

ОБ ОДНОЙ ЗАДАЧЕ КЛАСТЕРИЗАЦИИ НА ГРАФЕ

Ильев В.П., Ильева С.Д.

Омский государственный университет

Задачи кластеризации

В *задаче кластеризации* требуется разбить заданное множество объектов на несколько подмножеств (*кластеров*) на основе сходства объектов друг с другом.

Мера сходства определяется по-разному в разных задачах.

В теории распознавания образов и в машинном обучении задачи кластеризации относят к разделу *обучения без учителя*.

Наряду с этим рассматриваются также *задачи кластеризации с частичным обучением*, в которых часть объектов изначально распределена по кластерам.

Задача кластеризации на графе (задача аппроксимации графа)

Одна из наглядных формализаций задачи кластеризации взаимосвязанных объектов — *задача кластеризации на графике* (или *задача аппроксимации графа*):

- вершины графа соответствуют объектам;
- пары вершин, соответствующие похожим объектам, связаны посредством ребер.

Требуется разбить множество вершин на попарно непересекающиеся группы (кластеры) с учетом реберной структуры графа.

Цель — минимизация числа связей между кластерами и числа недостающих связей внутри кластеров.

Определения и обозначения

Обыкновенный граф называется *клластерным графом*, если каждая его компонента связности является полным графом.

- $\mathcal{M}(V)$ – множество всех кластерных графов на множестве вершин V ,
- $\mathcal{M}_k(V)$ – множество всех кластерных графов на множестве V , имеющих ровно k непустых компонент связности, $2 \leq k \leq |V|$,
- $\mathcal{M}_{1,k}(V)$ – множество всех кластерных графов на множестве V , имеющих не более k компонент связности, $2 \leq k \leq |V|$.

Расстояние между графами $G_1 = (V, E_1)$, $G_2 = (V, E_2)$:

$$\rho(G_1, G_2) = |E_1 \Delta E_2| = |E_1 \setminus E_2| + |E_2 \setminus E_1|.$$

Постановки задач

Задача А. Дан граф $G = (V, E)$. Найти такой граф $M^* \in \mathcal{M}(V)$, что

$$\rho(G, M^*) = \min_{M \in \mathcal{M}(V)} \rho(G, M)$$


Задача А_k. Дан граф $G = (V, E)$ и целое число k , $2 \leq k \leq |V|$. Найти такой граф $M^* \in \mathcal{M}_k(V)$, что

$$\rho(G, M^*) = \min_{M \in \mathcal{M}_k(V)} \rho(G, M)$$


Задача А_{1,k}. Дан граф $G = (V, E)$ и целое число k , $2 \leq k \leq |V|$. Найти такой граф $M^* \in \mathcal{M}_{1,k}(V)$, что

$$\rho(G, M^*) = \min_{M \in \mathcal{M}_{1,k}(V)} \rho(G, M)$$

Пример. Задачи A, A₂, A_{1,2}



G



M^*

Другие названия

- Задача аппроксимации графов

[Zahn C.T. *Approximating symmetric relations by equivalence relations* // J. of the Society for Industrial and Applied Mathematics. 1964. V. 12. P. 840–847.]

- Correlation Clustering

[Bansal N., Blum A., Chawla S. *Correlation Clustering* // Machine Learning. 2004. V. 56. P. 89–113.]

- Cluster Editing

[Shamir R., Sharan R., Tsur D., *Cluster graph modification problems* // Discrete Appl. Math. 2004. V. 144. P. 173–182.]

Точные алгоритмы

- Задача **A** полиномиально разрешима для графов специального вида [Zahn, 1964]
- Задача **A** для графов без треугольников сведена к задаче о наибольшем паросочетании [Фридман, 1971]
- Точный алгоритм решения задачи **A** для графов, не содержащих четырехвершинных подграфов ровно с пятью ребрами [Вейнер, 1971]

Вычислительная сложность

- Задача \mathbf{A} NP -трудна
[Křivánek-Morávek, 1986; Bansal-Blum-Chawla, 2004;
Shamir-Sharan-Tsur, 2004]
- Задача \mathbf{A}_k NP -трудна при любом фиксированном $k \geq 2$
[Shamir-Sharan-Tsur, 2004; Giotis-Guruswami, 2006]
- Задачи $\mathbf{A}_{1,2}$ и \mathbf{A}_2 NP -трудны на кубических графах.
Отсюда выводится, что все варианты задач являются NP -трудными, включая $\mathbf{A}_{1,k}$ при любом фиксированном $k \geq 2$
[Агеев-Ильев-Кононов-Талевнин, 2006]

Алгоритмы приближенного решения

- 3-приближенный алгоритм для задачи $A_{1,2}$
[Bansal-Blum-Chawla, 2004]
- 4-приближенный алгоритм для задачи A
[Charikar-Guruswami-Wirth, 2005]
- Рандомизированная ППС для задачи $A_{1,k}$ при любом
фиксированном $k \geq 2$ [Giotis-Guruswami, 2006]
- 2-приближенный алгоритм для задачи $A_{1,2}$
[Coleman-Saunderson-Wirth, 2008]
- 2,5-приближенный алгоритм для задачи A
[Ailon-Charikar-Newman, 2008]
- 3-приближенный алгоритм для задачи A_2
[Ильев-Ильева-Навроцкая, 2011]

Задача кластеризации с частичным обучением

Задача A_k^+ . Дан граф $G = (V, E)$ и целое число k , $2 \leq k \leq |V|$. Выделено множество попарно различных вершин $X = \{x_1, \dots, x_k\} \subseteq V$. Найти такой граф $M^* \in \mathcal{M}_k(V)$, что

$$\rho(G, M^*) = \min_{M \in \mathcal{M}_k(V)} \rho(G, M),$$

где минимум берется по всем кластерным графикам $M \in \mathcal{M}_k(V)$, в которых никакие две вершины множества $X = \{x_1, \dots, x_k\}$ не принадлежат одному и тому же кластеру (т. е. множеству вершин одной компоненты связности графа M).

- Задача A_k^+ NP -трудна при любом фиксированном $k \geq 2$.

Приближенный алгоритм для A₂⁺

Задача A₂⁺. Дан граф $G = (V, E)$ и множество $X = \{x_1, x_2\}$, где $x_1, x_2 \in V$, $x_1 \neq x_2$. Найти такой граф $M^* \in \mathcal{M}_2(V)$, что

$$\rho(G, M^*) = \min_{M \in \mathcal{M}_2(V)} \rho(G, M),$$

причем минимум берется по всем кластерным графикам $M \in \mathcal{M}_2(V)$, таким, что $x_1 \in V_1$, $x_2 \in V_2$, где V_1, V_2 – кластеры (множества вершин компонент связности графа M).

Процедура построения кластерного графа.

Пусть v – произвольная вершина графа G , $N(v)$ – множество вершин графа G , смежных с v . Построим кластерный граф $M_v = M(V_1, V_2) \in \mathcal{M}_2(V)$ по следующим правилам.

Правила построения графа $M_v = M(V_1, V_2) \in \mathcal{M}_2(V)$



(а) Если в графе G вершина v смежна ровно с одной из вершин x_1, x_2 , то $V_1 = \{v\} \cup N(v)$, $V_2 = V \setminus V_1$.

(б) Если в графе G вершина v смежна с обеими вершинами x_1, x_2 , то

$$M' = M(V'_1, V'_2), \text{ где } V'_1 = (\{v\} \cup N(v)) \setminus \{x_2\}, V'_2 = V \setminus V'_1,$$
$$M'' = M(V''_1, V''_2), \text{ где } V''_1 = (\{v\} \cup N(v)) \setminus \{x_1\}, V''_2 = V \setminus V''_1.$$

Если при этом $\rho(G, M') \leq \rho(G, M'')$, то $M_v = M'$, в противном случае $M_v = M''$.



Пример. Правило (б)



$$\rho(G, M') = 5$$

$$\rho(G, M'') = 3$$

Пример. Правило (в)



$$\rho(G, M') = 5$$

$$\rho(G, M'') = 3$$

Правила построения графа $M_v = M(V_1, V_2) \in \mathcal{M}_2(V)$

(в) Если в графе G вершина v несмежна с обеими вершинами x_1, x_2 , то

$$M' = M(V'_1, V'_2), \text{ где } V'_1 = \{v\} \cup N(v) \cup \{x_1\}, V'_2 = V \setminus V'_1,$$
$$M'' = M(V''_1, V''_2), \text{ где } V''_1 = \{v\} \cup N(v) \cup \{x_2\}, V''_2 = V \setminus V''_1.$$

Если при этом $\rho(G, M') \leq \rho(G, M'')$, то $M_v = M'$, в противном случае $M_v = M''$.

(г) Если вершина v совпадает с одной из вершин x_1, x_2 , то
 $V_1 = (\{v\} \cup N(v)) \setminus \{x\}$, $V_2 = V \setminus V_1$,

где $x = x_1$, если $v = x_2$, и $x = x_2$, если $v = x_1$.

Приближенный алгоритм

Рассмотрим следующий алгоритм приближенного решения задачи A_2^+ .

Алгоритм ALG_2^+

Шаг 1. Для каждой вершины $v \in V$ построить кластерный граф $M_v \in \mathcal{M}_2(V)$ по правилам (а)–(г).

Шаг 2. Среди всех графов M_v выбрать такой граф M_2^+ , что

$$\rho(G, M_2^+) = \min_{v \in V} \rho(G, M_v).$$

Конец алгоритма.

Гарантированная оценка точности алгоритма ALG_2^+

Теорема 2. При $n \geq 3$ для любого n -вершинного графа $G = (V, E)$ и любого множества $X = \{x_1, x_2\} \subset V$ ($x_1 \neq x_2$) алгоритм ALG_2^+ находит такой кластерный граф $M_2^+ \in \mathcal{M}_2(V)$, что

$$\rho(G, M_2^+) \leq \left(3 - \frac{6}{n}\right) \rho(G, M^*),$$

где $M^* \in \mathcal{M}_2(V)$ – оптимальное решение задачи \mathbf{A}_2^+ на графике G .