

- راه حل دوم مسئله دوم:

نام این الگوریتم ویتربی (Viterbi) می باشد.

تعریف زیر را در نظر بگیرید:

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P[q_1, q_2, \dots, q_{t-1}, q_t = i, o_1, o_2, \dots, o_t | \lambda]$$

$$1 \leq i \leq N$$

P محتمل ترین دنباله حالات با این شرط است که در زمان t در حالت i باشیم و مشاهدات o_1, \dots, o_t را دیده باشیم.

از فرمول δ مشخص است که یک ماکزیمم گیری رو دنباله های پیشین انجام می شود.

$$\delta_{t+1}(j) = [\max_i \delta_t(i) a_{ij}] \cdot b_j(o_{t+1})$$

پس فرمول بازگشتی زیر را داریم:

کل روند الگوریتم ویتربی به صورت زیر است:

○ مقداردهی اولیه:

$$\delta_1(i) = \Pi_i b_i(o_1), 1 \leq i \leq N$$

$$\psi_1(i) = 0$$

از Ψ برای ذخیره مسیر استفاده می شود.

$\psi_t(i)$ محتمل ترین حالت قبل از حالت i در زمان t می باشد.

○ حلقه:

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(o_t) \quad \text{فرمول های بازگشتی زیر مهم ترین قسمت الگوریتم هستند:}$$

$$\psi_t(j) = \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}]$$

$$2 \leq t \leq T, 1 \leq j \leq N$$

○ پایان:

$$p^* = \max_{1 \leq i \leq N} [\delta_T(i)]$$

$$q_T^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)]$$

○ بازگشت به عقب برای پیمایش معکوس مسیر:

$$q_t^* = \psi_{t+1}(q_{t+1}^*), t = T-1, T-2, \dots, 1$$

1- مقدمه

اهداف درس:

در این فصل با آموزش مدل مخفی مارکوف آشنا می شویم

آموزش هم برای حالت گسسته و هم پیوسته بررسی خواهد شد

2- مسئله سوم برای HMM های گسسته

تعریف مسئله سوم:

فرض کنید یک مدل λ و یک دنباله مشاهدات O داریم، چگونه می توان پارامترهای مدل را تنظیم کرد که $P(O|\lambda)$ بیشینه شود (به عبارتی آموزش مدل از روی مشاهدات)؟

تخمین پارامترها بوسیله الگوریتم بیشینه سازی Expectation انجام می شود.

$$\begin{aligned}\xi_t(i, j) &= P(q_t = i, q_{t+1} = j | o, \lambda) \\ &= \frac{P(o, q_t = i, q_{t+1} = j | \lambda)}{P(o | \lambda)} \\ &= \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}\end{aligned}$$

قبل از شروع بحث تعریف زیر را در نظر بگیرید:

این مقدار احتمال پرش از حالت i به حالت j در زمان t را نشان می دهد.

نتیجه می شود که $\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j)$ را اگر همه j ها را در نظر بگیریم به احتمال وجود در حالت i در زمان t می رسیم که همان γ است.

$$\begin{aligned}\bullet & \sum_{t=1}^{T-1} \gamma_t(i) \quad \text{مقدار expected (از لحاظ آماری) تعداد پرش ها از حالت } i \\ \bullet & \sum_{t=1}^T \xi_t(i, j) \quad \text{مقدار expected (از لحاظ آماری) تعداد پرش ها از حالت } i \text{ به حالت } j\end{aligned}$$

با تعریف یک مقدار expectation و بیشینه کردن آن به فرمول ها زیر می رسیم (برای دیدن اثبات فرمول های زیر به کتاب

درسی مراجعه کنید):

$$\begin{aligned}\bar{\pi}_i &= \gamma_1(i) & \bar{a}_{ij} &= \frac{\sum_{t=1}^T \xi_t(i, j)}{\sum_{t=1}^T \gamma_t(i)} & \bar{b}_j(k) &= \frac{\sum_{t=1}^T \gamma_t(j)}{\sum_{t=1}^T \gamma_t(j)}\end{aligned}$$

فرمول های بالا برای آپدیت پارامترها (a و b و π) در هر تکرار از آموزش به کار می روند.

$$Q(\lambda' | \lambda) = \sum_q P(o, q | \lambda') \log P(o, q | \lambda)$$

