

ПРИКЛАДНАЯ ТЕОРИЯ ГРАФОВ

УДК 519.1

ОБ ОДНОЙ ЗАДАЧЕ КЛАСТЕРИЗАЦИИ ГРАФА
С ЧАСТИЧНЫМ ОБУЧЕНИЕМ¹А. В. Ильев^{*,**}, В. П. Ильев^{*,***}

^{*} Омский государственный технический университет, г. Омск, Россия,

^{**} Институт математики им. С. Л. Соболева СО РАН, г. Омск, Россия,

^{***} Омский государственный университет им. Ф. М. Достоевского, г. Омск, Россия

В задачах кластеризации требуется разбить данное множество объектов на несколько подмножеств (кластеров) только на основе сходства объектов друг с другом. Рассматривается вариант задачи кластеризации графа, являющийся одной из формализаций задачи кластеризации с частичным обучением. Доказано, что эта задача является NP-трудной. Для одного варианта задачи предложен полиномиальный 3-приближённый алгоритм.

Ключевые слова: граф, кластер, кластеризация с частичным обучением.

DOI 10.17223/20710410/42/5

ON A SEMI-SUPERVISED GRAPH CLUSTERING PROBLEM

A. V. Il'ev^{*,**}, V. P. Il'ev^{*,***}

^{*} Omsk State Technical University, Omsk, Russia

^{**} Sobolev Institute of Mathematics SB RAS, Omsk, Russia

^{***} Dostoevsky Omsk State University, Omsk, Russia

E-mail: artyom_iljev@mail.ru, iljev@mail.ru

In the clustering problems one has to partition a given set of objects into some subsets (called clusters) taking into consideration only similarity of the objects. In this paper we study a version of the graph correlation clustering that can be considered as a formalization of the semi-supervised clustering. We prove that the problem under consideration is NP-hard and propose a polynomial-time 3-approximation algorithm for a version of the problem.

Keywords: graph, cluster, semi-supervised clustering.

Введение

Важный раздел теории распознавания образов и машинного обучения составляют методы решения задач кластеризации [1]. В задаче кластеризации требуется разбить данное множество объектов на несколько подмножеств (кластеров) только на основе сходства объектов друг с другом. Одной из наиболее наглядных формализаций

¹Работа поддержана грантом РФФ №17-11-01117.

задач кластеризации является *задача кластеризации графа* [2, 3]. В ней отношение сходства объектов задаётся посредством неориентированного графа, вершины которого взаимно однозначно соответствуют объектам, а рёбра соединяют похожие объекты, обладающие достаточным количеством одинаковых признаков. Требуется разбить множество исходных объектов на попарно непересекающиеся группы (кластеры) так, чтобы минимизировать число рёбер между кластерами и число недостающих рёбер внутри кластеров. Количество кластеров может быть задано, ограничено или заранее не определено.

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 (как правило, небольшая) изначально распределена по кластерам [4, 5]. Задачи кластеризации графов имеют многочисленные приложения. Задачи кластеризации графов с частичным обучением тесно связаны с исследованием систем уравнений над графами [6].

В п. 1 настоящей работы рассматриваются три варианта задачи кластеризации графа, приводится краткий обзор известных результатов. В п. 2 рассматривается постановка задачи кластеризации графа, которая является одной из формализаций задачи кластеризации с частичным обучением. В этой задаче дано множество, состоящее из n объектов, которые необходимо распределить по k кластерам, $k < n$. Среди заданных объектов выделены k объектов, никакие два из которых не должны принадлежать одному и тому же кластеру. Отношение сходства объектов задано с помощью неориентированного графа. В работе доказано, что рассматриваемая задача является NP-трудной. Для случая $k = 2$ предложен полиномиальный 3-приближённый алгоритм.

1. Задачи кластеризации графов

1.1. Постановки задач

Будут рассматриваться только *обыкновенные* графы, т. е. графы без петель и кратных рёбер. Обыкновенный граф называется *кластерным*, если каждая его компонента связности является полным графом [7].

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

Если $G_1 = (V, E_1)$ и $G_2 = (V, E_2)$ — обыкновенные графы на одном и том же множестве вершин V , то *расстояние* $\rho(G_1, G_2)$ между ними определяется как

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

т. е. $\rho(G_1, G_2)$ — число несовпадающих рёбер в графах G_1 и G_2 .

В 60–80-е годы XX века в литературе изучались следующие три варианта задачи кластеризации графа, которые в то время принято было называть *задачами аппроксимации графов*. Постановки и различные интерпретации задач аппроксимации графов можно найти в [8–11]. В дальнейшем задачи аппроксимации графов неоднократно переоткрывались и независимо изучались под разными названиями (Correlation Clustering [12], Cluster Editing [7, 13] и др.).

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

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

Рассматривались также варианты задач кластеризации графов, в которых ограничения накладываются на размеры кластеров [14].

1.2. Вычислительная сложность и приближённые алгоритмы

В 1986 г. М. Крживанек и Дж. Моравек показали [15], что задача \mathbf{GC} является NP-трудной, однако их работа осталась незамеченной. В 2004 г. в [7, 12] доказана NP-трудность задачи \mathbf{GC} . В [7] доказано также, что задача \mathbf{GC}_k NP-трудна при любом фиксированном $k \geq 2$; в [16] приведено более простое доказательство этого же результата. В [17] доказано, что задачи \mathbf{GC}_2 и $\mathbf{GC}_{1,2}$ NP-трудны уже на кубических графах, откуда следует, что все упомянутые ранее варианты задачи кластеризации графа являются NP-трудными, включая и задачу $\mathbf{GC}_{1,k}$.

В 2004 г. в [12] предложен полиномиальный 3-приближённый алгоритм для задачи $\mathbf{GC}_{1,2}$. В 2006 г. в [17] доказано существование рандомизированной полиномиальной приближённой схемы для задачи $\mathbf{GC}_{1,2}$, а в [16] предложена рандомизированная полиномиальная приближённую схему для задачи \mathbf{GC}_k (для любого фиксированного $k \geq 2$). Указав, что сложность полиномиальной приближённой схемы из [16] лишает её перспективы практического использования, авторы [18] предложили 2-приближённый алгоритм для задачи $\mathbf{GC}_{1,2}$, применив процедуру локального поиска к допустимому решению, полученному с помощью 3-приближённого алгоритма из [12]. Для задачи \mathbf{GC}_2 в работе [19] предложен $(3 - 6/n)$ -приближённый алгоритм с достижимой гарантированной оценкой точности. В 2005 г. авторы [20] показали, что задача \mathbf{GC} является APX-трудной и разработали для неё 4-приближённый алгоритм. В 2008 г. в [21] предложен 2,5-приближённый алгоритм для задачи \mathbf{GC} .

Более подробный обзор результатов, относящихся к задачам \mathbf{GC} , \mathbf{GC}_k , $\mathbf{GC}_{1,k}$ и их взвешенным вариантам, можно найти в [22].

2. Задача кластеризации с частичным обучением

2.1. Вычислительная сложность

Рассмотрим задачу кластеризации графа с частичным обучением, самая общая постановка которой такова.

Дан обыкновенный n -вершинный граф $G = (V, E)$ и целое число k , $2 \leq k \leq n$. Выделено множество попарно различных вершин $X = \{x_1, \dots, x_k\} \subset V$, на котором задано бинарное симметричное иррефлексивное отношение P . Требуется найти ближайший к G граф $M^* \in \mathcal{M}(V)$, такой, что никакие две вершины множества X , связанные

отношением P , не принадлежат одной и той же компоненте связности (т. е. одному кластеру) графа M^* .

Более подробно изучим следующий вариант задачи кластеризации графа с частичным обучением.

Задача \mathbf{SGC}_k . Дан обыкновенный n -вершинный граф $G = (V, E)$ и целое число k , $2 \leq k \leq n$. Выделено множество попарно различных вершин $X = \{x_1, \dots, x_k\} \subset V$. Требуется найти такой граф $M^* \in \mathcal{M}_k(V)$, что

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

причём минимум берётся по всем кластерным графам $M = (V, E_M) \in \mathcal{M}_k(V)$, в которых $x_i, x_j \notin E_M$ для любых $i, j \in \{1, \dots, k\}$; другими словами, никакие две вершины множества $X = \{x_1, \dots, x_k\}$ не принадлежат одной и той же компоненте связности (т. е. одному кластеру) графа M .

Несложно свести по Тьюрингу задачу \mathbf{GC}_k к \mathbf{SGC}_k и тем самым показать, что задача \mathbf{SGC}_k NP-трудна. Действительно, рассмотрим произвольный граф $G = (V, E)$ — вход задачи \mathbf{GC}_k — и фиксируем целое число k и произвольный набор $\{x_1, \dots, x_k\}$, состоящий из k попарно различных вершин графа G . Имея оптимальное решение $M(x_1, \dots, x_k)$ задачи \mathbf{SGC}_k для любого такого набора $\{x_1, \dots, x_k\} \subset V$ и выбрав среди них ближайший к графу G кластерный граф

$$M^*(x_1, \dots, x_k) = \arg \min_{\{x_1, \dots, x_k\} \subset V} \rho(G, M(x_1, \dots, x_k)),$$

мы, очевидно, получим оптимальное решение исходной задачи \mathbf{GC}_k . Легко видеть, что при фиксированном k построение всех C_n^k входов задачи \mathbf{SGC}_k и получение оптимального решения исходной задачи \mathbf{GC}_k можно выполнить за время $O(n^k)$, где $n = |V|$. Таким образом, справедлива следующая теорема.

Теорема 1. Задача \mathbf{SGC}_k NP-трудна при любом фиксированном $k \geq 2$.

2.2. Задача \mathbf{SGC}_2

Рассмотрим частный случай задачи \mathbf{SGC}_k , когда $k = 2$.

Пусть $G_1 = (V, E_1)$ и $G_2 = (V, E_2)$ — n -вершинные графы на одном и том же множестве вершин V . Обозначим через $D(G_1, G_2)$ граф на множестве вершин V с множеством рёбер $E_1 \Delta E_2$. Через $d_D(u)$ обозначим степень вершины u в графе $D = D(G_1, G_2)$.

Нетрудно заметить, что $\rho(G_1, G_2)$ равно числу рёбер в графе D , которое по лемме о рукопожатиях равно половине суммы степеней вершин графа D . Отсюда получаем следующее утверждение.

Лемма 1 [19]. Пусть $d_{\min} = \min_{u \in V} d_D(u)$ — минимум степеней вершин в графе $D = D(G_1, G_2)$. Тогда

$$\rho(G_1, G_2) \geq \frac{nd_{\min}}{2}.$$

Введём следующие обозначения. Для произвольного графа $G = (V, E)$ и $u \in V$ обозначим $N_G(u) = \{v \in V : uv \in E\}$, $\overline{N}_G(u) = V \setminus (N_G(u) \cup \{u\})$. Таким образом, $|N_G(u)| = d_G(u)$ — степень вершины u в графе G .

Для множеств $V_1, V_2 \subseteq V$, таких, что $V_1 \cap V_2 = \emptyset$ и $V_1 \cup V_2 = V$, обозначим через $M(V_1, V_2)$ кластерный граф из класса $\mathcal{M}_2(V)$ с компонентами связности, порождёнными множествами V_1, V_2 . Нам понадобится следующая простая лемма.

Лемма 2. Пусть $G = (V, E)$ — n -вершинный граф, $u \in V$ — произвольная вершина, $M, M' \in \mathcal{M}_2(V)$ — кластерные графы на множестве V , такие, что M' получен из M путём переноса вершины u в другую компоненту связности. Тогда

$$\rho(G, M') - \rho(G, M) \leq n - 1.$$

Доказательство. Пусть $M = M(V_1, V_2)$, где V_1 — множество, содержащее вершину u . Тогда $M' = M(V_1 \setminus \{u\}, V_2 \cup \{u\})$. Заметим, что графы $D = D(G, M)$ и $D' = D(G, M')$ отличаются только рёбрами вида uv , $v \in V \setminus \{u\}$, а именно: u, v смежны в D тогда и только тогда, когда они не смежны в D' . Остальные рёбра графов D и D' совпадают. Следовательно,

$$\rho(G, M') - \rho(G, M) = |N_{D'}(u)| - |N_D(u)| = d_{D'}(u) - d_D(u).$$

Очевидно, $d_D(u) \geq 0$, $d_{D'}(u) \leq n - 1$, поэтому

$$\rho(G, M') - \rho(G, M) = d_{D'}(u) - d_D(u) \leq n - 1,$$

что и требовалось. ■

2.3. Приближённый алгоритм для задачи \mathbf{SGC}_2

Пусть $x_1, x_2 \in V$ — фиксированные вершины графа $G = (V, E)$, $x_1 \neq x_2$, $v \in V$ — произвольная вершина в G . Построим граф $M_v \in \mathcal{M}_2(V)$ по следующим правилам:

- (а) Если в графе G вершина v смежна ровно с одной из вершин x_1, x_2 и не совпадает с другой, то полагаем $M_v = M(V_1, V_2)$, где $V_1 = \{v\} \cup N_G(v)$, $V_2 = V \setminus V_1$.
- (б) Если в графе G вершина v смежна с обеими вершинами x_1, x_2 , то полагаем $M'_v = M(V'_1, V'_2)$. Здесь $V'_1 = (\{v\} \cup N_G(v)) \setminus \{x_2\}$, $V'_2 = V \setminus V'_1$, $M''_v = M(V''_1, V''_2)$, где $V''_1 = (\{v\} \cup N_G(v)) \setminus \{x_1\}$, $V''_2 = V \setminus V''_1$. Если при этом $\rho(G, M'_v) \leq \rho(G, M''_v)$, то полагаем $M_v = M'_v$, в противном случае $M_v = M''_v$.
- (в) Если в графе G вершина v не смежна и не совпадает ни с одной из вершин x_1, x_2 , то полагаем $M'_v = M(V'_1, V'_2)$. Здесь $V'_1 = \{v\} \cup N_G(v) \cup \{x_1\}$, $V'_2 = V \setminus V'_1$, $M''_v = M(V''_1, V''_2)$, где $V''_1 = \{v\} \cup N_G(v) \cup \{x_2\}$, $V''_2 = V \setminus V''_1$. Если при этом $\rho(G, M'_v) \leq \rho(G, M''_v)$, то полагаем $M_v = M'_v$, в противном случае $M_v = M''_v$.
- (г) Если вершина v совпадает с одной из вершин x_1, x_2 , то полагаем $M_v = M(V_1, V_2)$ для $V_1 = (\{v\} \cup N_G(v)) \setminus \{x\}$, $V_2 = V \setminus V_1$, где $x = x_1$, если $v = x_2$, и $x = x_2$, если $v = x_1$.

Очевидно, что построенный по этим правилам кластерный граф M_v является допустимым решением задачи \mathbf{SGC}_2 для графа G .

Лемма 3. Пусть $M^* \in \mathcal{M}_2(V)$ — оптимальное решение задачи \mathbf{SGC}_2 на графе $G = (V, E)$, $D = D(G, M^*)$, $v \in V$ — вершина минимальной степени в графе D : $d_D(v) = \min_{u \in V} d_D(u) = d_{\min}$. Тогда

$$\rho(G, M_v) \leq \rho(G, M^*) + d_{\min}(n - 1), \quad (1)$$

где $M_v = M(V_1, V_2)$ — кластерный граф, построенный по правилам (а)–(г).

Доказательство. Пусть $M^* = M(V_1^*, V_2^*)$, где V_1^* — множество, содержащее вершину v . Тогда из определения графа D вытекает, что

$$V_1^* = \{v\} \cup \left(N_G(v) \setminus N_D(v) \right) \cup \left(\overline{N_G(v)} \cap N_D(v) \right). \quad (2)$$

С л у ч а й 1. Пусть в графе $G = (V, E)$ вершина v смежна ровно с одной из вершин x_1, x_2 и не совпадает с другой. Покажем, что граф M_v , построенный по правилу (а), может быть получен из графа M^* путем переноса d_{\min} вершин в другую компоненту. Для этого достаточно оценить, как сильно отличаются множества V_1 и V_1^* . По построению графа M_v имеем

$$V_1 = \{v\} \cup N_G(v) = \{v\} \cup \left(N_G(v) \setminus N_D(v) \right) \cup \left(N_G(v) \cap N_D(v) \right).$$

Учитывая (2), получаем

$$V_1^* \Delta V_1 = (V_1^* \setminus V_1) \cup (V_1 \setminus V_1^*) = \left(\overline{N_G}(v) \cap N_D(v) \right) \cup \left(N_G(v) \cap N_D(v) \right) = N_D(v).$$

Таким образом, $|V_1^* \Delta V_1| = |N_D(v)| = d_D(v) = d_{\min}$, поэтому граф M_v может быть получен из графа M^* путём переноса d_{\min} вершин множества $N_D(v)$ в другую компоненту связности.

Нетрудно заметить, что если в графе M^* последовательно переносить все вершины множества $N_D(v)$ в другую компоненту, то после каждого переноса для вновь получаемых кластерных графов будут выполнены условия леммы 2. Так как граф M_v получен из графа M^* путём переноса d_{\min} вершин множества $N_D(v)$ в другую компоненту, то, применяя d_{\min} раз лемму 2, получаем $\rho(G, M_v) - \rho(G, M^*) \leq d_{\min}(n - 1)$, т. е. $\rho(G, M_v) \leq \rho(G, M^*) + d_{\min}(n - 1)$. Итак, неравенство (1) выполнено.

С л у ч а й 2. Пусть в графе $G = (V, E)$ вершина v смежна с обеими вершинами x_1, x_2 , т. е. $x_1, x_2 \in N_G(v)$. В этом случае граф M_v строится по правилу (б). Так как вершины x_1 и x_2 находятся в разных компонентах связности графа M^* и $x_1, x_2 \in N_G(v)$, то $d_{\min} \geq 1$. Покажем, что один из графов M'_v, M''_v может быть получен из графа M^* путём переноса $d_{\min} - 1$ вершин в другую компоненту связности.

Рассмотрим случай, когда $x_1 \in V_1^*$ (следовательно, $x_2 \in V_2^*$). Докажем, что в этом случае граф M'_v может быть получен из графа M^* путём переноса $d_{\min} - 1$ вершин в другую компоненту связности. По построению графа M'_v справедливо

$$V'_1 = \left(\{v\} \cup N_G(v) \right) \setminus \{x_2\} = \left(\{v\} \cup \left(N_G(v) \setminus N_D(v) \right) \cup \left(N_G(v) \cap N_D(v) \right) \right) \setminus \{x_2\}.$$

В силу (2), учитывая, что $x_2 \in N_G(v) \cap N_D(v)$, получаем

$$V_1^* \Delta V'_1 = \left(\left(\overline{N_G}(v) \cap N_D(v) \right) \cup \left(N_G(v) \cap N_D(v) \right) \right) \setminus \{x_2\} = N_D(v) \setminus \{x_2\},$$

т. е. $|V_1^* \Delta V'_1| = |N_D(v)| - 1 = d_{\min} - 1$, поэтому граф M'_v может быть получен из графа M^* путём переноса $d_{\min} - 1$ вершин множества $N_D(v) \setminus \{x_2\}$ в другую компоненту связности.

Применяя $d_{\min} - 1$ раз лемму 2, получаем $\rho(G, M'_v) - \rho(G, M^*) \leq (d_{\min} - 1)(n - 1)$, т. е. $\rho(G, M'_v) \leq \rho(G, M^*) + (d_{\min} - 1)(n - 1)$.

В случае $x_2 \in V_1^*$ (значит, $x_1 \in V_2^*$) с помощью аналогичных рассуждений доказывается неравенство $\rho(G, M''_v) \leq \rho(G, M^*) + (d_{\min} - 1)(n - 1)$. Таким образом,

$$\begin{aligned} \rho(G, M_v) &= \min \left(\rho(G, M'_v), \rho(G, M''_v) \right) \leq \rho(G, M^*) + (d_{\min} - 1)(n - 1) < \\ &< \rho(G, M^*) + d_{\min}(n - 1), \end{aligned}$$

т. е. неравенство (1) выполнено.

С л у ч а й 3. Пусть в графе $G = (V, E)$ вершина v не смежна и не совпадает ни с одной из вершин x_1, x_2 , т.е. $x_1, x_2 \in \overline{N_G(v)}$. В этом случае граф M_v строится по правилу (в). Так как вершины x_1 и x_2 находятся в разных компонентах связности графа M^* и $x_1, x_2 \in \overline{N_G(v)}$, то $d_{\min} \geq 1$. Покажем, что один из графов M'_v, M''_v может быть получен из графа M^* путём переноса $d_{\min} - 1$ вершин в другую компоненту связности.

Рассмотрим случай, когда $x_1 \in V_1^*$ (следовательно, $x_2 \in V_2^*$). Докажем, что в этом случае граф M'_v может быть получен из графа M^* путем переноса $d_{\min} - 1$ вершин в другую компоненту связности. По построению графа M'_v ,

$$V'_1 = \{v\} \cup N_G(v) \cup \{x_1\} = \{v\} \cup \left(N_G(v) \setminus N_D(v) \right) \cup \left(N_G(v) \cap N_D(v) \right) \cup \{x_1\}.$$

В силу (2), учитывая, что $x_1 \in \overline{N_G(v)} \cap N_D(v)$, получаем

$$V_1^* \Delta V'_1 = \left(\left(\overline{N_G(v)} \cap N_D(v) \right) \setminus \{x_1\} \right) \cup \left(N_G(v) \cap N_D(v) \right) = N_D(v) \setminus \{x_1\},$$

т.е. $|V_1^* \Delta V'_1| = |N_D(v)| - 1 = d_{\min} - 1$, поэтому граф M'_v может быть получен из графа M^* путём переноса $d_{\min} - 1$ вершин множества $N_D(v) \setminus \{x_1\}$ в другую компоненту. Рассуждая, как в случае 2, получаем $\rho(G, M'_v) \leq \rho(G, M^*) + (d_{\min} - 1)(n - 1)$.

В случае $x_2 \in V_1^*$ (значит, $x_1 \in V_2^*$) аналогично доказывается неравенство $\rho(G, M''_v) \leq \rho(G, M^*) + (d_{\min} - 1)(n - 1)$. Таким образом,

$$\rho(G, M_v) = \min \left(\rho(G, M'_v), \rho(G, M''_v) \right) < \rho(G, M^*) + d_{\min}(n - 1),$$

что и требовалось доказать.

С л у ч а й 4. Пусть в графе $G = (V, E)$ вершина v совпадает с одной из вершин x_1, x_2 . В этом случае граф M_v строится по правилу (г). Без ограничения общности будем считать, что $v = x_1$. Тогда $V_1 = \left(\{v\} \cup N_G(v) \right) \setminus \{x_2\}$. Если $x_2 \notin N_G(v)$, то $V_1 = \{v\} \cup N_G(v)$ и неравенство (1) доказывается, как в случае 1, а если $x_2 \in N_G(v)$, то как в случае 2.

Итак, в каждом из четырёх случаев справедливо неравенство (1). ■

Рассмотрим следующий алгоритм приближённого решения задачи **SGC₂**.

Алгоритм 1. Приближённое решение задачи **SGC₂**

- 1: Для каждой вершины $v \in V$ определить кластерный граф $M_v \in \mathcal{M}_2(V)$ по правилам (а)–(г).
 - 2: Среди всех графов M_v выбрать такой граф M , что $\rho(G, M) = \min_{v \in V} \rho(G, M_v)$.
-

Вычислительная сложность алгоритма 1 может быть оценена как $O(n^3)$, где n — число вершин графа G .

Справедлива следующая гарантированная оценка точности алгоритма 1.

Теорема 2. Для любого n -вершинного графа $G = (V, E)$ и любого множества $X = \{x_1, x_2\} \subset V$ ($x_1 \neq x_2$) алгоритм 1 находит такой кластерный граф $M \in \mathcal{M}_2(V)$ — допустимое решение задачи **SGC₂**, что

$$\rho(G, M) \leq \left(3 - \frac{2}{n} \right) \rho(G, M^*),$$

где $M^* \in \mathcal{M}_2(V)$ — оптимальное решение задачи **SGC₂** на графе G .

Доказательство. Очевидно, среди всех вершин на шаге 1 будет выбрана такая вершина $v \in V$, что $d_D(v) = d_{\min}$, поэтому $\rho(G, M) \leq \rho(G, M_v)$. Оценим величину $\rho(G, M_v)$ с учётом неравенства (1) и леммы 1:

$$\rho(G, M_v) \leq \rho(G, M^*) + d_{\min}(n-1) \leq \rho(G, M^*) + 2\rho(G, M^*) \left(1 - \frac{1}{n}\right) = \left(3 - \frac{2}{n}\right)\rho(G, M^*).$$

Отсюда получаем гарантированную оценку точности алгоритма 1:

$$\rho(G, M) \leq \rho(G, M_v) \leq \left(3 - \frac{2}{n}\right)\rho(G, M^*).$$

Теорема 2 доказана. ■

ЛИТЕРАТУРА

1. Журавлев Ю. И., Рязанов В. В., Сенько О. В. Распознавание. Математические методы. Программная система. Практические применения. М.: ФАЗИС, 2005.
2. Kulis B., Basu S., Dhillon I., and Mooney R. Semi-supervised graph clustering: a kernel approach // Mach. Learn. 2009. V. 74. No. 1. P. 1–22.
3. Schaeffer S. E. Graph clustering // Comput. Sci. Rev. 2005. V. 1. No. 1. P. 27–64.
4. Bair E. Semi-supervised clustering methods // Wiley Interdisciplinary Reviews: Computational Statistics. 2013. V. 5. No. 5. P. 349–361.
5. Chapelle O., Schölkopf B., and Zein A. Semi-supervised Learning. Cambridge, Massachusetts: MIT Press, 2006.
6. Ильев А. В., Ремесленников В. Н. Исследование совместности систем уравнений над графами и нахождение их общих решений // Вестник Омского университета. 2017. № 4(86). С. 26–32.
7. Shamir R., Sharan R., and Tsur D. Cluster graph modification problems // Discrete Appl. Math. 2004. V. 144. No. 1–2. P. 173–182.
8. Zahn C. T. Approximating symmetric relations by equivalence relations // J. Soc. Indust. Appl. Math. 1964. V. 12. No. 4. P. 840–847.
9. Tomescu I. La reduction minimale d'un graphe à une reunion de cliques // Discrete Math. 1974. V. 10. No. 1–2. P. 173–179.
10. Фридман Г. Ш. Исследование одной задачи классификации на графах // Методы моделирования и обработка информации. Новосибирск: Наука, 1976. С. 147–177.
11. Ильев В. П., Фридман Г. Ш. К задаче аппроксимации графами с фиксированным числом компонент // Докл. АН СССР. 1982. Т. 264. № 3. С. 533–538.
12. Bansal N., Blum A., and Chawla S. Correlation clustering // Mach. Learn. 2004. V. 56. No. 1–3. P. 89–113.
13. Ben-Dor A., Shamir R., and Yakhimi Z. Clustering gene expression patterns // J. Comput. Biol. 1999. V. 6. No. 3–4. P. 281–297.
14. Ильев В. П., Навроцкая А. А. Вычислительная сложность задачи аппроксимации графами с компонентами связности ограниченного размера // Прикладная дискретная математика. 2011. № 3(13). С. 80–84.
15. Křivánek M. and Morávek J. NP-hard problems in hierarchical-tree clustering // Acta Inform. 1986. V. 23. P. 311–323.
16. Giotis I. and Guruswami V. Correlation clustering with a fixed number of clusters // Theory Comput. 2006. V. 2. No. 1. P. 249–266.
17. Агеев А. А., Ильев В. П., Кононов А. В., Талевнин А. С. Вычислительная сложность задачи аппроксимации графов // Дискрет. анализ и исслед. операций. Сер. 1. 2006. Т. 13. № 1. С. 3–11.

18. *Coleman T., Saunderson J., and Wirth A.* A local-search 2-approximation for 2-correlation clustering // ESA 2008. LNCS. 2008. V. 5193. P. 308–319.
19. *Ильев В. П., Ильева С. Д., Навроцкая А. А.* Приближенные алгоритмы для задач аппроксимации графов // Дискрет. анализ и исслед. операций. 2011. Т. 18. № 1. С. 41–60.
20. *Charikar M., Guruswami V., and Wirth A.* Clustering with qualitative information // J. Comput. Syst. Sci. 2005. V. 71. No. 3. P. 360–383.
21. *Ailon N., Charikar M., and Newman A.* Aggregating inconsistent information: Ranking and clustering // J. ACM. 2008. V. 55. No. 5. P. 1–27.
22. *Ильев В., Ильева С., Кононов А.* Short survey on graph correlation clustering with minimization criteria // DOOR 2016. LNCS. 2016. V. 9869. P. 25–36.

REFERENCES

1. *Zhuravlev Yu. I., Ryazanov V. V., and Sen'ko O. V.* Raspoznavanie. Matematicheskie metody. Programmnaya sistema. Prakticheskie primeneniya [Recognition. Mathematical methods. Program system. Practical applications]. Moscow, FAZIS Publ., 2005. (in Russian)
2. *Kulis B., Basu S., Dhillon I., and Mooney R.* Semi-supervised graph clustering: a kernel approach. Mach. Learn., 2009, vol. 74, no. 1, pp. 1–2.
3. *Schaeffer S. E.* Graph clustering. Comput. Sci. Rev., 2005, vol. 1, no. 1, pp. 27–64.
4. *Bair E.* Semi-supervised clustering methods. Wiley Interdisciplinary Reviews: Computational Statistics. 2013, vol. 5, no. 5, pp. 349–361.
5. *Chapelle O., Schölkopf B., and Zein A.* Semi-supervised Learning. Cambridge, Massachusetts, MIT Press, 2006.
6. *Ильев А. В. and Ремесленников В. Н.* Исследование совместности систем уравнений над графами и нахождение их общих решений [Study of the compatibility of systems of equations over graphs and finding their general solutions]. Vestnik Omskogo Universiteta, 2017, no. 4(86), pp. 26–32. (in Russian)
7. *Shamir R., Sharan R., and Tsur D.* Cluster graph modification problems. Discrete Appl. Math., 2004, vol. 144, no. 1–2, pp. 173–182.
8. *Zahn C. T.* Approximating symmetric relations by equivalence relations. J. Soc. Indust. Appl. Math., 1964, vol. 12, no. 4, pp. 840–847.
9. *Tomescu I.* La reduction minimale d'un graphe à une reunion de cliques. Discrete Math., 1974, vol. 10, no. 1–2, pp. 173–179.
10. *Fridman G. Sh.* Исследование одной задачи классификации на графах [Investigation of a classifying problem on graphs]. In: Metody Modelirovaniya i Obrabotka Informatsii, Novosibirsk, Nauka Publ., 1976, pp. 147–177. (in Russian)
11. *Ильев В. П. and Fridman G. Sh.* On the problem of approximation by graphs with a fixed number of components. Sov. Math. Dokl., 1982, vol. 25, pp. 666–670.
12. *Bansal N., Blum A., and Chawla S.* Correlation clustering. Mach. Learn., 2004, vol. 56, no. 1–3, pp. 89–113.
13. *Ben-Dor A., Shamir R., and Yakhimi Z.* Clustering gene expression patterns. J. Comput. Biol., 1999, vol. 6, no. 3–4, pp. 281–297.
14. *Ильев В. П. and Навроцкая А. А.* Выхислительная сложность задачи аппроксимации графами с компонентами связности ограниченного размера [Computational complexity of the problem of approximation by graphs with connected components of bounded size]. Прикладная Дискретная Математика, 2011, no. 3(13), pp. 80–84. (in Russian)
15. *Křivánek M. and Morávek J.* NP-hard problems in hierarchical-tree clustering. Acta inform., 1986, vol. 23, pp. 311–323.

16. *Giotis I. and Guruswami V.* Correlation clustering with a fixed number of clusters. *Theory Comput.*, 2006, vol. 2, no. 1, pp. 249–266.
17. *Ageev A. A., Il'ev V. P., Kononov A. V., and Talevnin A. S.* Computational complexity of the graph approximation problem. *J. Appl. Indust. Math.*, 2007, vol. 1, no. 1, pp. 1–8.
18. *Coleman T., Saunderson J., and Wirth A.* A local-search 2-approximation for 2-correlation clustering. *ESA 2008, LNCS*, 2008, vol. 5193, pp. 308–319.
19. *Il'ev V. P., Il'eva S. D., and Navrotskaya A. A.* Approximation algorithms for graph approximation problems. *J. Appl. Indust. Math.*, 2011, vol. 5, no. 4, pp. 569–581.
20. *Charikar M., Guruswami V., and Wirth A.* Clustering with qualitative information. *J. Comput. Syst. Sci.*, 2005, vol. 71, no. 3, pp. 360–383.
21. *Ailon N., Charikar M., and Newman A.* Aggregating inconsistent information: Ranking and clustering. *J. ACM*, 2008, vol. 55, no. 5, pp. 1–27.
22. *Il'ev V., Il'eva S., and Kononov A.* Short survey on graph correlation clustering with minimization criteria. *DOOR 2016, LNCS*, 2016, vol. 9869, pp. 25–36.