

و

می دانیم که:

$$\Rightarrow P(o, q | \lambda) = P(o | q, \lambda) P(q | \lambda)$$

نتیجه می گیریم که:

$$\Rightarrow P(o, q | \lambda) = \prod_{q_1} b_{q_1}(o_1) a_{q_1 q_2} b_{q_2}(o_2) \cdots a_{q_{T-1} q_T} b_{q_T}(o_T)$$

که به دست می آید:

$$\Rightarrow P(o | \lambda) = \sum_q P(o, q | \lambda) =$$

که فرمول نهایی به صورت زیر می باشد:

$$\sum_{q_1 q_2 \cdots q_T} \prod_{q_1} b_{q_1}(o_1) a_{q_1 q_2} b_{q_2}(o_2) \cdots a_{q_{T-1} q_T} b_{q_T}(o_T)$$

مرتبه زمانی الگوریتم بالا $O(2TN^T)$ می باشد. این مقدار بسیار بالا می باشد.

این به این خاصیت است که سعی می شود در حین محاسبه همه دنباله حالت ها در نظر گرفته شوند.

در ادامه راه حل هایی برای کاهش مرتبه زمانی ارائه خواهیم کرد.

• راه حل دوم مسئله اول:

نام روش روش Forward است.

این روش نوعی الگوریتم پویاست که در یک متغیر مقادیر میانی ذخیره می شوند برای استفاده آینده.

در این روش متغیری به نام α وجود دارد.

$$\alpha_t(i) = P(o_1, o_2, \dots, o_t, q_t = i | \lambda)$$

مقدار این متغیر احتمال حضور در حالت q_t است با دیدن مشاهدات o_1, \dots, o_t .

کل روند الگوریتم به صورت زیر است:

○ مقداردهی اولیه: $\alpha_1(i) = b_i(o_1) \prod_i, 1 \leq i \leq N$ احتمال شروع از هر حالت و تولید مشاهده اول.

○ حلقه:

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

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

احتمال حضور در حالت بعدی با توجه به مشاهدات انجام شده به صورت بالا محاسبه می شود.

یعنی فرض کنید می خواهیم α حالت j را محاسبه کنیم (عامل $[\sum_{i=1}^N \alpha_t(i) a_{ij}]$)

باید از همه حالت ها بپریم به j و سپس مشاهده مربوطه را تولید کنیم (عامل $b_j(o_{t+1})$)

○ پایان: احتمال مورد نظر با استفاده از جمع α های زمان T محاسبه می شود:

$$P(o | \lambda) = \sum_{i=1}^N \alpha_T(i)$$

مرتبه زمانی این الگوریتم $O(N^2T)$ می باشد.

• راه حل سوم مسئله اول:

این روش شبیه روش Forward می باشد.

با این تفاوت که از عقب به جلو عمل می شود. به همین خاطر نام متغیر Backward است.

در این روش متغیری به نام β داریم: $\beta_t(i) = P(o_{t+1}, o_{t+2}, \dots, o_T | q_t = i, \lambda)$

کل روند الگوریتم به صورت زیر است:

○ مقداردهی اولیه: $\beta_T(i) = 1, 1 \leq i \leq N$

○ حلقه:

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

$$t = T-1, T-2, \dots, 1 \text{ And } 1 \leq j \leq N$$

احتمال حضور در حالت قبلی با توجه به مشاهدات انجام شده به صورت بالا محاسبه می شود.

○ پایان: احتمال مورد نظر با استفاده از جمع β های زمان 1 محاسبه می شود:

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

مرتبه زمانی این الگوریتم $O(N^2T)$ می باشد.

4- مسئله دوم

• تعریف مسئله دوم:

فرض کنید یک مدل λ و یک دنباله مشاهدات O داریم، محتمل ترین دنباله حالات مدل که آن مشاهدات را تولید

کرده اند کدام است؟

• راه حل اول مسئله دوم:

هدف یافتن محتمل ترین دنباله حالات می باشد.

فرض کنید یک متغیر γ به صورت روبرو تعریف شود: $\gamma_t(i) = P(q_t = i | o, \lambda)$

یعنی احتمال وجود در حالت i در زمان t با دیدن مشاهدات. یعنی در هر زمان احتمال وجود در یک حالت را داریم.

مقدار γ به صورت زیر محاسبه می شود:

$$\gamma_t(i) = P(q_t = i | o, \lambda) = \frac{P(o, q_t = i | \lambda)}{P(o | \lambda)}$$

$$= \frac{P(o, q_t = i | \lambda)}{\sum_{i=1}^N P(o, q_t = i | \lambda)} = \frac{\alpha_t(i) \beta_t(i)}{\sum_{i=1}^N \alpha_t(i) \beta_t(i)}$$

که α و β همان متغیرهای Forward و Backward هستند.

محتمل ترین حالت به این صورت به دست می آید: $q_t^* = \arg \max_i [\gamma_t(i)], 1 \leq t \leq T, 1 \leq t = n \leq N$

یعنی در هر زمان ماکزیمم گیری می شود که کدام حالت بیشترین احتمال رخداد را دارد.



6 – خلاصه و نتیجه گیری

در این فصل با مدل مخفی مارکوف آشنا شدیم

همچنین با دو مسئله از سه مسئله مهم HMMها آشنا شدیم و نحوه حل آن را فرا گرفتیم

7 – منابع درس

- 1- Rabiner, “Fundamentals of Speech Recognition”
- 2- Huang, Acero, “Spoken Language Processing”
- 3- Deller, “Discrete-time processing of speech signals”