

مختار توزیع های آمیخته : شنبه ۸، ۹، ۹۴ (کتاب راسخ)

۱- معرفی مختار توزیع های آمیخته :

* تعریف : هر ترکیب محدب به صورت $\sum_{i=1}^k p_i f_i(x)$ که در آن $\sum_{i=1}^k p_i = 1$ و f_i هر

توزیع باشد، یک توزیع آمیخته است.

هم چنین یک توزیع آمیخته می تواند به صورت $g(x) = \int f(x|\theta) h(\theta) d\theta$ بیان می شود

۱۰ انواع توزیع های آمیخته فرم سلسله مراتبی دارند :

مثلاً توزیع آمیخته طما - بواسن : (می توانست)

گفته : $y | w_i \sim f(y | w_i) \equiv N(w_i)$

$y | w \sim \text{poisson}(\lambda w)$

$w \sim \text{gamma}(\alpha, \beta)$

$w_i \sim \text{Multinomial}(1, p_1, \dots, p_k)$

$f(y) = \int h(y|w) g(w) dw$

$g(y) = \sum_{i=1}^k p_i f(y | w_i)$

۲۰ اگر توزیع w می تواند باشد \Leftarrow آمیخته می تواند

اگر توزیع w گسسته باشد \Leftarrow آمیخته گسسته \Leftarrow دو امکان وجود دارد :

- finite mixture ①
- infinite mixture ②

۲- اهمیت و کاربرد توزیع‌های آمیخته :

۲-۱- کلن خوشه بندی بر مبنای درستی : و متن جهت را به k دسته تقسیم می کنیم که

داخل دسته ها خصوصیت مشابه دارند (مثلا واریانس) داخل

دسته ها کم و واریانس بین دسته ها زیاد است

۲-۲- مدل بندی outlier : یکی از راه های مدل بندی و بوجه outlier در مدل سازی

استفاده از mixture حالت. مثلا فرض کنید توزیع داده های ما $N(\mu, \sigma^2)$ است


ولی بر تعدادی outlier داریم. $0 < \alpha < 1$ کوچه را تقسیم کنیم و به بیسی از

دو صورت زیر عمل می کنیم :

15

روش اول فرض می کنیم توزیع داده ها به جای $N(\mu, \sigma^2)$ به صورت زیر است :

$$Y \sim (1 - \alpha) N(\mu, \sigma^2) + \alpha N(\mu, k\sigma^2) \quad k \gg 1$$



چون تعداد outlier من کم بوده ، می گیم

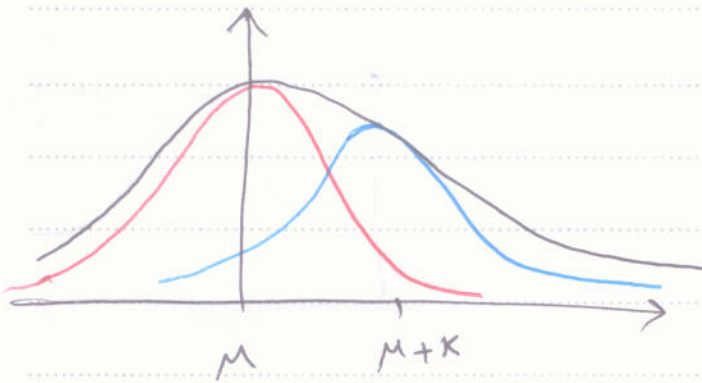
با احتمال کمی داده ها از توزیع $N(\mu, k\sigma^2)$

می آیند و با احتمال زیاد از $N(\mu, \sigma^2)$ می آیند.

25

روشن دوم فرض کنیم توزیع داده ها به جای $N(\mu, \sigma^2)$ به صورت زیر است:

$$Y \sim (1 - \pi_2) N(\mu, \sigma^2) + \pi_2 N(\mu + k, \sigma^2)$$



در واقع outlier های من مفقود طرف هستند.

۳-۲- در مدل سری داده های مستند:

در pattern-mixture model


۴-۲- در density Estimation: از این که هر توزیعی را می توان با امیخته k بعدی از نرمال

(k زیاده) تعریف زد، می توان از آمیخته ای از توزیع های نرمال، برای برآورد چگالی


داده ها استفاده کرد.

۳- و تری های و کساده های توزیع های امیخته:

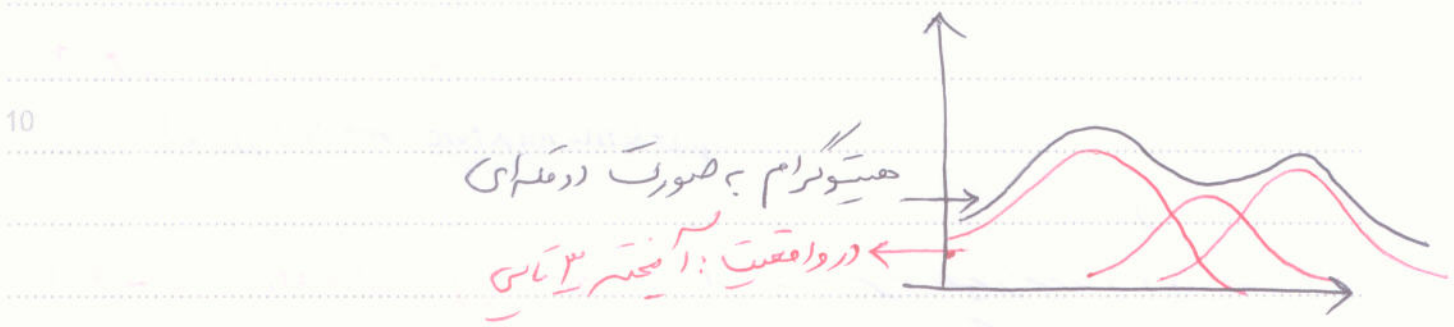


۳-۱- چند مدیولن: ماهی هسته گرام یک سری داده را رسم می کنیم:



در صورتی که در واقعیت به صورت دو به دو است



(یعنی مسئله این مدل را برآوردن دارد.)



۱۵ (گاهی هم فاکتور توزیع مثلاً k مدله داریم ولی وقتی رسم می کنیم می بینیم k^* تا
 قله (اره) یعنی برعکس حالت قبل) \leftarrow پس تعداد علم نشان (هذره تعداد k در افتخار هایت)

\leftarrow با رسم هیستوگرام نمی توانیم تعداد k را تشخیص دهیم. در مورد انتخاب k ، راه های

۲۰ زیادی وجود دارد که ساده ترین آن، بزرگترین عدد با k های متصل و مقایسه آنها از

صورتی AIC و BIC و ... است

۲۵ (ولی تویب با افتخار ای از مثال ها، راه مناسب تری است و می توانیم AIC و BIC را این
 مدل هم، با قبلی ها مقایسه کنیم.)

* اما وقتی هستوگرام داره های عا چندقله ای می شود ، حتماً دلیل داشته

1) گاهی دلیل چندقله ای بودن مشخص است : مثلاً مثال هگولوسن خون



به تعدادی حول هگولوسن 11 و به تعدادی حول 14 متمرکز شده اند . با استفاده از اطلاعات

بزرگی مشخص می شود که هگولوسن در زمان کمتر از مردان است و دلیل دوقله ای بودن

این هستوگرام جنیت است .

لکه حالا که دلیل دوقله ای بودن مشخص است ، در هر زیر گروه ، تحلیل های

جدگانه صورت می گیرد . مثلاً در گروه زنان توزیع را $N(\mu_1, \sigma_1^2)$ و در گروه مردان

توزیع را $N(\mu_2, \sigma_2^2)$ در نظر می گیریم و μ_1 و μ_2 هم که مشخص است

2) دلیل چندقله ای بودن مشخص نیست : در این صورت μ ها نامشخص اند و

نیاز به برآوردهایی داریم که در کسب برآوردهایی بکنیم اسکله می کنیم

۲-۳ - بدین آوردن بسا درهای توزیع های آمیخته :

$$Y \sim f(y) = \sum_{k=1}^K \eta_k h_k(y)$$

$$E(H(Y)) = \sum_{k=1}^K \eta_k E(H(Y_k)) \quad \leftarrow E(H(Y)) \text{ در زیر تابعه } k \text{ ام}$$

5 اثبات: $E(H(Y)) = \int_{-\infty}^{+\infty} H(y) f(y) dy$

$$= \int_{-\infty}^{+\infty} H(y) \sum_{k=1}^K \eta_k h_k(y) dy$$

10 (برای تساهل به حساب می آید) $= \sum_{k=1}^K \eta_k \int_{-\infty}^{+\infty} H(y) dy$

$$= \sum_{k=1}^K \eta_k E_k(H(Y)) \quad \square$$

15

$\Rightarrow \mu = E(Y) = \sum_{k=1}^K \eta_k E_k(Y_k)$ میانگین زیر تابعه k ام μ_k

20 $E((Y-\mu)^i) = \sum_{k=1}^K \eta_k E_k((Y-\mu)^i)$ $\pm \mu_k$

$$= \sum_{k=1}^K \sum_{r=0}^i \binom{i}{r} (\mu_k - \mu)^{i-r} E_k((Y-\mu_k)^r) \eta_k$$

\leftarrow زمانیکه $i=2$ ، (یعنی واریانس توزیع آمیخته) داریم:

25 $\sigma^2 = E((Y-\mu)^2) = \sum_{k=1}^K \eta_k ((\mu_k - \mu)^2 + \sigma_k^2)$

\downarrow
واریانس زیر تابعه k ام $= E_k((Y-\mu_k)^2)$

۲- برآورد مائیکس : \leftarrow رویکرد پلاسید \leftarrow رویکرد مینز

۳-۱- رویکرد پلاسید : ما فقط (اختیار) از توزیع های نرمال را در نظر می گیریم.

$$y \sim f(y) = \sum_{k=1}^K \pi_k N(\mu_k, \sigma_k^2)$$

5

$$\theta = (\mu_1, \dots, \mu_k, \sigma_1^2, \dots, \sigma_k^2, \pi_1, \dots, \pi_k)$$

۱) برآورد کلاسیک: که فقط در حالت خاص جواب می دهد و ما هم آن را بیان نمی کنیم.

۱۰) برآورد ML : که فقط برای اختیار ای از نرمال، آن هم در حالتی که $\pi_1 = \pi_2 = \dots = \pi_k$ بوده است

مدت آمده است \leftarrow بنابراین در حالت طی از الگوریتم EM استفاده می کنیم:

۱۵) اخت (مدت) آوردن در شانس پارامترها: $y_1, \dots, y_N \sim f(y)$

15

$$P(y|\theta) = L(\theta|y) = \prod_{i=1}^N \sum_{k=1}^K \pi_k N(y_i | \mu_k, \sigma_k^2)$$

نی توان ماری کرد

۲۰) با بر مبنی که نشان می دهد به هر زیر جامعه بایند، وجود داشته باشد ولی چون

20

این متغیر مشاهده شده است به آن latent variable می گویند و برای

سهولت محاسبات آن را وارد در شانس می کنند و الگوریتم EM بر مبنای

25

Expectation-maximization Algorithm

: EM الگوریتم

یک متغیر تصادفی گسسته w در $\{1, 2, \dots, k\}$ و مشخص می‌کنند. $w_i \in \{1, 2, \dots, k\}$ و مشخص می‌کنند. w_i از کدام گروه آمده است؟

است، در نظر می‌گیریم. در این حالت درستی داده‌های حاصل به صورت زیر است:

$$p(y, w | \theta) = L(\theta | y, w) = p(y | w, \theta) p(w | \theta)$$

خم سلیقه‌های
خوش را نشان
دهد

وقت کنیم که هر y_i می‌تواند فقط متعلق به یک زیرگروه باشد. بنابراین:

$$p(w_i = w_i) = \begin{matrix} w_i & 1 & 2 & \dots & k \\ p(w_i=1) & p(w_i=2) & \dots & p(w_i=k) \end{matrix} \xrightarrow{\text{sum}} f_{w_i} = \prod_{k=1}^k (p(w_i=k))^{I(w_i=k)} \quad k=1, 2, \dots, k$$

$$p(y, w | \theta) = f(y | w, \theta) p(w | \theta)$$

$$= \prod_{i=1}^N f(y_i | w_i, \theta) f(w_i | \theta)$$

$$= \prod_{i=1}^N \prod_{j=1}^k \left\{ N(y_i | \mu_j, \sigma_j^2) p(w_i=j) \right\}^{I(w_i=j)}$$

که چرا توان هم توان $I(w_i=j)$ می‌گیرد؟

$$y_i | w_i = j \sim N(\mu_j, \sigma_j^2) \quad I(w_i=j)$$

$$\Rightarrow \ell(\theta | y, w) = \sum_{i=1}^N \sum_{j=1}^k (I(w_i=j)) \ln N(y_i | \mu_j, \sigma_j^2)$$

همه برادر ML ما درستی را max می کنیم ولی در EM ما امید درستی (بر حسب W) را
 ماکزیم می کنیم. چون W تصادفی است از درستی بر حسب W امید می گیریم تا از
 سر تصادفی بودن W خلاص شویم و پس آن امید را max می کنیم.

الگوریتم EM بد روش تکرار است. پس با نقطه شروع لایه $\theta^{(0)}$ شروع می کنیم.

$$\theta^{(0)} = (\mu_1^{(0)}, \dots, \mu_k^{(0)}, \sigma_1^{(0)}, \dots, \sigma_k^{(0)}, \eta_1^{(0)}, \dots, \eta_{k-1}^{(0)})$$

والگوریتم EM سه مرحله Step است:

E-Step: $E_w(\ell(\theta | y, w))$

M-Step: $Q(\theta, \theta^{(p-1)}) = E_w[\ell(\theta | y, w) | y, \theta^{(p-1)}]$

$$= \sum_{w \in S_w} P(w | y, \theta^{(p-1)}) \log P(y, w | \theta)$$

$$\theta^{(p)} = \arg \max_{\theta} Q(\theta, \theta^{(p-1)})$$

این الگوریتم تا جایی ادامه پیدا می کند که اختلاف $\theta^{(p-1)}$ و $\theta^{(p)}$ کم شود.