}(\mathbf{t} | \mathbf{y}) \ln P_{\theta}(\mathbf{t}, \mathbf{y})$. Este utilizată în continuare metoda multiplicatorilor Lagrange.

$$\frac{\partial}{\partial p_{ij}} \left[\sum_{\mathbf{t}} P_{\theta}(\mathbf{t} | \mathbf{y}) \ln P_{\theta}(\mathbf{t}, \mathbf{y}) - \sum_m \lambda_m \sum_n p_{mn} \right] = 0$$

$$\text{Obținem } \sum_{\mathbf{t}} P_{\theta}(\mathbf{t} | \mathbf{y}) \frac{\partial}{\partial p_{ij}} \frac{P_{\theta}(\mathbf{t}, \mathbf{y})}{P_{\theta}(\mathbf{t}, \mathbf{y})} - \lambda_i = 0 \quad (15)$$

Deoarece drumul \mathbf{t} determină secvența \mathbf{y} , rezultă că $P_{\theta}(\mathbf{t}, \mathbf{y}) = 0$ dacă \mathbf{y} este incompatibil

$$\text{cu } \mathbf{t} \text{ sau } P_{\theta}(\mathbf{t}, \mathbf{y}) = P_{\theta}(\mathbf{t}) = \prod_{l=1}^k P(t_{ijl}) = \prod_{l=1}^k p_{ijl}.$$

Fie $c_{ij}(\mathbf{t})$ numărul de tranziții t_{ij} din drumul

$$\mathbf{t}. \text{ Pe baza relației } \frac{\partial}{\partial p_{ij}} P_{\theta}(\mathbf{t}, \mathbf{y}) = \frac{\partial}{\partial p_{ij}} \prod_{l=1}^k p_{ijl}$$

$$= \sum_{l=1}^k P_{\theta}(y_1, y_2, \dots, y_{l-1}, s_{l-1} = i) p'_{ij} P_{\theta}(y_l, y_{l+1}, \dots, y_n | s_l = R(t_{ij})), \text{ deci}$$

$$\sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(\mathbf{t}) = \sum_{l=1}^k \alpha_{l-1}^{ij}(i) p'_{ij} \beta_l^{ij}(R(t_{ij})), \quad (16)$$

unde, $\alpha_l^{ij}(s) = P_{\theta}(y_1, y_2, \dots, y_l, s_l = s)$ și

$$\beta_l^{ij}(s) = P_{\theta}(y_{l+1}, y_{l+2}, \dots, y_k | s_l = s).$$

$$= \sum_{l=1}^k P_{\theta}(y_1, y_2, \dots, y_{l-1}, s_{l-1} = i) p'_{ij} P_{\theta}(y_l, y_{l+1}, \dots, y_n | s_{l-1} = R(t_{ij}))$$

$$\text{Și } \sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(\mathbf{t}) = \sum_{l=1}^k \alpha_{l-1}^{ij}(i) p'_{ij} \beta_{l-1}^{ij}(R(t_{ij})) \quad (17)$$

În relațiile (16) și (17), fiecare membru drept este contribuția adusă de algoritmul Baum-Welch în calculul valorilor p_{ij} la următorul pas. Valorile $\alpha_l^{ij}(s)$ și $\beta_l^{ij}(s)$ sunt obținute iterativ pe baza relațiilor (5) și (6).

Bibliografie

- [1] Bishop C., "Neural Networks for Pattern Recognition", Oxford University Press, 1996
- [2] Boulard H., Morgan N., "Connectionist Speech Recognition: A Hybrid Approach", Kluwer Academic Press, 1994
- [3] Devroye L., Györfi L., Lugosi G., "A Probabilistic Theory of Pattern Recognition", Springer Verlag, 1996
- [4] Gold B., Morgan N., "Speech Audio Signal Processing", John Wiley & Sons, 2000

$$\text{obținem } \frac{\frac{\partial}{\partial p_{ij}} P_{\theta}(\mathbf{t}, \mathbf{y})}{P_{\theta}(\mathbf{t}, \mathbf{y})} = \frac{c_{ij}(\mathbf{t})}{p_{ij}}.$$

Utilizând relația (15), rezultă

$$\sum_{\mathbf{t}} P_{\theta}(\mathbf{t} | \mathbf{y}) \frac{c_{ij}(\mathbf{t})}{p_{ij}} = \lambda_i, \text{ deci}$$

$$p_{ij} = \frac{1}{\lambda_i P_{\theta}(\mathbf{y})} \sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(\mathbf{t}) = \frac{1}{K_i} \sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(\mathbf{t}),$$

unde K_i este constanta de normalizare

$$\left(\sum_j p_{ij} = 1 \right). \text{ Deoarece } \mathbf{t} = t_{i_1 j_1} t_{i_2 j_2} \dots t_{i_k j_k}, \quad c_{ij}(\mathbf{t})$$

$$\text{poate fi evaluată astfel } c_{ij}(\mathbf{t}) = \sum_{l=1}^k \delta(t_{ij}, t_{i_l j_l}).$$

Pentru toate tranzițiile nenule t_{ij} , are loc șirul de egalități,

$$\sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(\mathbf{t}) = \sum_{l=1}^k \sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(t_{ij} t_{i_l j_l}) =$$

Pentru toate tranzițiile nule t_{ij} , obținem,

$$\sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(\mathbf{t}) = \sum_{l=1}^k \sum_{\mathbf{t}} P_{\theta}(\mathbf{t}, \mathbf{y}) c_{ij}(t_{ij} t_{i_l j_l}) =$$

[5] Husmeier D., "Learning Non-stationary Conditional Probability Distributions", Neural Networks, Vol. 13, 2000

[6] Jelinek F., "Statistical Methods for Speech Recognition", MIT Press, 1997

[7] Morgan D.P., "Neural Networks and Speech Processing", Kluwer Academic Publishers, 1991

[8] Juang B.-H., Rabiner L., "Issue in Using Hidden Markov Models for Speech Recognition", Advances in Signal Processing, 1992

[9] Stewart W., "Introduction to the Numerical Solutions of Markov Chains", Princeton University Press, 1994

[10] Young S.J., "Competitive Training in Hidden Markov Models", Proceedings of IEEE Int. Conf. on Acoustic, Speech and Signal Processing", 1990