Второй курс, осенний семестр 2021/22
Практика по алгоритмам #7

Строки (база, хеши)

21 октября

Собрано 19 октября 2022 г. в 12:48

Содержание

Строки (база, хеши)

Разрешается пользоваться только префикс-функцией, Z-функцией, хешами.

Суффиксный массив – отсортированный массив суффиксов строки.
Каждый суффикс кодируется позицией начала.

1. **gcd – тоже период!**

   Период строки s – число x: s – префикс $\texttt{s[0:x)}^\infty$.
   Период называется *целым*, если $x \mid |s|$.
   Пусть у строки s есть периоды $a, b \leqslant \frac{|s|}{2}$. Докажите, что $\gcd(a, b)$ – тоже период.

2. **В поисках периода (и целого, и вещественного!)**

   a) Найти кратчайший период строки тремя способами: π-функции, Z-функция, хеши.
   b) Найти все периоды строки.

3. **Подсчёт различных подстрок**

   a) Найти число различных подстрок строки. $\mathcal{O}(n^2)$. Два способа: Z-функция, хеши.
   b) Найти подстроку данной строки, встречающуюся максимальное число раз.
   c) Найти подстроку данной строки длины ровно k, встречающуюся максимальное число раз.
   d) Возьмём последнее решение. Какова вероятность коллизии?

4. **Суффиксный массив и сортировки**

   Даны строка s. Постройте её суффиксный массив.

   a) $\mathcal{O}(n^2 \log n)$.
   b) $\mathcal{O}(n \log^2 n)$.
   c) Что оптимальнее использовать: `sort` или `stable_sort`?

5. **Позиция строки в суффиксном массиве**

   Найти позицию строки в ее суффиксном массиве. Два способа: Z-функция, хеши.

6. **k-й суффикс**

   Найти k-й в лексикографическом порядке суффикс строки.

   a) $\mathcal{O}(n \log^2 n)$.
   b) $\mathcal{O}(n \log n)$.

7. **Поиск с одной ошибкой**

   Научиться искать образец в строке, если допустимо различие в один символ между образцом и найденной подстрокой.

8. **Поиск с перестановками символов и алфавита**

   Найти образец в строке, если допустимо:

   a) в образце применять к алфавиту перестановку.
   b) в образце переставлять символы.
   c) в образце переставлять и алфавит, и символы.

9. **Наибольшая дважды подстрока**

   Найти наибольшую по длине строку, которая дважды без перекрытий встречается в заданной строке. $\mathcal{O}(n \log n)$.

10. **Палиндромы**

    a) Найти количество подпалиндромов строки. $\mathcal{O}(n \log n)$.
    b) Найти максимальный подпалиндром строки. $\mathcal{O}(n)$.

11. **Восстановление строки по P и Z функциям**

    За $\mathcal{O}(n)$ восстановить строку, если дана ее

    a) Z-функция.
    b) префикс-функция.

12. (*) **Модуль в хешах - 1**

    Задача: $n \leqslant 10^6$ раз сравнить на равенство две подстроки s. Хватит ли `int`-ого хеша?

13. (*) **Модуль в хешах - 2**

    Мы считаем число различных подстрок хешами за $\mathcal{O}(n^2)$, $n \leqslant 1000$. Хватит ли `int`-ого хеша?

14. (*) **Префиксы, представимые в k-$\alpha\beta$-виде**

    Для каждого префикса строки проверить, представим ли он в виде $\alpha\beta\alpha\beta\ldots\alpha$, где α и β – произвольные, возможно пустые, строки, строка β повторяется ровно k раз.

15. (*) **Minimal cyclic shift**

    Найти минимальный циклический сдвиг строки за $\mathcal{O}(n)$.

16. (*) **Контртест к $\langle P, M\rangle$-хешу.**

    Даны число P и модуль M.
    Постройте две различные строки длины до 10 000, имеющие равные $\langle P, M\rangle$-хеши.

    a) $1 \leqslant P < M < 2^{31}$.
    b) $1 \leqslant P < M < 2^{63}$.

Разбор задач практики

1. **gcd – тоже период!**

   $\gcd(a, b) = xa + yb$, у x и y разные знаки. Раз $a + b < |s|$, то в любой точке можно сделать либо `+=` a, либо `-=` b, значит, можно такими прыжками отступить на gcd вперед или назад.

2. **В поисках периода**

   Есть период длины $t \Leftrightarrow s[t, n) = s[0, n - t) \Leftrightarrow$ суффикс, равный префиксу.

   КМП: периоды это $n - p[n], n - p[p[n]], n - p[p[p[n]]], \ldots$,
   ибо $p[n], p[p[n]], \ldots$ – все суффиксы, равные префиксам.
   Z: для каждого t проверить, что $z[t] \geqslant n - t$.
   Хеши: для каждого t проверить, что $s[t, n) = s[0, n - t)$.

3. **Подсчёт различных подстрок**

   a) Хеши: перебираем x, кладем в `unordered_set` хеши всех подстрок длины x, смотрим `size`.
   Z: в позиции i начинается $n-i$ подстрок, вычтем встречавшиеся левее, длины $[1..m[i]]$.

```
vector<int> m(n, 0);
for (int i = 0; i < n; i++):
  auto z = zFunction(s + i);
  answer += n - i - m[i];
  for (int j = i + 1; j < n; j++)
    m[j] = max(m[j], z[j - i]);
```

   В обоих решениях память $\mathcal{O}(n)$, время $\mathcal{O}(n^2)$.

   b) Любой символ самой частой подстроки – тоже самая частая подстрока `:)` Просто ищем самый частый символ.

   c) `unordered_map<uint64_t, int> cnt; cnt[hash(i,i+k)]++;`

   d) Если все подстроки различны, вероятность коллизии $\frac{n^2}{MOD}$.

4. **Суффиксный массив и сортировки**

   `char s[n+1]; int p[n] = {0, 1, 2, 3, ...};`

   a) $\mathcal{O}(n^2 \log n)$ – `sort(p, p + n, cmp1)`. Очень маленькая константа.

   b) $\mathcal{O}(n \log^2 n)$ – `sort(p, p + n, cmp2)`.

```
bool cmp1(int i, int j):
  return strcmp(s + i, s + j) < 0;
bool cmp2(int i, int j):
  int x = LCP(i, j); // бинпоиском с хешами
  return s[i + x] < s[j + x];
```

   `sort` сработает в разы медленнее `stable_sort`.
   `MergeSort` внутри `stable_sort` делает меньше сравнений, чем `QuickSort` внутри `sort`:
   $n \log_2 n - \Theta(n)$ в худшем против $2n \ln n - \Theta(n)$ в среднем.
   На самом деле `sort` = `IntroSort` = `QuickSort` + `HeapSort` + `InsertionSort`, общее время работы меньше `QuickSort`, но число сравнений больше.
   Когда функция сравнения тяжелая, оптимальнее `stable_sort`.

5. **Позиция строки в суффиксном массиве**

Просто сравнить строку с каждым суффиксом. Хешами за $\mathcal{O}(\log n)$ на каждый.
Z: $z[i] = lcp(0, i)$, сравнить первые несовпадающие символы: $s[z[i]]$, $s[i+z[i]]$, $\mathcal{O}(1)$ на суффикс.

6. **k-й суффикс**

   У нас есть компаратор за $\mathcal{O}(\log n)$. Его нужно передать функции `sort` ($\mathcal{O}(n \log n)$ вызовов), либо функции `nth_element` ($\mathcal{O}(n)$ вызовов).

7. **Поиск с одной ошибкой**

   Ищем s в t. Переберем начало вхождения i.
   Чтобы проверить за $\mathcal{O}(1)$, берем LCP $t[i:]$ и s (Z-функция), после LCP одна ошибка.
   Осталось проверить равенство суффиксов (хеши или $z(\overline{s}\#\overline{t})$).

8. **Поиск с перестановками символов и алфавита**

   a) **Можно переставлять алфавит.** Считаем модифицированную префикс-функцию: самый длинный суффикс данной позиции, равный префиксу с точностью до перестановки алфавита. Такой же код, как у обычной префикс-функции, но внутри модифицированное сравнение на равенство. Заведем массив `prev[i]`, предыдущая позиция символа `s[i]`.

```
bool isEqual(int i, int j): // (s[0, i] == s[j - i, j]) <=> (s[i] == s[j])
  if (prev[i] != -1) return s[j] == s[j - (i - prev[i])];
  else return prev[j] < j - i;
```

   Решение #2, хешами. Движемся по тексту окном длины $|s|$. Для каждого символа алфавита c будем поддерживать h_c «хеш множества позиций, где этот символ встречается». Строка найдена, если множества $\{h_c\}$ для строк s и t совпадают. Чтобы проверять это за $\mathcal{O}(1)$, нужно поддерживать для каждого из множеств хеш $H = \sum_c Q^{h_c} \bmod M$.

   b) **В образце s можно переставлять символы.** Идём по тексту, для окна текста длины $|s|$ поддерживаем массив частот `count[char]` и количество совпадений с массивом частот s.

   c) **В образце можно переставлять и алфавит, и символы.** Идём по тексту, для окна поддерживаем массив частот частот `count[count[char]]` и количество совпадений с аналогичной конструкцией для образца.

9. **Наибольшая дважды подстрока**

   Бинарный поиск по ответу. Внутри бинпоиска для каждого хеша подстроки длины x в `unordered_map` запоминаем самое левое и самое правое вхождения подстроки.

10. **Палиндромы**

    В обоих пунктах нужно отдельно решить задачу для чётных и нечётных палиндромов.

    a) Для каждого центра бинпоиском ищем самый длинный палиндром. Сравниваем хешами исходной и развернутой строки.

    b) Перебираем центр, линейным поиском находим самый длинный палиндром, но начинаем поиск с текущего найденного макисмума.

```
answer = 0;
for (int i = 0; i < n; i++)
  while (substr(i - answer, i) == reversed_substr(i, i + answer))
      answer++;
```

11. **Восстановление строки по P и Z функциям**

    И префикс-функция, и Z дают нам набор из $\mathcal{O}(n)$ отрезков $[l_i, r_i)$: $l_i > 0, s[0{:}r_i{-}l_i) = s[l_i : r_i)$.

Двигаемся слева направо по строке, если j-й символ не покрыт ни одним отрезком, делаем `s[j] = cc++`, иначе, он покрыт отрезком $[l_i, r_i)$, делаем `s[j] = s[j - l`$_i$`]`.

12. **(*) Модуль в хешах - 1**

Да. Вероятность провала одного сравнения равна $\frac{1}{M}$, вероятность провала хотя бы одного из n сравнений не больше $\frac{n}{M} \approx 10^{-3}$ для $M = 10^9 + 7$.
Как это увидеть быстро? n сильно меньше M.

Но нет. Если нам будут пытаться мешать, вероятность одного успеха мы умеем оценивать только как $1 - \frac{len}{M}$, вероятность всех успехов $\leqslant (1 - \frac{len}{M})^n \leqslant e^{\frac{-n \cdot len}{M}} \approx 0$.

13. **(*) Модуль в хешах - 2**

Нет. Пусть мы просто все $\frac{n(n-1)}{2}$ хешей положили в `set`.
Получили $\approx \frac{n^4}{8}$ пар хешей, которые должны различаться.
Смотрим на $(1 - \frac{1}{M})^{n^4/8}$, она почти 0. Как это быстро увидеть? $\frac{n^4}{8}$ сильно больше M.

Но да. А если для длин решаем независимо, то для длины $n - k$ есть $\frac{k(k+1)}{2}$ пар, которые должны различаться. Итого $\sum_k \frac{k(k+1)}{2} \approx \frac{n^3}{6}$ сравнений, вероятность провала $\leqslant \frac{n^3}{6M} \approx \frac{1}{6}$.
Правда, если в задаче, как обычно бывает, 20-50 тестов, не зайдёт.

14. **(*) Префиксы, представимые в $\alpha\beta$-виде**

Перебираем $l = |\alpha\beta|$, проверяем $z[l] \geqslant l(k-1)$.
Тогда все префиксы на отрезке $[lk, lk + \min(l, z[lk]))$ $\alpha\beta$-представимы.
Пометить все точки, покрытые отрезками, можно за $\mathcal{O}(n)$.

15. **(*) Minimal cyclic shift**

За $\mathcal{O}(n \log n)$: `ss = s + s; n = |s|; min_element(ss, ss + n, hashComparator)`.

За $\mathcal{O}(n)$: алгоритм Дюваля разложения на простые строки.

16. **(*) Контртест к $\langle P, M \rangle$-хешу.**

Есть решение за $\sqrt{M}$, следующее из парадокса дня рождений.
В этом случае строки достаточно брать длины $\log M$.

Есть более быстрое решение. Рассмотрим строки s и t, $|s| = |t| = n$ над алфавитом $\{a, b\}$.
Тогда $H_{P,M}(s) - H_{P,M}(t) = \sum c_i P^i \bmod M$, где $|c_i| \leqslant 1$. В другую сторону тоже работает – $\forall$ знакопеременной суммы $\sum c_i P^i$, существуют строки s, t.

Решение:

$A_0 =$ `sorted` $\{P^0, P^1, \dots P^{n-1}\}$.
$A_{i+1} =$ `sorted` $\{A_i[1] - A_i[0], A_i[3] - A_i[2], A_i[5] - A_i[4], \dots\}$

Заметим, что по построению $\forall i, j\ A_i[j] \geqslant 0$ и является знакопеременной суммой P^k.

Если $A_i[0] = 0$, то мы нашли $s \neq t$: $H_{P,M}(s) - H_{P,M}(t) = 0$.

Осталось понять, насколько быстро процесс сойдётся и сойдётся ли вообще.
Для этого сделаем кучу смелых предположений.

1. Элементы A_0 – случайные числа в диапазоне $[0, M)$.
   Обозначим за d_i верхнюю границу диапазона, $d_0 = M$.
2. $|A_i| = \frac{n}{2^i} \Rightarrow$ элементы A_{i+1} – случайные в диапазоне $d_i / \frac{n}{2^i}$.
3. Если $n = 2^k$, то получится для A^k получим $|A_k| = 1$.

Мы хотим получить $1 = d_k = M/\left(\prod_{i=1..k} 2^i\right) \Rightarrow \log M = \frac{k(k+1)}{2} \Rightarrow k \approx \sqrt{2 \log M}$.

4. Получили $M \approx 2^{64} \Rightarrow k \approx 11 \Rightarrow$ достаточно $|s| \approx 4000$.

Домашнее задание

3.1. Обязательная часть

1. **(3) Тандемный повтор – 1**

   Тандемным повтором называется строка вида $\alpha\alpha$. Найдите за $\mathcal{O}(n^2)$ самый длинный тандемный повтор. Нужно представить три решения, используя

   a) хеши
   b) Z-функция
   c) предподсчитанный массив `lcp[i,j]`

   За каждое решение вы получите по одному баллу.

2. **(2) Общий подпалиндром**

   Нужно за $\mathcal{O}(n \log n)$ найти максимальный общий подпалиндром двух строк.

3. **(2) Ретростока**

   Для каждого префикса строки найти количество его префиксов равных его суффиксу. $\mathcal{O}(n)$.

4. **(3) Z → КМП**

   Преобразовать Z-функцию в префикс-функцию без промежуточного восстановления строки.

5. **(1) Поиск с ошибкой в алфавите**

   Найти подстроку в тексте.
   При сравнении строк можно делать циклический сдвиг алфавита в одной из них.
   Время решения $\mathcal{O}(n|\Sigma|)$. (+1) допбалл за $\mathcal{O}(n)$.

6. **(2) Поиск с двумя ошибками**

   Найти подстроку в тексте. При сравнении строк, если несовпадений символов было не более двух, строки считаются равными. $\mathcal{O}(n)$.

7. **(2) Поиск с k ошибками**

   Найти подстроку в тексте. При сравнении строк, если несовпадений символов было не более k, строки считаются равными. $\mathcal{O}(nk \log n)$.

3.2. Дополнительная часть

1. **(4) Обезьянка за клавиатурой**

   За одну секунду в конец изначально пустого текста дописывается случайная буква.
   Какое матожидание времени T, когда первый раз s станет подстрокой выписанного текста?
   Решения за полином от $n = |s|$ получат 1 балл. Чтобы получить 3 балла, нужно $\mathcal{O}(n^2)$.

2. **(3) Антихеш тест**

   Даны целые числа p_1, m_1, p_2, m_2. Построить две разных строки, у которых полиномиальные хеши (p_1, m_1) и (p_2, m_2) совпадают. Оба.

3. **(3) Тандемный повтор – 2**

   Решите задачу про тандемный повтор за $\mathcal{O}(n \log n)$ методом разделяй и властвуй.

4. **(3) Покрытие строки**

   Говорят, что строка α покрывает строку s, если каждый символ s покрыт хотя бы одним вхождением α. Иначе говоря, все вхождения α в s, как отрезки, покрывают всю s. Дана s, найти минимальную по длине α, покрывающую s. $\mathcal{O}(n \log n)$.