


حل مساله‌ی خوشه‌بندی طیفی با استفاده از روش لاگرانژ افزوده‌شده



دانشجو: محمدرضا صادقی
استاد راهنما: دکتر محمدعلی اخایی
دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران

نتایج

در این قسمت به ارزیابی کارایی الگوریتم ارائه شده پرداخته خواهد شد. الگوریتم ارائه شده بر روی ۳ دیتاست ساختگی و ۶ دیتاست واقعی اجرا شده‌است و با ۴ روش دیگر مقایسه شده است. که نتایج آن به شرح زیر است.



شکل ۱: نتایج بر روی دیتاست‌های ساختگی

جدول ۱: مقایسه‌ی روش‌های مختلف روی دیتاست‌های واقعی

	K-means	SEI [1]	MBSC [2]	RCSF [3]	Proposed
Yeast	45.62	67.99	47.17	64.49	77.96
TOX	57.89	73.68	66.08	72.51	80.11
Glass	51.40	50.00	47.66	50.93	56.54
Ecoli	64.28	79.76	66.07	72.02	84.52
Usps	78.50	82.10	70.40	74.50	86.30
Jaffe	80.28	91.07	85.91	88.26	94.83

مقدمه

گراف‌ها ابزار ریاضی مناسبی برای بیان روابط متقابل بین داده‌ها هستند. در تئوری گراف، داده‌ها با گره‌ها و روابط بین آنها با یال‌های گراف مدل می‌شود. نمونه‌ی نمایش داده‌ها به صورت گراف را می‌توان در بسیاری از کاربردها از جمله شبکه‌های اجتماعی و الگوهای ترافیکی در شبکه‌های کامپیوتری مشاهده کرد. هدف این پروژه، خوشه‌بندی گره‌های یک گراف یال‌دار است به گونه‌ای که گره‌هایی از گراف که یال‌های بین آنها وزن بیشتری دارند با احتمال بیشتری در یک خوشه قرار گیرند. به این نوع خوشه‌بندی، خوشه‌بندی طیفی می‌گویند.

مدل پیشنهادی

برای حل مساله‌ی خوشه‌بندی طیفی باید به هر گره‌ی گراف وزن‌دار یک بردار تخصیص داده شود (بردارهای $u \in R^{1 \times K}$) به گونه‌ای که در فضای جدید آن دسته از گره‌هایی که وزن بیشتری روی یال متصل کننده‌ی آنها است، به یکدیگر نزدیکتر باشند. برای این منظور تابع خطایی تعریف می‌شود که در نقطه‌ی کمینه‌ی آن، بردارهایی بدست آیند که ویژگی‌های یاد شده را دارا باشند. تابع خطای مذکور به شکل زیر است:

$$B = w_{ij} \left\| u_i - u_j \right\|^2 = \text{Tr}(U^T L U)$$

$$s.t \quad U^T U = I_{K \times K}$$

در رابطه‌ی فوق $U = [u_1, \dots, u_N]^T$ و L ماتریس لاپلاسین گراف است. این تابع خطا در حالت کمینه به نقاطی همگرا می‌شود که وقتی وزن بین دو گره‌ی گراف زیاد باشد نقاط متناظر آنها در فضای جدید نزدیک به هم قرار می‌گیرند. محدودیت اضافه شده در مساله‌ی بهینه‌سازی به این منظور است که ویژگی‌ها در بردار U از هم ناهمبسته باشند و الگوریتم به جواب جزئی ماتریس صفر همگرا نشود.

برای حل مساله‌ی فوق ابتدا با استفاده از الگوریتم لاگرانژ افزوده‌شده تابع خطایی تعریف می‌کنیم که محدودیت را از بین ببرد. سپس برای حل آن از الگوریتم آدام استفاده می‌کنیم. تابع خطای جدید به فرم زیر است.

$$B = \frac{1}{2} \text{Tr}(U^T L U) + \text{Tr}(\lambda^T (U^T U - I_{K \times K})) + c \text{Tr}((U^T U - I_{K \times K})^T (U^T U - I_{K \times K}))$$

برای حل مساله به روش لاگرانژ افزوده‌شده یک جمله‌ی جریمه به تابع خطا اضافه می‌شود که با آن بتوان مقادیر ماتریس $\lambda \in R^{K \times K}$ را تخمین زد. برای این منظور در هر تکرار مقدار کمینه‌ی تابع خطا (B) با استفاده از الگوریتم آدام پیدا می‌شود و مقدار λ با توجه به کمینه‌ی تابع بروز رسانی می‌شود. در هر تکرار با استفاده از الگوریتم QR نقاط بهینه‌ی که محدودیت را برآورده می‌سازند یافته می‌شوند. در آخر با استفاده از الگوریتم K-means بر روی سطرهای ماتریس U خوشه‌ها جداسازی می‌شوند.

Algorithm 1 Optimization Algorithm

```

1: Input:  $L, c, \alpha, \beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$ 
2: Output:  $U$ 
3:
4:  $\lambda \leftarrow 0 \in R^{k \times k}$ 
5:  $U \leftarrow N(0, \sigma^2) \in R^{N \times k}$ 
6: while  $\lambda$  Converge do
7:    $t \leftarrow 0$ 
8:    $m_t \leftarrow 0$ 
9:    $v_t \leftarrow 0$ 
10:  while  $U$  Converge do
11:     $t \leftarrow t + 1$ 
12:     $g_t \leftarrow \nabla_U B$  from (7)
13:     $m_t \leftarrow \beta_1 m_t + (1 - \beta_1) g_t$ 
14:     $v_t \leftarrow \beta_2 v_t + (1 - \beta_2) g_t \otimes g_t$ 
15:     $m' = \frac{m_t}{1 - \beta_1}$ 
16:     $v' = \frac{v_t}{1 - \beta_2}$ 
17:     $U \leftarrow U - \alpha m' \otimes (\sqrt{v'} + \epsilon)$ 
18:   $\lambda \leftarrow \lambda + c (U^T U - I_{k \times k})$ 
19:   $c \leftarrow \mu c$ 
20:   $U \leftarrow QR(U)$ 
21: Apply K-means algorithm

```

\otimes is element wise product
 \otimes is element wise division
 $\mu \geq 1$ is constant

جمع بندی

- این پروژه یک روش نوین جهت حل مساله‌ی خوشه‌بندی طیفی ارائه داد که در آن از الگوریتم لاگرانژ افزوده‌شده به همراه روش بهینه‌سازی آدام استفاده شده است. ما با استفاده از آنالیزهای تئوری و همچنین شبیه‌سازی بر روی دیتاست‌های واقعی و مصنوعی کارایی روش خود را به اثبات رساندیم. شبیه‌سازی‌ها بر روی داده‌های واقعی نشان داد که روش ارائه شده از چهار روش دیگر عملکرد بهتری دارد و می‌تواند جایگزین الگوریتم‌های موجود در این حوزه شود.
- در ادامه‌ی این پروژه پژوهش‌های دیگری قابل انجام است. یکی از پژوهش‌ها پیاده‌سازی بهینه‌ی این روش بر روی GPU ها است که باعث سریعتر شدن الگوریتم فوق می‌شود. همچنین این روش می‌تواند جایگزین الگوریتم‌های دوستیابی در شبکه‌های اجتماعی شود.

مراجع اصلی

- El Gheche, Mireille, Giovanni Chierchia, and Pascal Frossard. "Stochastic Gradient Descent for Spectral Embedding with Implicit Orthogonality Constraint." *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2019.
- Han, Yufei, and Maurizio Filippone. "Mini-batch spectral clustering." *2017 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2017.
- Li, Zhihui, et al. "Rank-constrained spectral clustering with flexible embedding." *IEEE transactions on neural networks and learning systems*, 2018