

بخش بندی تصاویر بر اساس مدل میدان تصادفی مخفی مارکوف

سید مهدی صفوی^۱، محمد میکایلی^۲، محمد پویان^۳

۱-دانشجو گروه مهندسی پزشکی دانشکده فنی مهندسی دانشگاه شاهد

۲و۳-عضو هیات علمی دانشیار گروه مهندسی پزشکی دانشکده فنی مهندسی دانشگاه شاهد

safavi.mehdi@gmail.com

pooyan@shahed.ac.ir

m_mikaili@yahoo.com

چکیده — ما با مطالعه مدل مخفی میدان تصادفی مارکوف از الگوریتم EM جهت تخمین پارامترهای مدل استفاده کردیم تا بتوانیم بر اساس آن بخش بندی تصویر را انجام دهیم. در این مقاله برای پارامترها از مدل گوسی استفاده شده که طی الگوریتم EM تخمین زده شده و سپس با روش MAP بخش بندی تصویر بر اساس تئوری Hammersly-Clifford بروزرسانی میشود. پیاده سازی مدل در بخشهای مجزا ارایه شده است.

واژه‌های کلیدی — مدل مخفی میدان تصادفی مارکوف (HMRF)Hidden Markov Random Field Model ، EM (Expectation Maximization) MAP ، (Maximum Aposterior Probability)

حاصل بخش بندی تصویر، یک تصویر معادل برچسب گذاری شده است که با بردار $X = (x_0, x_1, x_2, \dots, x_N)$ که در آن $x_i \in L$ بیان میشود. برای مثال در بخش بندی باینری مجموعه L دارای دو عضو $L = \{0, 1\}$ بوده و x_i مقدار 0 یا 1 را خواهد داشت.

برای برچسب گذاری تصویر، طبق معیار MAP در جستجوی X^* ای هستیم که حداکثر احتمال X را با دانستن Y ، طبق رابطه (۱) برآورده کند.

$$X^* = \operatorname{argmax} \{P(X|Y)\} = \operatorname{argmax} \{P(Y|X, \theta)P(X)\} \quad (1)$$

که در آن $P(X)$ احتمال پیشین با توزیع Gibbs و $P(Y|X, \theta)$ احتمال توام درست نمایی از رابطه (۲) بدست می

۱. مقدمه:

میدان های تصادفی مارکوف (MRF) در مسایل بینایی ماشین مانند بخش بندی تصویر و بازسازی آن کاربرد دارد. از ویژگیهای بارز آن میتوان به الگوریتمهای کارا، مانند مدهای شرطی تکراری با لحاظ وفاداری به دیتا و همواری و نرمی مدل اشاره نمود.

قالب HMRF-EM در ابتدا برای بخشبندی تصاویر MRI ارایه شد [۷]

در یک تصویر متشکل از N پیکسل، شدت روشنایی تصویر را با بردار $Y = (y_0, y_1, y_2, \dots, y_N)$ نشان میدهم که y_i شدت روشنایی پیکسل i ام میباشد. در تصویر رنگی شدت روشنایی در سه بعد R, G و B بصورت مجزا YR, YG, YB بیان میشود.


این تئوری اگر $P(X)$ یک حوزه برجسب زنی MRF باشد آنگاه بایستی از توزیع Gibbs پیروی کند. پس احتمال تخصیص برجسب به هر پیکسل به شرط مشاهده همسایه ها است.

$$P(X) = \frac{1}{Z} \exp(-U(X))$$

$$U(X) = \sum_{\substack{j \in N_i \\ c \in C}} V_c(l, x_i)$$

تعریف کلیک یا دسته Clique

زیر مجموعه C از همسایگی هر پیکسل را در حوزه برجسب زنی یک دسته میگویند اگر هر جفت پیکسل در این زیر مجموعه همسایه باشند. این همسایگی میتواند هشت تایی و چهارتایی تعریف شود. در این مقاله برای هر پیکسل دسته چهار همسایگی، مطابق شکل در نظر گرفته شده است.



شکل (۲)

برای محاسبه انرژی در حوزه لیبیل تصویر ELF، به لیبیلی کلیک یا دسته ی هر پیکسل توجه میکنیم.

$$ELF = U(X)$$

برای تمام پیکسهای تصویر میزان شباهت لیبیل دسته ها با لیبیل l ام تصویر با $I_{x_i, l}$ تعیین میشود.

$$I_{x_i, l} = \begin{cases} 0 & \text{if } x_i \neq l \\ 1 & \text{if } x_i = l \end{cases}$$

پس از شباهت سنجی، میتوان پتانسیل هر دسته را طبق رابطه () بدست آورد. و یا با رابطه () مستقیما پتانسیل هر دسته را در حوزه لیبیل l ام تصویر بدست آورد.

$$V_c(l, x_i) = \frac{1}{2} (1 - I_{x_i, l})$$

$$V_c(l, x_i) = \begin{cases} \frac{1}{2} & \text{if } x_i \neq l \\ 0 & \text{if } x_i = l \end{cases}$$

بنابراین انرژی هر دسته در حوزه لیبیل l ام ELF قابل محاسبه خواهد بود.

الگوریتم EM

آید که در آن $P(y_i | x_i, \theta_{x_i})$ یک توزیع گوسی با پارامترهای $\theta_{x_i} = (\mu_{x_i}, \sigma_{x_i})$ است.


$$P(Y|X, \Theta) = \prod_i P(y_i | X, \Theta)$$

$$= \prod_i P(y_i | x_i, \theta_{x_i}) \quad (۲)$$

معمولا در مسائل MRF، آموزش مجموعه پارامتر θ از طریق دیتای آموزشی صورت میگیرد. برای مثال در مسائل بخش بندی دانش قبلی راجع به توزیع شدت پس زمینه و روی زمینه ممکن است در یک مجموعه اطلاعات (دیتا ست) ثابت باشد. بنابراین ما می توانیم پارامترها را از طریق برخی تصاویر که بصورت دستی برجسب گذاری شده آموزش دهیم و آن پارامترها را برای اجرای MRF جهت بخش بندی سایر تصاویر بکاربندیم.

تفاوت اصلی بین MRF و HMRF اینست که در HMRF مجموعه پارامترهای θ بدون راهنما آموزش داده میشوند (unsupervised).

در مدل HMRF برای مساله بخش بندی تصویر، نیازی به مرحله آموزش نیست و فرض میشود دانشی راجع به توزیع شدت روشنایی پیش زمینه و پس زمینه ارایه نشده باشد. بنابراین الگوریتم EM جهت بدست آوردن مجموعه پارامتر $\Theta = \{\theta_l | l \in L\}$ پیشنهاد میشود که در سیر تکراری اطلاعات آن تکمیل میشود.



شکل (۱)

۲. مواد و روشها:

تئوری Hammersly-Cliford

در تصاویر حقیقی پیکسلهای همسایگی معمولا ویژگی مشابهی دارند (شدت روشنایی، رنگ و بافت و ...) که براساس

برای مدل سازی بر پایه توزیع گوسی بایستی یک بخش بندی اولیه داشته باشیم. این بخش بندی اولیه یا به عنوان اطلاعات اولیه داده میشود یا از طریق الگوریتمی آن را بدست آورد.

در این بخش با استفاده از الگوریتم خوشه بندی k-means یک بخش بندی اولیه روی شدت سطح خاکستری پیکسل های تصویر اعمال میکنیم تا برچسب اولیه $X^{(0)}$ را در k کلاس فراهم شود. حال می توان پارامترهای اولیه مدل $\Theta^{(0)}$ را برای هر

$$\theta_l = (\mu_l, \sigma_l) \text{ کلاس بدست آورد.}$$

$$\Theta = \{\theta_l \mid l \in L\}$$

الگوریتم EM

طبق مراحل زیر تغییر خواهد کرد

شروع با مجموعه پارامتر اولیه $\Theta^{(0)}$

مدلسازی توزیع روی هر لیبیل و محاسبه انرژی حوزه برچسب گذاری EFF و انرژی حوزه ویژگی ELF(شدت روشنایی) آن

$$\begin{aligned} EFF_l &= U(Y|X, \theta_l) = \sum_i U(y_i|x_i, \theta_l) \\ &= \sum_i \frac{(y_i - \mu_{x_i})^2}{2\sigma_{x_i}^2} + \ln \sigma_{x_i} \\ ELF_l &= U(X) = \sum_{j \in N_i} V_c(l, x_j^{(k)}) \end{aligned}$$

با استفاده از مجموعه پارامتر فعلی $\Theta^{(l)}$ ، $X^{(l)}$ را آپدیت کنید. که با روش MAP تخمین $X^{(l)}$ انجام میشود. در بخش ۵ بحث خواهد شد.

$$\begin{aligned} X^{(l)} &= \arg \max_{X \in \mathcal{X}} \{P^{(l)}(Y|X, \Theta^{(l)}) \cdot P(X)\} \\ &= \arg \min_{X \in \mathcal{X}} \{U(Y|X, \Theta^{(l)}) + U(X)\} \end{aligned} \quad (۸)$$

محاسبه چگالی احتمال توزیع پسین برای تمام $l \in L$ و

$$y_i \text{ که } x_{N_i}^{(l)} \text{ پیکره بندی همسایگی } x_i^{(l)}$$

$$P^{(l)}(l|y_i) = \frac{G(y_i; \theta_l) P(l|x_{N_i}^{(l)})}{P^{(l)}(y_i)} \quad (۹)$$

$$P^{(l)}(y_i) = \sum_{l \in L} G(y_i; \theta_l) P(l|x_{N_i}^{(l)}) \quad (۱۰)$$

$$P(l|x_{N_i}^{(l)}) = \frac{1}{Z} \exp\left(-\sum_{j \in N_i} V_c(l, x_j^{(l)})\right) \quad (۱۱)$$

۱. استفاده از $P^{(l)}(l|y_i)$ برای آپدیت پارامترهای مدل

ما از الگوریتم EM برای تخمین مجموعه پارامتر Θ طبق مراحل زیر استفاده کرده ایم.

شروع: فرض کنید مجموعه پارامتر اولیه ما $\Theta^{(0)}$ باشد.

مرحله E: $\Theta^{(t)}$ مجموعه پارامتر در t امین تکرار بوده و

امید شرطی را طبق رابطه زیر بدست می آوریم

$$\begin{aligned} Q(\Theta|\Theta^{(t)}) &= E[\ln P(X, Y|\Theta)|Y, \Theta^{(t)}] \\ &= \sum_{X \in \mathcal{X}} [P(X|Y, \Theta) \ln P(X, Y|\Theta^{(t)})] \end{aligned} \quad (۳)$$

که \mathcal{X} مجموعه ای از مقادیر ممکن برچسب هاست.

مرحله M: حالا بایستی $Q(\Theta|\Theta^{(t)})$ را بیشینه کنیم تا $\Theta^{(t+1)}$

تخمین بعدی مجموعه پارامتر را بدست آوریم

$$\Theta^{(t+1)} = \arg \max_{\Theta} \{Q(\Theta|\Theta^{(t)})\} \quad (۴)$$

پس با جاگذاری $\Theta^{(t+1)} \rightarrow \Theta^{(t)}$ مرحله E را تکرار می

کنیم.

فرضیات مساله:

با یک سری از فرضیات به تشریح الگوریتم خواهیم پرداخت:

فرض ۱: اگر $G(z; \theta_l)$ تابع توزیع گوسی با پارامترهای $\theta_l = (\mu_l, \sigma_l)$ باشد:

$$G(z; \theta_l) = \frac{1}{\sqrt{2\pi}\sigma_l} \exp\left(-\frac{(z - \mu_l)^2}{2\sigma_l^2}\right) \quad (۵)$$

فرض ۲: احتمال پیشین $P(X)$ را به صورت یک توزیع

Gibbs بیان می کنیم که در آن $U(X)$ را تابع انرژی حوزه لیبیل می نامیم.

$$P(X) = \frac{1}{Z} \exp(-U(X)) \quad (۶)$$

فرض ۳: همچنین اگر $P(Y|X, \Theta)$ نیز از توزیع گوسی

حاصل شده باشد آنگاه میتوان آن را در فرم توزیع Gibbs طبق رابطه زیر بیان نمود

$$\begin{aligned} P(Y|X, \Theta) &= \prod_i P(y_i|x_i, \theta_{x_i}) \\ &= \prod_i G(y_i; \theta_{x_i}) = \frac{1}{Z'} \exp(-U(Y|X)) \\ &= \prod_i \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(y_i - \mu_i)^2}{2\sigma_i^2}\right) = \frac{1}{Z'} \exp(-U(Y|X)) \end{aligned} \quad (۷)$$

محاسبه مجموعه پارامتر اولیه با k-means

۳. جمع بندی :

با الگوریتم EM بخش بندی تصاویر در میدان مدل مخفی تصادفی مارکوف پیاده سازی انجام شد. این الگوریتم بر روی تصویر حاصل از روش kmeans پالایش انجام میدهد. در تصاویری که پیچیدگی دارند در تخمین توزیع شدت انرژی پیکسل های آن، نمیتوان نتایج پالایشی خوبی گرفت و باید از ویژگی دیگری برای آن استفاده کرد. نتیجه اعمال الگوریتم ارایه شده در شکل (۳) ارایه شده است.

Input Image



initial labels from kmeans



$$\mu_i^{(t+1)} = \frac{\sum_i P^{(t)}(l | y_i) \cdot y_i}{\sum_i P^{(t)}(l | y_i)} \quad (12)$$

$$(\sigma_i^{(t+1)})^2 = \frac{\sum_i P^{(t)}(l | y_i) \cdot (y_i - \mu_i^{(t+1)})^2}{\sum_i P^{(t)}(l | y_i)} \quad (13)$$

۲. بررسی شروط همگرایی EFF+ELF یا حداکثر تکرار الگوریتم جهت اتمام و یا ادامه الگوریتم که با جاگذاری $\Theta^{(t)} \rightarrow \Theta^{(t+1)}$ و پرش به مرحله ۲ میسر خواهد بود.

تخمین MAP

با توجه به اینکه در الگوریتم EM نیاز به یافتن X^* است که در آن کل انرژی پسین حداقل می شود

$$X^* = \arg \min_{X \in \mathcal{X}} \{U(Y | X, \Theta) + U(X)\} \quad (14)$$

$$U(Y | X, \Theta) = \sum_i U(y_i | x_i, \Theta)$$

$$U(y_i | x_i, \Theta) = \frac{(y_i - \mu_{x_i})^2}{2\sigma_{x_i}^2} + \ln \sigma_{x_i} \quad (15)$$

$$U(Y | X, \Theta) = \sum_i \left(\frac{(y_i - \mu_{x_i})^2}{2\sigma_{x_i}^2} + \ln \sigma_{x_i} \right)$$

$$U(X) = \sum_{c \in C} V_c(X) \quad (16)$$

که $V_c(X)$ پتانسیل دسته یا گروه همسایگی و C مجموعه

تمام دسته های ممکن می باشد.

ما در حوزه تصویر فرض می کنیم که یک پیکسل دارای حداکثر چهار همسایگی است بنابراین پتانسیل گروه بر روی جفتهای همسایگی پیکسلها تعریف میشود

$$V_c(x_i, x_j) = \frac{1}{2} (1 - I_{x_i, x_j}) \quad (17)$$

$$I_{x_i, x_j} = \begin{cases} 0 & \text{if } x_i \neq x_j \\ 1 & \text{if } x_i = x_j \end{cases} \quad (18)$$

ما الگوریتم تکراری را برای حل (۱۴) توسعه دادیم با:

شروع راه حل با تخمین اولیه $X^{(0)}$ است که از حلقه قبلی

الگوریتم EM گرفته شده است

و جستجو می کنیم $1 < i < N$ آماده شده برای $X^{(k)}$

$$X^{(k+1)} = \operatorname{argmin}_{l \in L} \left\{ U(y_i | l) + \sum_{j \in N_i} V_c(l, x_j^{(k)}) \right\}$$

تکرار مرحله ۲ تا همگرایی $U(Y | X, \Theta) + U(X)$ یا رسیدن

به حداکثر تکرار k

finallabels



شکل (۳)