

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ ОБРАЗОВАТЕЛЬНОЕ
УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«НОВОСИБИРСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ» (НОВОСИБИРСКИЙ ГОСУДАРСТВЕННЫЙ
УНИВЕРСИТЕТ, НГУ)

Факультет
Кафедра

Механико-математический факультет
Теоретической кибернетики

Направление подготовки Прикладная математика и информатика

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА БАКАЛАВРА

Смирнов Павел Владимирович

(Фамилия, Имя, Отчество автора)

Тема работы: Редукция данных для задачи о вершинном покрытии гиперграфа за линейное время с линейной памятью.

«К защите допущена»
Заведующий кафедрой,
д.ф.-м.н., проф.

Научный руководитель
Заведующий лабораторией
алгоритмики ММФ НГУ,
Dr.rer.nat.

Ерзин А.И. /
(фамилия , И., О.) / (подпись, МП)
«...».....20...г.

ван Беверн Р.А. /
(фамилия , И., О.) / (подпись, МП)
«...».....20...г.

Дата защиты: «...».....20...г.

Новосибирск, 2018

Содержание

1 Введение	3
2 Алгоритм Фафьяни и Кратча	6
3 Структура данных supersets[]	7
4 Линейная память	8
5 Алгоритм ван Беверна	11
6 Тестирование и сравнение алгоритмов	15
7 Заключение	17

Аннотация

Линейные алгоритмы кернелизации для задачи о вершинном покрытии d -гиперграфа были предложены ван Беверном в 2014 году и Фафьяни и Кратчем в 2015 году. Обоим алгоритмам нужна структура данных, способная обращаться к данным, ассоциированным с кортежем чисел, за константное время. Ван Беверн экспериментировал с разными структурами данных. Хеш-таблицы имеют константный доступ к данным в среднем, но линейный в худшем случае. Сбалансированные деревья поиска обеспечивают линейную память, но неконстантное обращение. Префиксные деревья предоставляют доступ к памяти за константное время, но объём памяти, необходимый для построения такого дерева, сверхлинейный. В этой работе описан способ получить одновременно линейное время работы и линейную память. Оптимизация памяти применяется к алгоритму Фафьяни и Кратча и к алгоритму ван Беверна. Для оценки эффективности оптимизации проводятся вычислительные эксперименты.

1 Введение

Некоторые труднорешаемые задачи в частных и практически значимых случаях решаются быстро. В попытке обобщения таких “хороших” частных случаев для задачи вводятся *параметры*, относительно которых можно анализировать сложность задачи. Например, параметром может быть размер ответа задачи. В графовой задаче параметром может быть число компонент сильной связности или ограничение на максимальную степень вершины.

Приведём формальное определение [8].

Определение 1.1. *Параметризованная задача (язык задачи)* — это множество $L \subseteq \{0, 1\}^* \times \mathbb{N}$. Здесь пара $(X, k) \in \{0, 1\}^* \times \mathbb{N}$ состоит из *входа* задачи X и *параметра* k .

Определение 1.2. Параметризованная задача $L \subseteq \{0, 1\}^* \times \mathbb{N}$ называется *решаемой полиномиально с параметрозвисимым множителем* (принадлежит классу *FPT*), если существует алгоритм A , определяющий принадлежность пары (X, k) языку задачи L за время $f(k)|X|^c$. Здесь f — произвольная вычислимая функция, а c — константа. Алгоритм A называется *полиномиальным с параметрозвисимым множителем*.

Одним из подходов к построению полиномиального с параметроравнозависимым множителем алгоритма является “сжатие” входа задачи X до размера, не зависящего от его исходного размера, а только лишь от k . Тогда, при запуске любого экспоненциального алгоритма решения задачи на “сжатом” входе X' , мы получим, что время работы экспоненциального алгоритма от размера исходного входа зависеть не будет.

Такое “сжатие” называется *редукцией данных* или, если размер “сжатого” входа зависит только от параметра k , *кернелизацией*.

Определение 1.3. *Кернелизация* параметрической задачи $L \in \{0, 1\}^* \times \mathbb{N}$ — это полиномиальный алгоритм, входом которого является (X, k) , а выходом — (X', k') . При этом выполняются условия

1. $(X, k) \in L \Leftrightarrow (X', k') \in L$,
2. $|X'| \leq f(k)$ для некоторой вычислимой функции f ,
3. $k' \leq g(k)$ для некоторой вычислимой функции g .

Результат (X', k') кернелизации называется *ядром*, а $f(k)$ — его *размером*.

Поскольку редукция данных потенциально применяется к большему входам, важна полиномиальная или лучше линейная трудоёмкость кернелизации.

В этой работе предлагается новая кернелизация для следующей задачи.

Задача о вершинном покрытии d -гиперграфа.

Дано: гиперграф $G = (V, E)$ такой, что $\forall e \in E : e \subseteq V, |e| \leq d$.

Требуется: найти *вершинное покрытие* $S \subseteq V$ минимального размера, т. е. такое множество $S \subseteq V$, что $\forall e \in E : e \cap S \neq \emptyset$ и $|S| \rightarrow \min$.

В дальнейшем для краткости будем называть гиперграф графом, а гиперребра — ребрами.

Заметим, что ограничение на размер максимального ребра в гиперграфе d является частью задачи. В дальнейшем мы будем считать d константой. Решение задачи с таким ограничением представляет интерес и для достаточно маленьких d . Например, задача о кластеризации графа сводится к задаче о вершинном покрытии гиперграфа при $d = 3$ [3], а задача о линейках Голомба — при $d = 4$ [5]. Последняя задача имеет приложение при максимизации использованных радиочастот с минимизацией интерференций.

Параметризуем задачу, взяв в качестве параметра k — ограничение на размер вершинного покрытия S .

Параметризованная задача о вершинном покрытии d -гиперграфа.

Дано: гиперграф $G = (V, E)$ такой, что $\forall e \in E : e \subseteq V, |e| \leq d$.

Параметр: k .

Требуется: определить, существует ли вершинное покрытие $S \subseteq V$ размера не более k , т. е. такое множество $S \subseteq V$, что $\forall e \in E : e \cap S \neq \emptyset$ и $|S| \leq k$.

Такая задача всё еще остается NP-трудной, однако для неё существует алгоритм полиномиальный с параметрозвисимым множителем, работающий за время $O(d^k|E|)$ [10].

В данной работе рассматриваются алгоритмы кернелизации для задачи о вершинном покрытии гиперграфа, с помощью которых можно ускорить известные полиномиальные с параметрозвисимым множителем алгоритмы. Входом алгоритма кернелизации будет являться гиперграф G , а выходом — гиперграф G' .

В настоящее время существует несколько алгоритмов кернелизации для параметризованной задачи о вершинном покрытии. В 2003 году Нидермайер и Росманит [9] предложили алгоритм кернелизации задачи для $d = 3$ с ядром размера $O(k^3)$. Для произвольного d первый алгоритм был предложен в 2006 году Флюром и Гроэ [2]. В ядре кернелизации $O(k^d)$ рёбер, что является асимптотически наилучшим ядром: в 2010 году Делл и ван Мелькебек показали, что нельзя за полиномиальное время построить ядро $O((k+1)^{d-\epsilon})$, если не схлопывается полиномиальная иерархия [7]. Время работы алгоритма Флюма и Гроэ сверхлинейное, поэтому интерес в данной работе будут составлять более поздние алгоритмы. Алгоритмы ван Беверна 2014 года [4] и Фафьяни и Кратча 2015 года [6] получают ядра размера $O(k^d)$ и работают за линейное время, однако требуют сверхлинейного объёма памяти. В следующих частях будут предложены модификации обоих алгоритмов, сокращающие объем требуемой памяти до линейного.

В дальнейшем будем пользоваться обозначениями: $G = (V, E)$ — исходный граф, $G' = (V', E')$ — результат кернелизации, $n = |V|$, $m = |E|$. Ограничение на размеры рёбер — d . Вершины будем считать пронумерованными от 1 до n , а размером входа при подсчёте времени работы будем считать $O(n + dm)$.

2 Алгоритм Фафьяни и Кратча

В 2015 году Фафьяни и Кратч предложили алгоритм кернелизации (Алгоритм 1), работающий за линейное время [6]. Этот алгоритм сокращает число рёбер до $(k + 1)^d$.

Алгоритм 1 по очереди обрабатывает рёбра исходного графа G и решает, взять ли очередное ребро e в конечный граф G' . Для этого он рассматривает каждое подмножество s ребра e и проверяет, сколько рёбер, уже взятых в конечный граф $G' = (V, E')$, являются надмножествами e . Это число надмножеств хранится в структуре данных $\text{supersets}[]$. Если $\text{supersets}[s]$ уже имеет предельное допустимое значение $(k + 1)^{d - |s|}$ для некоторого $s \subseteq e$, то ребро e в графе можно не брать. Доказательство этого факта выходит за рамки данной работы, его можно найти в оригинальной работе Кратча и Фафьяни [6]. Если ребро e всё же было взято в конечный граф, то алгоритм увеличивает на 1 значения $\text{supersets}[s]$ для всех подмножеств s ребра e , поскольку e теперь является новым надмножеством для s . Заметим, что после этого сохранилось соотношение $\text{supersets}[s] \leq (k + 1)^{d - |s|}$ для любого s .

Алгоритм 1: Алгоритм Фафьяни и Кратча

Вход: d -гиперграф $G = (V, E)$, натуральное число k .

Выход: d -гиперграф $G' = (V, E') : |E'| \leq (k + 1)^d$.

```
1  $L \leftarrow \emptyset$ ;
2 foreach  $s \subseteq e, e \in E$  do
3    $\text{supersets}[s] \leftarrow 0$ ;
4  $E' \leftarrow \emptyset$ ;
5 foreach  $e \in E$  do
6    $take \leftarrow \text{True}$ ;
7   foreach  $s \subseteq e$  do
8     if  $\text{supersets}[s] \geq (k + 1)^{d - |s|}$  then
9       // ребро  $e$  не попадёт в граф  $G'$ 
10       $take \leftarrow \text{False}$ ;
11       $E' \leftarrow E' \cup \{e\}$ ;
12      foreach  $s \subseteq e$  do
13         $\text{supersets}[s] \leftarrow \text{supersets}[s] + 1$ ;
14 return  $G' = (V, E')$ ;
```

Получить оценку размер выходного графа несложно. Любое ребро $e \in E'$ является надмножеством для \emptyset . Для любого множе-

ства s сохраняется соотношение $\text{supersets}[s] \leq (k+1)^{d-|s|}$. Поэтому число рёбер $|E'| = \text{supersets}[\emptyset] \leq (k+1)^d$.

3 Структура данных `supersets[]`

Как было видно в предыдущем разделе, алгоритм 1 использует структуру данных $\text{supersets}[s]$. В ней хранится число взятых в граф G' рёбер-надмножеств для каждого возможного подребра. Фафьянни и Кратч в качестве такой структуры данных используют префиксное дерево, предложенное ван Беверном в его алгоритме [4]. Сначала рассмотрим такую структуру данных и покажем, что она потребляет сверхлинейный объём памяти.

Префиксное дерево строится следующим образом. Пусть S — множество всех возможных подмножеств всех рёбер $e \in E$, то есть

$$s \in S \iff \exists e \in E \mid s \subseteq e.$$

Для каждого множества $s \in S$ создадим свою вершину node_s в дереве и выделим для неё блок памяти. Блок состоит из счётчика counter_s , который будет хранить значение $\text{supersets}[s]$, и массива указателей $\text{nextset}_s[]$ размера n . Элемент массива $\text{nextset}_s[x]$ указывает на блок памяти для вершины дерева $\text{node}_{s'}$, где $s' = s \cup \{x\}$, тогда и только тогда, когда $s' \in S$ и $\forall y \in s : x > y$. Иначе $\text{nextset}_s[x]$ не указывает никуда.

Мы требуем, чтобы номер вершины x был больше, чем у любой другой в s , чтобы путь от корневой вершины node_\emptyset , до любой другой вершины node_s определялся единственным образом. Чтобы найти блок памяти, соответствующий node_s для $s = \{x_1, x_2, \dots, x_{|s|}\}$, отсортируем $x_1, x_2, \dots, x_{|s|}$ по возрастанию. Теперь можно считать, что $x_1 \leq x_2 \leq \dots \leq x_{|s|}$. Будем переходить поочерёдно по вершинам дерева, соответствующим множествам $s_0 = \emptyset$, $s_1 = s_0 \cup \{x_1\}$, \dots , $s_{i+1} = s_i \cup \{x_{i+1}\}$, \dots , $s_{|s|} = s_{|s|-1} \cup \{x_{|s|}\}$. Пусть p_0 — указатель на блок памяти, соответствующий корневой вершине. Имея указатель p_i на память для множества s_i можем получить $p_{i+1} = \text{nextset}_{s_i}[x_{i+1}]$. Чередой таких переходов получим нужный $p_{|s|}$.

Так как для каждого множества s , нужно сделать $|s| \leq d$ переходов, каждый из которых делается за константное время, то доступ к counter_s происходит за время $O(d)$ для любого множества, где d — константа. Значит доступ к $\text{supersets}[s]$ — константный по времени.

Теперь, проанализируем размер памяти, необходимый для работы такой структуры данных. Число вершин в дереве — это хотя

бы число различных множеств в S . Каждое множество требует наличия в дереве еще d множеств, чтобы построить путь от корня до него. Эти множества — $\emptyset, \{x_1\}, \{x_1, x_2\}, \dots, s \setminus \{x_{|s|}\}$. Но все эти множества мы уже посчитали, так как они входят в множество S . Поэтому число вершин в дереве ровно $|S|$. Для каждой из этих вершин мы храним массив из n указателей и один счетчик. Поэтому необходимый размер памяти $\Theta(|S|n)$. Так как $|S| \leq 2^d m$, то асимптотика потребляемой памяти $O(2^d m n) = O(mn)$. Поскольку S содержит по крайней мере все рёбра графа, $S \geq m$. Это значит, что необходимо иметь память размера $\Omega(mn)$.

Проблема в огромном числе неиспользуемых указателей, которые никуда не указывают. Можно их убрать и хранить только полезные указатели, но это будет стоить добавочного времени работы. В следующей части будет показано, как сохранить константное время обращения к $supersets[s]$ и добиться резервирования лишь линейной памяти.

4 Линейная память

Опишем метод сокращения объема требуемой памяти до линейной, сохраняя линейное время работы, для алгоритма Фафьянини-Кратча (Алгоритм 2). Метод будет основан на предварительной сортировке запросов к структуре данных $supersets[]$.

Введём несколько обозначений. Нужно уметь адресоваться к рёбрам, поэтому для каждого ребра $e \in E$ введём идентификатор ребра e_id . Это уникальное для каждого ребра целое число в отрезке $[1, m]$. Множество $s \subseteq V : |s| \leq d$ в памяти компьютера представляем следующим способом.

Определение 4.1. *Код* множества s — это кортеж $code(s)$ размера d такой, что первые $|s|$ его значений — номера вершин из s в возрастающем порядке. Последние $d - |s|$ его значений — нули.

Такой способ представления множеств позволяет нам хранить каждое множество в виде d чисел. Также, при таком представлении, можно сравнивать два множества лексикографически. Для этого просто представим эти коды множеств строками длины d с символами из алфавита $\{0, 1, 2, \dots, n\}$ и сравним их как строки.

Заметим, что Алгоритм 1 всегда обращается к $supersets[s]$ для подмножества s некоторого ребра e только, когда обрабатывает это ребро.

Определение 4.2. Запрос к структуре данных $\text{supersets}[]$ — это пара $(\text{code}(s), e_id)$, где $e \in E, s \subseteq e$. Будем называть $\text{code}(s)$ аргументом запроса.

Запросы будем сравнивать между собой по аргументу запроса. То есть

$$(\text{code}(s1), e1_id) < (\text{code}(s2), e2_id) \Leftrightarrow \text{code}(s1) < \text{code}(s2).$$

Улучшенный алгоритм Фафьяни и Кратча (Алгоритм 2) работает следующим образом.

Пусть L — список всех возможных запросов к структуре данных $\text{supersets}[]$. То есть $L = \{(\text{code}(s), e_id) : e \in E, s \subseteq e\}$. Этот список имеет линейный от входа размер $O(2^d m)$. Найти его можно за линейное время. Для этого совершим проход по всем рёбрам $e \in E$, для каждого из них найдем все подребра $s \subseteq e$ и запрос $(\text{code}(s), e_id)$ положим в L (строка 3 Алгоритма 2).

Так как $\text{code}(s)$ сравнимы между собой, то список L можно отсортировать и получить список L' (строка 4). Сортируем по аргументу запроса, который является кортежем длины d из чисел в отрезке $[0, n]$. Значит это можно сделать за время $O(dn + 2^d dm)$ цифровой сортировкой [1].

Заметим, что при сортировке мы не различали между собой запросы $(\text{code}(s), e1_id)$ и $(\text{code}(s), e2_id)$, так как сортировали только по аргументу запроса. Все запросы с одинаковым аргументом будут располагаться в L' непрерывным отрезком. Назовём такой отрезок *классом эквивалентности*.

Легко разбить L' на классы эквивалентности за линейное время и выдать каждому элементу в L' уникальный идентификатор его класса (строки 5-13). Для этого выдадим первому элементу в L' идентификатор 1, что будет означать первый класс эквивалентности. Теперь пробежим по всем остальным элементам в L' по порядку и будем делать следующее. Пусть, мы сейчас рассматриваем элемент $(\text{code}(s_{cur}), e_{cur_id})$, а предыдущим элементом был $(\text{code}(s_{prev}), e_{prev_id})$. Если $\text{code}(s_{cur}) = \text{code}(s_{prev})$, то текущий элемент в том же классе эквивалентности, что и предыдущий. Выдадим ему такой же идентификатор. Иначе выдадим ему идентификатор на 1 больше, чем у предыдущего элемента. Это будет означать новый класс эквивалентности.

Алгоритм 2: Модифицированный алгоритм Фафьяни и Кратча

Вход: d -гиперграф $G = (V, E)$, натуральное число k .
Выход: d -гиперграф $G' = (V, E') : |E'| \leq (k + 1)^d$.

```
1  $L \leftarrow \emptyset;$ 
2 foreach  $s \subseteq e, e \in E$  do
3    $\lfloor$  put  $(code(s), e\_id)$  in  $L$ ;
4  $L' \leftarrow$  ЦифроваяСортировка( $L$ );
5  $classes\_number \leftarrow 0$ ;
6  $prev\_key \leftarrow code(\emptyset)$ ;
7  $sizes \leftarrow \emptyset$ ;
8 foreach  $(key, e\_id) \in L'$  do
9    $\lfloor$  if это первая итерация  $\vee key \neq prev\_key$  then
10     $classes\_number \leftarrow classes\_number + 1$ ;
11     $sizes[classes\_number] \leftarrow$  число ненулевых
      значений в  $key$ ;
12    положить  $classes\_number$  в  $subset\_list[e\_id]$ ;
13     $prev\_key \leftarrow key$ ;
14 foreach  $s\_id \in [1 \dots classes\_number]$  do
15    $\lfloor supersets[s] \leftarrow 0$ ;
16  $E' \leftarrow \emptyset$ ;
17 foreach  $e \in E$  do
18    $take \leftarrow True$ ;
19   foreach  $s\_id \in subset\_list[e\_id]$  do
20      $\lfloor$  if  $supersets[s\_id] \geq (k + 1)^{d - sizes[s\_id]}$  then
21        $//$  ребро  $e$  не попадёт в граф  $G'$ 
22        $take \leftarrow False$ ;
23   if  $take$  then
24      $E' = E' \cup \{e\}$ ;
25     foreach  $s\_id \in subset\_list[e\_id]$  do
       $\lfloor supersets[s\_id] \leftarrow supersets[s\_id] + 1$ ;
26 return  $G' = (V, E')$ ;
```

Каждый класс эквивалентности обозначает уникальное множество $s \in S$. Номер класса, соответствующего множеству s , назовём s_id . Это число в отрезке $[1, |S|]$. Заметим, что мы перешли от множеств s к кодам $code(s)$ и наконец к числам s_{id} , так что теперь обращаться к структуре данных $supersets[]$ можно по целочислен-

ному индексу, а значит в качестве $supersets[]$ можно использовать обычный массив.

Чтобы при обработке очередного ребра e знать индексы s_id всех его подрёбер s , будем хранить их в списке $subset_list[e_id][]$. Обрабатывая ребро e , алгоритм пробегает по всем подмножествам e в некотором порядке. Теперь этот порядок будет определен порядком элементов в $subset_list[e_id][]$, потому что алгоритм будет пробегать по этому списку, для всех $i \in [1 \dots 2^{|e|}]$ обращаясь к $supersets[subset_list[e_id][i]]$ (строка 19).

Все, что осталось сделать, — это заполнить для каждого ребра $e \in E$ список $subset_list[e_id][]$. Для каждого возможного запроса $(code(s), e_id) \in L'$ положим в $subset_list[e_id][]$ номер класса эквивалентности s_id , в котором лежит эта пара (строка 12).

Подготовка структуры данных $supersets[]$ закончена, и можно запускать алгоритм кернелизации. Остаётся одна маленькая деталь: для каждого класса эквивалентности нужно знать размеры $|s|$ его представителей s , чтобы поддерживать ограничение из строки 8 в Алгоритме 1. Можно хранить эти значения для каждого класса напрямую или запоминать произвольного представителя для каждого класса. В Алгоритме 2 для этого используется массив $sizes[]$.

Время работы состоит из времени сортировки $O(dn + 2^d dm)$ и времени работы алгоритма Фафьяни и Кратча $O(2^d m)$. Итоговое время работы $O(dn + 2^d dm)$.

Массивы $supersets[]$ и $sizes[]$ имеют размер $O(2^d m)$, а список L — $O(2^d dm)$. Еще $O(n + 2^d m)$ памяти потребуется для сортировки списка L . Итоговый размер выделяемой памяти: $O(n + 2^d dm)$.

Таким образом, показано:

Теорема 4.1. Для задачи о вершинном покрытии d -гиперграфа на n вершинах с m рёбрами может быть построена кернелизация

1. с линейной трудоёмкостью $O(dn + 2^d dm)$,
2. с линейной памятью $O(n + 2^d dm)$,
3. с не более чем $(k + 1)^d$ рёбрами в ядре.

5 Алгоритм ван Беверна

Алгоритм ван Беверна (Алгоритм 3) работает за линейное время и сокращает число рёбер до $d!d^{d+1}(k + 1)^d$. Такая оценка на размер ядра хуже, чем у алгоритма Фафьяни и Кратча, однако

последний не всегда может сократить вход, когда это делает алгоритм ван Беверна. Подробнее об этом в разделе 6.

Для понимания работы алгоритма введём понятие *подсолнуха*.

Определение 5.1. Подсолнухом с центром s в гиперграфе $G = (V, E)$ называется множество $F \subseteq E$ рёбер такое, что $s \subseteq e$ для каждого ребра $e \in F$, и каждая пара рёбер $e_1, e_2 \in F$ пересекается ровно по множеству s . Рёбра $e \in F$ называются *лепестками*. Размер подсолнуха — $|F|$.

Можно показать, что для подсолнуха размера $k + 2$, любой его лепесток можно выкинуть из графа, и ответ на параметризованную задачу о вершинном покрытии d -гиперграфа не изменится. На этом факте и основан Алгоритм 3.

Алгоритм 3: Алгоритм ван Беверна

Вход: d -гиперграф $G = (V, E)$, натуральное число k .

Выход: d -гиперграф $G' = (V, E') : |E'| \leq d!d^{d+1}(k + 1)^d$.

```

1 foreach  $s \subseteq e, e \in E$  do
2    $petals[s] \leftarrow 0$ ;
3   foreach  $v \in e$  do
4      $used[s][v] \leftarrow False$ ;
5    $E' \leftarrow \emptyset$ ;
6   foreach  $e \in E$  do
7      $take \leftarrow True$ ;
8     foreach  $s \subseteq e$  do
9       if  $petals[s] > k$  then
10         // ребро  $e$  не попадёт в граф  $G'$ 
11          $take \leftarrow False$ ;
12       if  $take$  then
13          $E' \leftarrow E' \cup \{e\}$ ;
14         foreach  $s \subseteq e$  do
15           if  $\forall v \in e \setminus s : used[s][v] = False$  then
16              $petals[s] \leftarrow petals[s] + 1$ ;
17             foreach  $v \in e \setminus s$  do
18                $used[s][v] \leftarrow True$ ;
19
18 return  $G' = (V, E')$ ;

```

Алгоритм 3 просматривает все рёбра графа $G = (V, E)$ по очереди и для каждого из них решает, брать ли его в кернелизованный граф $G' = (V, E')$. По ходу работы алгоритм строит подсолнухи F_s

для каждого множества $s \subseteq e : e \in E$. При взятии ребра e в E' , он выясняет для каждого множества $s \subseteq e$, можно ли добавить e в подсолнух F_s . Если в подсолнухе F_s и так есть хотя бы $k + 1$ лепесток, то ребро e можно не брать в граф G' (строки 9-10 Алгоритма 3). Если каждый из подсолнухов $F_s, s \subseteq e$ еще недостаточно велик, то можно в каждый из них попробовать добавить новый лепесток e . Алгоритм смотрит, не пересечёт ли множество $e \setminus s$ какое-нибудь другое ребро $e' \in F_s$ (строка 14). Для этого он хранит в структуре данных $used[s] []$ булевое значение для каждой вершины v , истинное тогда и только тогда, когда $v \in \bigcup_{e' \in F_s} e' \setminus s$. Если для всех вершин $v \in e \setminus s$ выполняется $used[s][v] = False$, то e не пересекает других лепестков подсолнуха не по множеству s . Тогда оно само может стать лепестком. Для этого алгоритм помечает *True* нужные значения в $used[s] []$ и увеличивает на 1 счётчик лепестков $petals[s]$.

Доказательство оценки на размер ядра можно прочитать в работе ван Беверна [4].

Память, требуемая алгоритмом для его работы, сверхлинейна из-за структур данных $petals[]$ и $used[][]$. Первая из них — это префиксное дерево, а вторая — префиксное дерево, у которого в вершинах, соответствующих рёбрам графа, хранится массив из n булевых значений. Улучшим потребление памяти и этого алгоритма тоже.

Заметим, что структура данных $petals[]$ так же как и $supersets[]$ хранит счётчик для некоторых подрёбер $s \subseteq e : e \in E$. Значит, все суждения относительно структуры данных $supersets[]$ применимы и к структуре данных $petals[]$. Запросы к ней можно отсортировать и сделать $petals[]$ массивом. Для $used[][]$ применим похожую методику сортировки запросов.

Определение 5.2. Запрос к структуре данных $used[][]$ — это тройка $(code(s), v, e_id)$, где $e \in E, s \subseteq e, v \in e \setminus s$. Будем называть $code(s)$ и v первым и вторым аргументами запроса соответственно.

Сравнивать такие запросы будем по первому аргументу запроса, а затем по второму, то есть

$$\begin{aligned} (code(s1), v1, e1_id) < (code(s2), v2, e2_id) \Leftrightarrow \\ \Leftrightarrow code(s1) < code(s2) \vee (code(s1) = code(s2) \wedge v1 < v2). \end{aligned}$$

Заметим, что к таким запросам снова применима цифровая сортировка, так как можно считать $code(s) \cup \{v\}$ одним кортежем длины $d + 1$ с элементами из $[0, n]$.

Улучшенный алгоритм ван Беверна (Алгоритм 4) работает следующим образом.

Алгоритм 4: Модифицированный алгоритм ван Беверна

Вход: d -гиперграф $G = (V, E)$, натуральное число k .
Выход: d -гиперграф $G' = (V, E') : |E'| \leq d!d^{d+1}(k + 1)^d$.

```

1  $L \leftarrow \emptyset;$ 
2 foreach  $e \in E, s \subseteq e, v \in e \setminus s$  do
3    $\quad$  put  $(code(s), v, e\_id)$  in  $L$ ;
4    $L' \leftarrow$  ЦифроваяСортировка( $L$ );
5    $classes\_number \leftarrow 0$ ;
6    $subclasses\_number \leftarrow 0$ ;
7   foreach  $(key1, key2, e\_id) \in L'$  do
8     Пересчитать  $classes\_number$  и  $subclasses\_number$ 
      сравнив  $key1$  и  $key2$  в текущем элементе списка и в
      предыдущем;
9     if  $subset\_list[e\_id] = \emptyset \vee$ 
        $subset\_list[e\_id][size(subset\_list[e\_id]) - 1] \neq$ 
        $classes\_number$  then
10      положить  $classes\_number$  в  $subset\_list[e\_id]$ ;
11      положить  $\emptyset$  в  $vertex\_list[e\_id]$ ;
12      положить  $subclasses\_number$  в
           $vertex\_list[e\_id][size(vertex\_list[e\_id]) - 1]$ ;
13 Занулить все значения  $petals[]$  и  $used[][]$ ;
14 Запустить алгоритм ван Беверна;
15 return  $G' = (V, E')$ ;

```

Положим в список L все запросы к структуре данных $used[][]$ из Алгоритма 3, отсортируем и разобьем на классы эквивалентности с одинаковым первым аргументом запроса. Заметим, что таким образом мы уже для каждого ребра e нашли все s_id для дальнейшей индексации в массивах $petals[]$ и $used[]$. Положим s_id в массив $subset_list[e_id][][]$ для каждого ребра e , присутствующего в запросах из класса эквивалентности с номером s_id .

Каждый класс эквивалентности теперь можно разбить на *подклассы эквивалентности*, такие непрерывные отрезки, для которых совпадает второй аргумент запроса. Выдадим каждому подклассу класса с номером s_id свой уникальный идентификатор v_id . После строки 8 Алгоритма 4 значения $classes_number$ и $subclasses_number$ будут равны s_id и v_id соответственно. Тен-

перь можно обращаться в $used[s_id] []$ по индексу v_id .

Рассмотрим подкласс эквивалентности C с номером v_id в классе эквивалентности с номером s_id . Для каждого ребра e в запросе $(code(s), v, e_id) \in C$ в массив $vertex_list[e_id][s_id'] []$ положим v_id . Здесь s_id' — это номер класса эквивалентности s_id в списке $subset_list[e_id] []$. То есть мы не храним для ребра e лишних списков номеров вершин, а только непустые. Теперь нужные значения v_id хранятся в $vertex_list[e_id][s_id'] []$ для того, чтобы при обработке ребра e и его подребра s , были известны значения v_id , по которым будут происходить обращения в массив $used[e_id] []$.

Время работы Алгоритма 4 складывается из времени сортировки $O(dn + 2^d dm)$ и времени работы алгоритма ван Беверна $O(2^d dm)$. Итоговое время работы $O(dn + 2^d dm)$.

Массив $petals []$ имеет размер $O(2^d m)$, а список $L = O(2^d dm)$. Для сортировки L потребуется $O(n + 2^d m)$ дополнительной памяти. Сумма размеров массивов $used[s_id] []$ по всем s_id не превышает числа запросов к структуре данных $used []$, а значит имеет значение $O(2^d dm)$. Итоговый размер выделяемой памяти: $O(n + 2^d dm)$.

6 Тестирование и сравнение алгоритмов

Оба Алгоритма 2 и 4 были реализованы на языке C++, скомпилированы при помощи GNU C++ 5.4.0 с уровнем оптимизации -O2 и протестированы на компьютере с процессором Intel Core i7-4600U с тактовой частотой 2.10GHz и 64-битной операционной системой Ubuntu 16.04.

Тестирование проходило на гиперграфах, порождаемых задачей о подлинейках Голомба. Это важная подзадача в построении линеек Голомба: множеств $R \subseteq \mathbb{N}$ таких, что разность любых двух чисел в нём уникальна. То есть для любой четверки чисел $a, b, c, d \in R$ выполняется $|a - b| = |c - d| \Rightarrow \{a, b\} = \{c, d\}$. Задача о подлинейках Голомба — это задача поиска наибольшей по размеру линейки Голомба $R \subseteq M$ для некоторого $M \subseteq \mathbb{N}$. Эта задача сводится к задаче о вершинном покрытии 4-гиперграфа [5]. Для этого построим гиперграф конфликтов $G = (M, E)$, где множество рёбер E будет содержать все четверки $\{a, b, c, d\} : |b - a| = |c - d|$ и тройки $\{a, b, c\} : |a - b| = |b - c|$. Ответ к задаче о вершинном покрытии гиперграфа для G — это множество всех чисел, которые не входят в ответ к задаче о подлинейках Голомба R . В наших тестах

$M = \{1, \dots, n\}$ для различных $n \in [100, 300]$. Параметр k выбран равным нижней оценке на размер ответа. Для её нахождения, мы ищем максимальное по включению множество попарно непересекающихся рёбер. Ясно, что размер такого множества не превосходит размер вершинного покрытия.

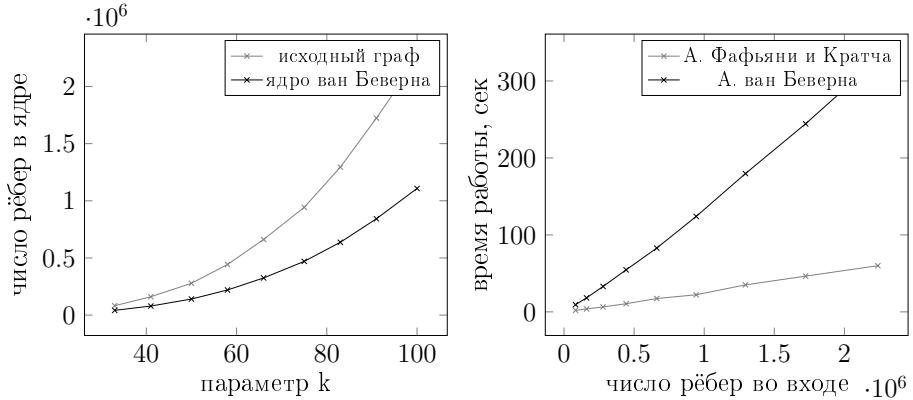


Рис. 1: Сравнение работы алгоритмов ван Беверна и Фафьяни и Кратча.

В ходе тестирования было замечено, что Алгоритм 2 (основанный на алгоритме Фафьяни-Кратча) не всегда сжимает гиперграф, когда алгоритм ван Беверна это делает, хотя верхняя оценка на число рёбер в ядре для алгоритма ван Беверна больше. Более того, для задачи о подлинейках Голомба, алгоритм Фафьяни и Кратча не сокращал число рёбер вовсе, и размер ядра совпадает с размером исходного графа. Параметр k в тестах, порождённых задачей о подлинейках Голомба, настолько велик, что оценка на число рёбер в ядре $(k + 1)^d$ для алгоритма Фафьяни и Кратча превышает исходное число рёбер, и сокращения графа не происходит. Алгоритм ван Беверна имеет худшую оценку на размер ядра, но всё-таки сокращает число рёбер приблизительно в 2 раза.

Для более эффективного сжатия входного графа, можно использовать оба алгоритма: модифицированный Фафьяни-Кратча и ван Беверна в этом порядке. Тогда, более тяжеловесный по времени и памяти алгоритм ван Беверна будет работать на уже сжатом графе, и, возможно, сократит его сильнее.

7 Заключение

В данной работе приведены два алгоритма кернелизации для задачи о вершинном покрытии гиперграфа. Оба алгоритма работают за линейное время, повторяя предыдущие результаты, однако достигают линейности по памяти.

Реализованы программы на языке C++. Было произведено сравнение алгоритма Фафьяни и Кратча с алгоритмом ван Беверна и обнаружена относительно низкая эффективность первого на примере задачи о линейках Голомба. Предложена идея о комбинировании алгоритмов.

Остается открытым вопрос о меньшем потреблении памяти при кернелизации для задачи о вершинном покрытии гиперграфа. Предпосылки к этому есть: Фафьяни и Кратч предложили алгоритм кернелизации, работающий за время $O(m^{d+2})$, однако требующий лишь логарифмическую память.

Список литературы

- [1] Т. Кормен, Ч. Лейзерсон, Р. Ривест, К. Штайн. *Алгоритмы: построение и анализ*. Москва. МЦНМО. 2000.
- [2] J. Flum and M. Grohe. *Parameterized Complexity Theory*. Springer, 2006
- [3] F. Hüffner, C. Komusiewicz, H. Moser, R. Niedermeier. Fixed-Parameter Algorithms for Cluster Vertex Deletion. *Theory of Computing Systems* 47(1): 196-217, 2010.
- [4] R. van Bevern. Towards Optimal and Expressive Kernelization for d -Hitting Set. *Algorithmica* 70(1):129-147, 2014. arXiv:1112.2310
- [5] M. Sorge, H. Moser, R. Niedermeier, and M. Weller. Exploiting a hypergraph model for finding Golomb rulers. *Acta Informatica* 51(7):449-471, 2014.
- [6] S. Fafianie and S. Kratsch. A shortcut to (sun)flowers: Kernels in logarithmic space or linear time. In *Proceedings of the 40th International Symposium on Mathematical Foundations of Computer Science (MFCS'15)*, volume 9235 in LNCS, pp. 299-310, Springer, 2015.
- [7] H. Dell and D. van Melkebeek. Satisfiability allows no nontrivial sparsification unless the polynomial-time hierarchy collapses. *Journal of the ACM*, 61(4): 23:1-23:27

- [8] M. Cygan, F. V. Fomin, L. Kowalik, D. Lokshtanov, D. Marx, M. Pilipczuk, M. Pilipczuk, and S. Saurabh. *Parameterized Algorithms*. Springer, 2015
- [9] R. Niedermeier and P. Rossmanith. An efficient fixed-parameter algorithm for 3-Hitting Set. *Journal of Discrete Algorithms* 1(1), 2003, pages 89–102
- [10] R. Niedermeier. *Invitation to Fixed Parameter Algorithms*. Oxford University Press, 2006