

2 курс ПМИ, осень 2024/25
Практика по алгоритмам #8

Бор, Ахо-Корасик, суфдерево
12 ноября

Собрано 11 ноября 2024 г. в 15:29

Содержание

1. Бор, Ахо-Корасик, суфдерево	1
2. Разбор задач практики	3
3. Домашнее задание	6
3.1. Обязательная часть	6
3.2. Дополнительная часть	7

Бор, Ахо-Корасик, суффдерево

1. Сравнение множеств (задача из дз)

Придумайте хеш-функцию, которая позволяет за $\mathcal{O}(1)$ делать 3 операции с множествами целых положительных 32-битных чисел.

- a) Добавить элемент в множество
- b) Удалить элемент из множества
- c) Проверить два множества на равенство.
- d) (*) $+=$ ко всем элементам множества.

2. ST \rightarrow SA

По суффиксному дереву постройте суффиксный массив с LCP.

3. SA \rightarrow ST

По суффиксному массиву с LCP постройте суффиксное дерево.

4. (*) Хитрый поиск

Дан словарь, постройте структуру, чтобы быстро отвечать на запросы

- a) $\text{get}(s)$ – число строк в словаре, которые начинаются с s , заканчиваются на \overleftarrow{s} .
- b) $\text{get}(s, t)$ – число строк в словаре, которые начинаются с s , заканчиваются на t , $|s| = |t|$.
- c) $\text{get}(s, t)$ – число строк в словаре, которые начинаются с s , заканчиваются на t .

5. Словари offline

Даны словарь (конечное множество слов) и текст.

- a) Для каждого слова из словаря определить, входит ли оно как подстрока в текст.
- b) Для каждого слова из словаря найти число вхождений в текст.

6. Словари online

Даны словарь (конечное множество слов) и текст. Обновлять ответ `online` при добавлении символа в конец текста.

- a) Пересчитать суммарное число вхождений слов из словаря в текст за $\mathcal{O}(1)$.
- b) Пересчитать множество всех вхождений слов из словаря в текст за $\mathcal{O}(1 + |\Delta A|)$, где ΔA – приращение ответа после добавления очередного символа.

7. Разбиение на словарные слова

Дан словарь слов суммарной длины L и текст T .

- a) Слова длины $\leq l$. Представить T в виде конкатенации минимального числа словарных слов за $\mathcal{O}(L + l|T|)$. Слова можно использовать более одного раза.
- b) (*) За $\mathcal{O}(L + \sqrt{L}|T|)$.
- c) Представить T в виде конкатенации минимального количества **подстрок** словарных слов за $\mathcal{O}(\text{poly}(L) + |T|)$.

8. Задачи про суффиксное дерево

- a) Найти количество различных подстрок.
- b) Найти самый длинный рефрен – подстроку s : $\text{count}(s) \cdot |s| \rightarrow \max$.

- c) Самая длинная подстрока, входящая в s дважды, причём вхождения не пересекаются.
- d) Общая подстрока двух строк за $\mathcal{O}(|s| + |t|)$.
- e) Общая подстрока $k \leq 64$ строк за суммарную длину всех строк.
- f) (*) Общая подстрока $\forall k$ строк за суммарную длину всех строк.

9. Амортизация в Укконене

Приведите пример, когда Укконен

- a) при добавлении одного символа потратит $\Omega(n)$ времени,
- b) (*) при вычислении одной суффсылки спустится вниз $\Omega(\sqrt{n})$ раз.

10. Бажный Укконен

При подсчёте суффиксных ссылок в алгоритме Укконена маленький Петя делает спуск не по ребрам (пройти всё ребро за шаг), а по символам (пройти один символ за шаг). Приведите пример строки, на которой полученный алгоритм будет работать $\omega(n)$.

11. Один бор хорошо, а два – лучше!

Даны два бора A и B . Найдите для каждой вершины $u \in A$ самую глубокую вершину B , путь до которой равен суффиксу $path: root_A \rightsquigarrow u$. $\mathcal{O}(|A| + |B|)$. Размер алфавита $\mathcal{O}(1)$.

Как увидеть в этой задаче обобщение Ахо-Корасик? Что есть A и B в Ахо-Корасик?

12. Быстрый Ахо-Корасик

Дан бор A над алфавитом S произвольного размера, постройте суффиксные ссылки за $\mathcal{O}(|A| \cdot \text{poly}(\log |S|))$. На самом деле за такое время можно построить полный автомат.

Мы уже умеем строить суффиксные ссылки несколькими способами.

Полный автомат мы строим за $\mathcal{O}(|A| \cdot |S|)$. `dfs` + откаты, как в префикс функции, работают за $\mathcal{O}(\sum |s_i|)$, что может быть сильно больше $|A|$.

13. (*) ∞ , избегаемость шаблонов («вирусы»)

Дан словарь слов суммарной длины L . За время $\mathcal{O}(L)$ определите, существует ли бесконечная строка, не содержащая ни одно словарное слово как подстроку.

14. (*) XOR → max

Дан массив a длины n . Найдите пару $a_i, a_j: a_i \hat{a} a_j = \max$.

- a) $\mathcal{O}(n \log M)$. $M = \max(a_1, \dots, a_n)$.
- b) $\mathcal{O}(\text{sort} + n)$

15. (*) XOR $\geq k$

Дан массив a длины n и число k . Длина чисел в массиве $\mathcal{O}(1)$. За время $\mathcal{O}(n)$ посчитайте количество

- a) пар индексов таких, что побитовый XOR элементов по этим индексам $\geq k$.
- b) отрезков последовательности, побитовый XOR всех чисел из которых $\geq k$.

16. (*) Окно и стек

Найти максимальный refrain (число вхождения \times длину $\rightarrow \max$) с помощью суффиксного массива.

Разбор задач практики

1. Сравнение множеств (задача из дз)

Мы можем поддерживать для множества A величину $\sum_{a \in A} f(a) \bmod m$.

Осталось придумать f : легко посчитать и сложно подделать. $f(a) = P^a \bmod m$.

$\forall a \ a+=\Delta a \Leftrightarrow f(a)*=P^{\Delta a} \bmod m \Rightarrow$ все три операции `add`, `del`, `+=` за $\mathcal{O}(\log a)$.

Вероятность ошибки: P случайное и должно быть корнем многочлена $\deg = \max a \Rightarrow \Pr \leq \frac{\max a}{m}$. $\max a \leq 10^9$, $m \leq 10^{18} \Rightarrow$ ОК. Но для $A_1 = \{0\}$, $A_2 = \{m-1\}$ хеши совпадут $\forall P$.

Мемное решение. Пусть $f(x) = \text{mem}[x]$, где `mem` — хеш-таблица, куда при первом обращении кладётся псевдорандом. $\Pr[\text{ошибки}] = \frac{1}{m}$, время `add`, `del` $\mathcal{O}(1)$, но много лишней памяти.

Третий вариант. $A = \prod_{a \in A} (z-a) \bmod m$, где z фиксированное случайное.

Множества A и B имеют коллизию $\Leftrightarrow z$ — корень многочлена степени $\leq \max |A|, |B| \Rightarrow \Pr[\text{ошибки}] \leq \frac{|A|}{m}$. `add` за $\mathcal{O}(1)$, `del` за $\mathcal{O}(\log m)$ т.к. нужно обращать по модулю.

Итого. Первое — единственное решение с `+=`. Хеш-таблица даёт самое быстрое решение, но ест много памяти. Третье решение лучше первого по ошибке и времени `add`.

2. ST \rightarrow SA

dfs по дереву, помним позицию самой высокой вершины с момента, как последний раз были в листе, эта высота и есть LCP.

3. SA \rightarrow ST

Пусть мы уже построили дерево для первых i суффиксов SA, стоим в листе. Поднимаемся от листа до уровня $lcp[i]$, создаём развилку, новый лист.

4. Хитрый поиск

- a) `get(s)` — бор из $LCP(w, \overleftarrow{w})$. Спускаемся по s , смотрим число конечных вершин в поддереве.
- b) `get(s, t)` — бор из строк $w_1 w_n w_2 w_{n-1} w_3 w_{n-2} \dots w_n w_1$. Спускаемся попеременно по символам s и \overleftarrow{t} . Смотрим число конечных вершин в поддереве.
- c) `get(s, t)` — бор прямых строк, отдельно бор обратных строк. Конечные вершины помечены номерами строк.

Спускаемся в первом боре по s , во втором по \overleftarrow{t} , получили два поддерева. Ответ — пересечение множеств пометок в этих поддеревьях. В каждом дереве все пометки различны, умеем решать такую задачу 2D-запросом.

5. Словари offline

Строим Ахо-Корасик для словаря.

- a) Проходим по тексту, помечаем все посещенные вершины. В конце проходим снизу вверх по бору и делаем `visited[suf[v]] |= visted[v]`.
- b) Проходим по тексту, считаем число посещений каждой вершины. В конце проходим снизу вверх по бору и делаем `count[suf[v]] += count[v]`.

6. Словари online

Строим Ахо-Корасик для словаря.

- a) Посчитаем динамику: количество терминальных вершин на суффиксном пути.
- b) Посчитаем супер-суффиксные ссылки: ближайшая терминальная вершина на суффиксном пути.

7. Разбиение на словарные слова

- a) Строим бор из словаря. $f[i]$ – минимальная стоимость выписать префикс длины i .

Динамика вперёд: спускаемся по бору суффиксом $s[i:]$, если очередная вершина бора конечная, то $\text{relax}(f[i + \text{dep}], f[i] + 1)$.

Максимальная глубина бора $l \Rightarrow$ время $\mathcal{O}(L + l|T|)$.

- b) Строим суффдерево для $s_1\#s_2\#\dots\#s_n$ за $\mathcal{O}(L)$.

Жадно разбиваем текст за $\mathcal{O}(|T|)$: пока текст не пуст, отрезаем самый длинный префикс текста, по которому можем спуститься в боре.

Способ #2: Ахо-Корасиком. Он находит самую глубокую вершину бора, в которую можно прийти суффиксом текста.

Считаем динамику, держим очередь с минимумом для окна, покрытого путем до текущей вершины бора.

8. Задачи про суффиксное дерево

В суффиксном дереве s $\forall x$ подстрока s заканчивается в вершине u или посреди ребра $v \rightarrow u$. В поддереве u заканчиваются все суффиксы начинающиеся в x (все вхождения x).

- a) **Число подстрок.** В боре это число вершин. В сжатом боре это сумма длин ребер.
- b) **Рефрен.** $\text{count}(s)$ – число суффиксов, кончающихся в поддереве, если спуститься по s .
Заметим, что достаточно смотреть на строки, кончающиеся в вершинах.
- c) **Дважды входящая.** Ищем v : $\min(R[v] - L[v], \text{depth}[v]) \rightarrow \max$. Ответ может быть посередине ребра.
- d) **Общая подстрока.** Суффдерево для $s\#t\#$. Самая глубокая вершина, в поддереве которой есть и суффикс s , и суффикс t . Чтобы это определить, храним \min и \max суффиксы в поддереве.
- e) **$k \leq 64$ строк.** Для каждой вершины считаем битмаску номеров строк, суффиксы которых есть в ее поддереве. Ищем самую глубокую, в поддереве которой есть все k .
- f) $\forall k$. За $\mathcal{O}(n)$ посчитаем для каждой вершины количество различных чисел в поддереве.
Было в прошлом семестре через LCA и суммирование снизу вверх по дереву.

9. Амортизация в Укконене

- a) $aaa\dots ab$. Добавление последнего символа создаст n новых листьев.
- b) $axbbbbbbbbbby xbc xbbc xbbbc xbbbbc xbbbbc\dots axbbbbbbbbbzbz$

10. Бажный Укконен

$aaa\dots a$. Добавляем b . Для создания листа суффикса i нужно спуститься из корня на i .

11. Один бор хорошо, а два – лучше!

Замкнем бор B до полного автомата за $\mathcal{O}(|B|)$. Для каждой вершины $u \in A$ ответ пересчитываем через предка: $\text{ans}[a[v][c]] = b[\text{ans}[v]][c]$.

12. Быстрый Ахо-Корасик

Храним в каждой вершине v персистентный массив $\text{next}[v]: \text{next}[v] = \text{next}[\text{suf}[v]]$ кроме тех рёбер, которые торчат из вершины v вниз. $\text{suf}[v] = \text{next}[\text{suf}[\text{p}[v]]][\text{pchar}[v]]$.

13. (*) ∞ , избегаемость шаблонов («вирусы»)

Строим автомат Ахо-Корасик для словаря. Запретим (выкинем из автомата) вершины, на пути из суффсылок от которых есть запрещённые слова. Проверим, есть ли в графе цикл, достижимые из стартовой вершины. Бесконечная строка $\exists \text{ iff } \exists$ такой цикл.

14. (*) **XOR** $\rightarrow \max$

- a) Числа – битовые строки длины **ровно** $\log M$.

Строим на них бор, старшие биты ближе к корню.

Переберём a_i . Будем спускаться по бору, стараясь получить a_j с максимальным $a_i \hat{} a_j$: если есть ребро по биту, не равному соответствующему биту в a_i , спускаемся по нему.

- b) $\mathcal{O}(\text{sort} + n)$. Сначала заметим, что можно не перебирать a_i , а найти оба элемента параллельным спуском по бору: идем по разным битам, если можем.

Далее, размер сжатого бора $\mathcal{O}(n)$. Имея сжатый бор, можно за $\mathcal{O}(n)$ найти ответ.

Сортируем массив и считаем LCP соседних. LCP можно посчитать битовыми операциями и предпосчитанными логарифмами степеней двоек.

По сортированному массиву и LCP умеем строить сжатый бор за $\mathcal{O}(n)$.

15. (*) **XOR** $\geq k$

- a) Строим бор на числах массива как битовых строках равной длины.

Перебираем a_i , считаем число пар с ним. Для этого спускаемся по бору туда, где **XOR** даст результат, как в k . Если спустились по 0, прибавляем к ответу число листьев поддерева, куда ведёт ребро по 1.

- b) **XOR** подотрезка $[i, j]$ – это $\text{pref}_i \hat{} \text{pref}_{j+1}$, где pref_i – **XOR** на префикссе. Решаем предыдущий пункт для pref .

16. (*) Окно и стек

Взяли LCP соседних, получили задачу: найти отрезок такой, что длина $\times \min \rightarrow \max$. Умеем её решать стеком за $\mathcal{O}(n)$ из первого семестра.

Домашнее задание

3.1. Обязательная часть

1. (2) Первое и последнее вхождение

Даны словарь и текст. Найдите для каждого словарного слова первое и последнее его вхождения в текст в качестве подстроки.

2. (3) Навигация в боре

Даны бор A и строка s . Найдите вершину бора v , от которой строку s можно отложить вниз по бору. Размер алфавита $\mathcal{O}(1)$. Время $\mathcal{O}(|A| + |s|)$.

3. (3) Количество строк

Дан словарь и число n . Посчитайте количество строк длины n над алфавитом $\{a, b\}$, которые не содержат ни одного словарного слова, как подстроку. Время $\mathcal{O}(nL)$, где L – суммарная длина слов в словаре.

(+1) допбалл за $\mathcal{O}(L)$ памяти.

4. (2) LowerBound

Напишите код на C++ структуры данных с интерфейсом

- a) `void add(const vector<int> &s);` – добавить строку.
- b) `vector<int> lowerbound(const vector<int> &s);` – найти строку лексикографически минимальную среди больше либо равных s .

Размер алфавита $\mathcal{O}(1)$. За основу возьмите следующий бор:

```

1 struct Vertex {
2     static const int ALPHABET = 26;
3     vector<int> next;
4     bool isEnd;
5     Vertex() : next(ALPHABET, -1), isEnd(0) { }
6 }
7 vector<Vertex> trie(1); // бор из одной вершины
8 int root = 0;
```

5. (3) Ключевые подстроки

Дан набор строк s_i . Для каждой s_i найдите минимальную по длине подстроку, которая не встречается в других s_j .

6. (3) Уникальные суффиксы

Два типа запросов в онлайн, в сумме должно отработать за линию:

- a) `addLetter(c)` – дописать в конец строки символ c .
- b) `isUnique(len)` – является ли суффикс длины len уникальной подстрокой.

7. (3) k -я общая подстрока

Найти k -ю лексикографически общую подстроку s и t за $\mathcal{O}(|s| + |t|)$. Размер алфавита $\mathcal{O}(1)$.

(+1) за произвольный размер алфавита.

3.2. Дополнительная часть

1. (1) XOR-3

Дана массив натуральных чисел a длины $n \leq 10^6$. Найдите отрезок a , побитовый XOR всех чисел из которого максимальен. Полный балл получит решение за время $\mathcal{O}(n + \text{sort})$.

На дополнительный балл можно придумать чистое $\mathcal{O}(n)$.

2. (3) Поиск по отрезку словаря

Дан словарь s_1, s_2, \dots, s_n . Отвечать в offline на запросы `get(t,l,r)` – сколько строк из $\{s_l, \dots, s_r\}$ входят в t как подстроки. Время работы – линия от размера входа на полилог.

3. (3) Динамический словарь

В словаре теперь добавляются «`add(s)`» и удаляются «`del(s)`» слова.

Необходимо в online научиться отвечать на запрос `get(t)` вида «входит ли в текст t хоть одно словарное слово». Время работы `add(s)` и `del(s)`: $\mathcal{O}(|s| \log L)$, время работы `get(t)`: $\mathcal{O}(|t| \log L)$ (L – суммарная длина всего).

4. (3) Три вхождения

Дана строка s . Найти число строк t таких, что они имеют хотя бы 3 непересекающихся вхождения в строку s .