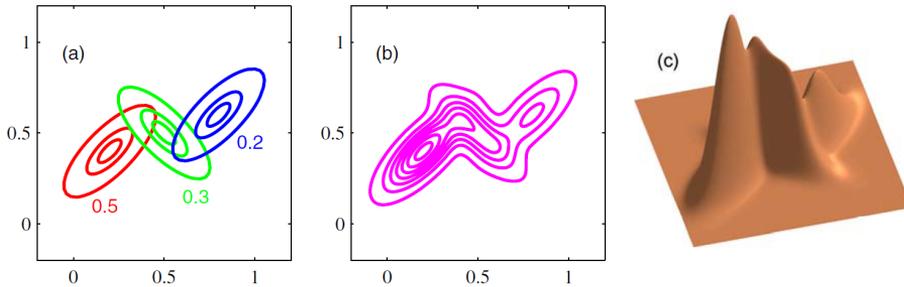


Mladen Nikolić

Anđelka Zečević

# MAŠINSKO UČENJE

Beograd  
2019.



Slika 14.4: Ilustracija mešavine normalnih raspodela. Na slici (a) prikazane su konture tri normalne raspodele sa pridruženim verovatnoćama da tačka pripada klasteru (brojevima 0.5, 0.3 i 0.2). Na slici (b) prikazane su konture mešavine, a na slici (c) njen grafik.

## 14.2 Mešavina normalnih raspodela i EM algoritam

Mešavina normalnih raspodela (eng. *mixture of Gaussians*) predstavlja nešto sofisticiraniji model klasterovanja od modela  $k$  sredina, ali je zanimljivo primetiti da postoji i veza, koja će biti objašnjena na kraju. Osnovna pretpostavka je da se podaci mogu podeliti u određeni broj relativno kompaktnih globularnih klastera čiji se oblik može dobro opisati normalnim raspodelama sa različitim prosecima i matricama kovarijacije. Proseci, jasno, definišu pozicije klastera u prostoru, dok matrice kovarijacije opisuju njihov oblik i orijentaciju u prostoru. Površi jednake gustine u okviru jednog klastera u tom slučaju predstavljaju elipsoide. U ovom modelu, raspodela je malo složenija nego u dosadašnjim, ali ima prirodnu dekompoziciju na jednostavnije raspodele. Zamislimo kako se može dobiti nasumično generisana tačka iz ovakve raspodele. Prvo se može nasumice izabrati klaster, a potom se iz tog klastera može izabrati tačka u skladu sa normalnom raspodelom koja mu odgovara. Ukoliko je  $C$  broj klastera i za brojeve  $p_1, \dots, p_C$  važi  $p_i \geq 0$  i  $\sum_{i=1}^C p_i = 1$ , onda  $(p_1, \dots, p_C)$  predstavlja multinomijalnu raspodelu nad klasterima. Gustina raspodele nad instancama se može zapisati kao:

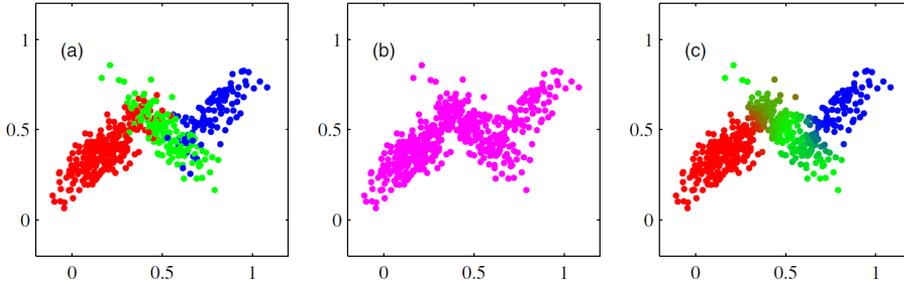
$$p(x) = \sum_{i=1}^C p_i \mathcal{N}(x; \mu_i, \Sigma_i)$$

gde je  $\mathcal{N}$  gustina normalne raspodele sa više promenljivih

$$\mathcal{N}(x; \mu, \Sigma) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu)^T \Sigma^{-1} (x - \mu)\right)$$

Ovo je ilustrovano slikom 14.4.

Primetimo da ovaj model prestavlja generativni model i mogao bi se koristiti u različite svrhe, pa i u svrhe klasifikacije. Pošto svakoj klasi može odgovarati



Slika 14.5: Ilustracija podataka iz mešavine normalnih raspodela. Na slici (a) prikazani su podaci kao uzorci iz raspodele  $p(x, z) = p(x|z)p(z)$ , zbog čega se na slici vidi i njihova boja, koja se dobija na osnovu multinomijalne raspodele i pozicija, koja se dobija na osnovu normalne raspodele. Na slici (b), prikazana je informacija koja se može dobiti na osnovu marginalne raspodele  $p(x)$  i otud nije poznata informacija o promenljivim  $z$ , odnosno o bojama. Na slici (c) tačke su obojene mešavinom boja klastera, pri čemu je svaka od boja zastupljena proporcionalno verovatnoći da tačka pripada tom klasteru.

jedan klaster, uslovna raspodela  $p(x|z = c)$  je definisana kao dogovarajuća normalna raspodela, a ona se može koristiti za klasifikaciju, jer Bajesova teorema omogućava da se na osnovu nje izračuna  $p(y|x)$ . Ipak, time se nećemo baviti. U kontekstu klasterovanja, neka promenljiva  $z$  uzima vrednosti od 1 do  $C$  u skladu sa multinomijalnom raspodelom  $(p_1, \dots, p_C)$ . Verovatnoća da instanca pripada klasteru  $k$  je

$$p_w(z = k|x) = \frac{p_w(x|z = k)p_w(z = k)}{p_w(x)} = \frac{p_w(x|z = k)p_w(z = k)}{\sum_{k=1}^C p_w(x|z = k)p_w(z = k)}$$

gde je  $w$  vektor parametara koji objedinjuje sve parametre iz svih vektora  $\mu_k$  i matrica  $\Sigma_k$ , kao i  $(p_1, \dots, p_C)$ . Ilustracija podataka kao uzoraka iz mešavine raspodela, data je na slici 14.5

Primitimo da, iako se koriste u modelu, vrednosti promenljive  $z$  za različite instance nisu poznate u vreme obučavanja. Primitimo takođe, da bi problem bio vrlo jednostavan ukoliko bi bile. Kada su poznate vrednosti  $z_i$  za svaku od instanci, parametri  $\mu_k$  i  $\Sigma_k$  normalne raspodele klastera  $k$  se ocenjuju standardnim empirijskim ocenama – prosekom instanci za koje važi  $z_i = k$  matricom kovarijacija između svih atributa izračunatom na osnovu tih instanci. U ovakvim situacijama, kada se može pretpostaviti da postoje takozvane *latentne*, odnosno *skrivenne* promenljive  $z$  koje nisu opažene i kada je ocena parametara raspodele  $p_w(x)$  teška, a ocena parametara raspodele  $p_w(x, z)$  laka (kada su dati empirijski podaci i za  $x$  i za  $z$ ), pribegava se algoritmu *maksimizacije očekivanja* (eng. *expectation maximization*) ili, skraćeno – *EM algoritmu*.

EM algoritam ćemo prikazati prvo u opštem obliku, pa ćemo ga precizirati

za model mešavine normalnih raspodela. Za logaritam funkcije verodostojnosti parametara važi:

$$\ell(w) = \log \mathcal{L}(w) = \sum_{i=1}^N \log p_w(x_i) = \sum_{i=1}^N \log \int_z p_w(x_i, z) dz$$

ili u diskretnom slučaju

$$\ell(w) = \log \mathcal{L}(w) = \sum_{i=1}^N \log p_w(x_i) = \sum_{i=1}^N \log \sum_{k=1}^C p_w(x_i, k)$$

Ovaj problem nije lak za rešavanje, pošto logaritam ne može da prođe kroz sumu. Rešenje se sastoji u posmatranju funkcije verodostojnosti u odnosu na zajedničku raspodelu promenljivih  $x$  i  $z$ . Imajući u vidu da svakoj instanci pored vrednosti opaženih promenljivih  $x$  odgovaraju i vrednosti latentnih promenljivih  $z$ , ovo je potpuno legitimno, ali kako vrednosti  $z$  nisu poznate, takva funkcija verodostojnosti se ne može izračunati, već predstavlja slučajnu promenljivu. Iako se ona ne može izračunati, može se izračunati njeno očekivanje u odnosu na promenljive  $z$ , tako da optimizacija može biti vršena po njemu. Konkretno, logaritam funkcije verodostojnosti koja uzima u obzir i promenljive  $z$  je

$$\ell(w) = \sum_{i=1}^N \log p_w(x_i, z_i)$$

Neka je  $Q$  pomoćna funkcija

$$Q(w, w^{t-1}) = \mathbb{E}_z[\ell(w)|w^{t-1}] = \int \ell(w) p_{w^{t-1}}(z) dz$$

Nova vrednost parametara  $w$  se dobija maksimizacijom funkcije  $Q$ . Konkretno

$$w^t = \arg \max_w Q(w, w^{t-1})$$

Ovako definisan algoritam se može podeliti u dva koraka. U prvom se ocenjuje funkcija  $Q$ . Ovaj korak se naziva E, pošto se u tom postupku zapravo vrši ocena očekivanja. U drugom koraku se vrši maksimizacija, pa se zato naziva korak M. Ovaj algoritam ima jedno zanimljivo svojstvo, a to je da se vrednost funkcije  $Q$  nikad ne smanjuje, što može biti korisno pri debugovanju njegove implementacije.

U slučaju problema klasterovanja pomoću mešavine normalnih raspodela,

funkcija  $Q$  ima sledeći oblik:

$$\begin{aligned}
Q(w, w^{t-1}) &= \mathbb{E} \left[ \sum_{i=1}^N \log p_w(x_i, z_i) \right] \\
&= \sum_{i=1}^N \mathbb{E} \left[ \log \left[ \prod_{k=1}^C p_k p_w(x_i)^{I(z_i=k)} \right] \right] \\
&= \sum_{i=1}^N \sum_{k=1}^C \mathbb{E}[I(z_i = k)] \log[p_k p_w(x_i)] \\
&= \sum_{i=1}^N \sum_{k=1}^C p_{w^{t-1}}(z_i = k|x_i) \log[p_k p_w(x_i)] \\
&= \sum_{i=1}^N \sum_{k=1}^C p_{w^{t-1}}(z_i = k|x_i) \log p_k + \sum_{i=1}^N \sum_{k=1}^C p_{w^{t-1}}(z_i = k|x_i) \log p_w(x_i)
\end{aligned}$$

Korak E se sastoji od izračunavanja veličine  $p_{w^{t-1}}(z_i = k|x_i)$  na sledeći način:

$$p_{w^{t-1}}(z_i = k|x_i) = \frac{p_k \mathcal{N}(x; \mu_k^{t-1}, \Sigma_k^{t-1})}{\sum_{j=1}^C p_j \mathcal{N}(x; \mu_j^{t-1}, \Sigma_j^{t-1})}$$

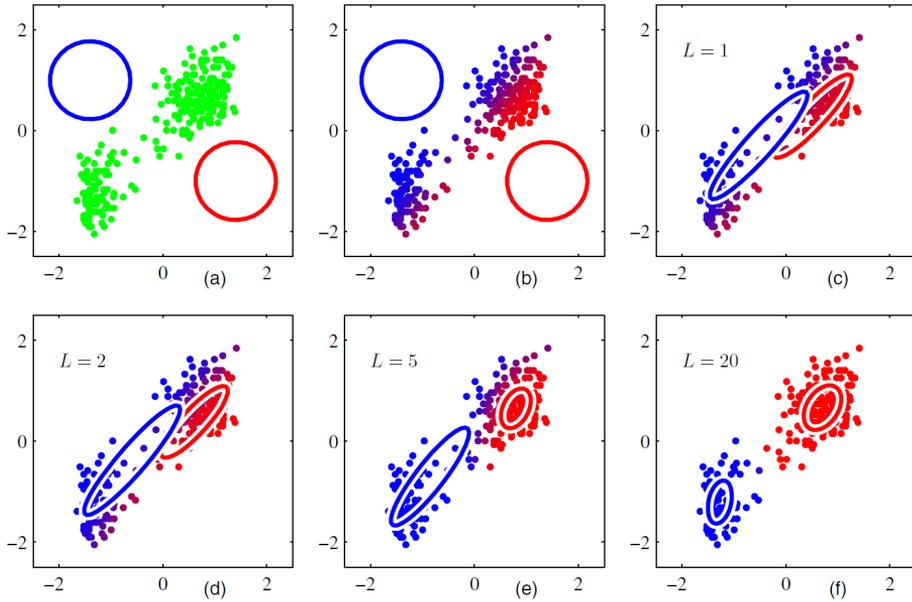
Kako su sve vrednosti koje izraz uključuje definisane u prethodnom koraku, ovaj izraz je lako izračunati.

Korak M se sastoji od maksimizacije funkcije  $Q$  po  $w$ , odnosno po veličinama  $p_k$ ,  $\mu_k$  i  $\Sigma_k$ . Može se izvesti sledeće rešenje:

$$\begin{aligned}
p_k &= \frac{1}{N} \sum_{i=1}^N p_{w^{t-1}}(z_i = k|x_i) \\
\mu_k &= \frac{\sum_{i=1}^N p_{w^{t-1}}(z_i = k|x_i) x_i}{\sum_{i=1}^N p_{w^{t-1}}(z_i = k|x_i)} \\
\Sigma_k &= \frac{\sum_{i=1}^N p_{w^{t-1}}(z_i = k|x_i) (x_i - \mu_k)^T (x_i - \mu_k)}{\sum_{i=1}^N p_{w^{t-1}}(z_i = k|x_i)}
\end{aligned}$$

Primetimo da su izvedene formule intuitivne. Naime,  $p_k$  je praktično udeo instanci koje su pridružene klasteru  $k$ , s tom ogradom da sad svaka instanca pripada svakom klasteru, ali sa težinom  $p_{w^{t-1}}(z_i = k|x_i)$ . Prosek ovih težina za klaster  $k$  je ocena  $p_k$ . Slično, prosek klastera  $k$  je prosek svih instanci, ali otežanih u skladu sa udelom sa kojim pripadaju tom klasteru. Interpretacija formule za kovarijansu je potpuno analogna. Izvršavanje ovog algoritma u više iteracija ilustrovano je na slici 14.6.

Primetimo da se algoritam  $k$  sredina može posmatrati kao jednostavnija verzija klasterovanja pomoću mešavine normalnih raspodela koja se karakteriše sledećim pretpostavkama:



Slika 14.6: Izvršavanje EM algoritma za mešavinu normalnih raspodela u 20 koraka.

- $\Sigma_k = \sigma^2 I$  za svako  $k$ ,
- $p_k = 1/C$  za svako  $k$  i
- $p(z_i = k|x_i)$  je 1 ako je među svim prosecima  $\mu_j$  instanci  $x_i$  najbliži baš  $\mu_k$ , a 0 u suprotnom

Očito, klasterovanje zasnovano na mešavini normalnih raspodela je značajno izražajnije – može prirodno modelovati ne samo loptaste klasterne, već i klasterne u obliku elipsoida različitih orijentacija u prostoru. Pritom njihov oblik se može ustanoviti na osnovu matrice kovarijanse, što znači da ovaj model omogućava i interpretaciju. Takođe, dodele instanci klasterima nisu tvrde, već mogu izražavati i pouzdanost da instanca pripada nekom klasteru.