

Российская академия наук
Национальный комитет по автоматическому управлению
Научный совет по теории управляемых процессов и автоматизации
ОЭММПУ РАН

Институт проблем управления им. В.А. Трапезникова РАН
Министерство образования и науки Удмуртской Республики

Удмуртский государственный университет

Удмуртский НОЦ ПУ (на базе УдГУ)

Волгоградский НОЦ ПУ (на базе ВолГУ)

Воронежский НОЦ ПУ (на базе ВГАСУ)

Инновационный НОЦ ПУ (на базе МАИ)

Казанский НОЦ ПУ (на базе КГТУ-КАИ)

Курский НОЦ ПУ (на базе КГТУ)

Липецкий НОЦ ПУ (на базе ЛГТУ)

НОЦ «Системный анализ в управлении» (на базе МИФИ)

Пермский НОЦ ПУ (на базе ПГТУ)

Самарский НОЦ ПУ (на базе СГАУ)

Тверской НОЦ ПУ (на базе ТГТУ)

Старооскольский НОЦ ПУ (на базе СТИ)

Удмуртский Совет ИТ-директоров

Институт логики, когнитологии и развития личности РАН

VI Всероссийская

школа-семинар

молодых ученых

Управление большими системами

посвящается памяти А.А. Маркова

Том 1



31 августа – 5 сентября 2009

г. Ижевск

УДК 007

VI Всероссийская школа-семинар молодых ученых «Управление большими системами»: Сборник трудов. – Т1.- Ижевск: ООО Информационно-издательский центр «Бон Анца», 2009. – 400 с.

В первый том сборника трудов включены научные статьи молодых ученых по фундаментальным основам теории управления, вопросам управления организационными и социально-экономическими системами, управлению качеством.

ISBN 978-5-903140-57-2

Научное издание осуществлено при поддержке РФФИ
грант № 09-07-06039г

© Авторы, постатейно, 2009
©ООО ИИЦ «Бон Анца»
(оформление обложки, верстка)

Блочное построение суффиксного массива

Айткулов П.Г.

Удмуртский государственный университет, г. Ижевск

Аннотация

В статье строится алгоритм блочного построения суффиксного массива с асимптотикой $O(n \log^2(n))$. К существующему суффиксному массиву добавляется минимальная строка, не входящая в текущий суффиксный массив. Как побочное действие, на каждом шаге поддерживается *lcp*.

Ключевые слова: сопоставление строк, суффиксный массив, динамическое построение суффиксного массива, строковые алгоритмы.

Abstract

An algorithm for incremental constructing suffix array in $O(n \log^2(n))$ in worst case is described here. This algorithm adds a string (a minimal string which doesn't contained in suffix array) to the existing suffix array and updates supplementary data structures. As side effects on every iteration we have *lcp*-array (longest common prefix).

Keywords: string matching, suffix array, dynamic construction suffix array, string algorithm.

Введение

Суффиксный массив строки определяется как перестановка, выражающая лексикографический порядок всех суффиксов строки. Суффиксный массив представляет собой компактное представление суффиксного дерева. Суффиксные массивы имеют массу приложений в задачах поиска образца в строке, биоинформатике [10], сжатии данных [4]. Имеются алгоритмы построения суффиксного массива за $O(n)$ [3], распределенные алгоритмы [6], [7].

Для существующих алгоритмов построения суффиксных массивов требуется наличие всей входной строки. Это ограничивает использование суффиксных массивов в задачах с потоковыми данными.

В статье построен алгоритм блочного построения суффиксного массива с асимптотикой $O(n \log^2(n))$ для наихудшего случая, приспособленный для применения к частично заданной строке.

1. Концепция приложения

Пусть дана строка s . Суффиксный массив строки s обозначим как sa . К строке s мы добавляем новый блок ns . Необходимо получить суффиксный массив для объединенной строки $s ++ ns$. Здесь и далее символ $++$ означает конкатенацию строк, а символ $+$ будет использоваться только

в арифметическом смысле. Введем обозначение $l = |s|$, $k = |ns|$, где $|s|$ – длина строки s . Запись $s[i..j]$ обозначает подстроку s , начинающуюся с символа с индексом i по символ с индексом j . Запись $s[i..]$ является сокращением для суффикса $s[i..|s|]$.

2. Построение алгоритма

В качестве ns выберем блок такого размера, чтобы строка ns была минимальной строкой, еще не входящей в текущий суффиксный массив. Такой выбор блока ns важен, объяснение выбора будет изложено ниже.

Рассмотрим, что происходит при добавлении строки ns к существующему суффиксному массиву sa строки s . Ко всем суффиксам приписываем строку ns . Некоторые суффиксы могут изменить свое положение относительно существующих. Необходимо также добавить в суффиксный массив sa все суффиксы строки ns .

Шаг 1. Ко всем суффиксам приписать строку ns .

Поддерживать отсортированный порядок в суффиксном массиве.

Шаг 2. В суффиксный массив добавить все суффиксы строки ns .

При построении алгоритма нам потребуется такая дополнительная структура данных, как массив наибольшего общего префикса (lcp , longest common prefix). Значением i -го элемента массива lcp определяется как длина общего префикса между суффиксами sa_i и sa_{i+1} .

Наша задача состоит в реализации алгоритма со сложностью меньше квадратичной. Очевидная реализация первой части алгоритма (прямое приписывание строки ns , попарное сравнение суффиксов, сравнение двух суффиксов за линейное время, перемещение одного суффикса за линейное время) не удовлетворяет требованиям сложности. Покажем, как можно эффективно реализовать эту часть алгоритма.

Лемма 1.

Пусть дан суффиксный массив sa . При приписывании новой строки ns ко всем суффиксам суффиксного массива sa свое местоположение могут менять только суффиксы, для которых выполнено $lcp_i = |sa_i|$.

Доказательство.

Утверждение $lcp_i < |sa_i|$ означает, что $lcp_i < |sa_{i+1}|$; поэтому добавление строки ns не изменит лексикографический порядок суффиксов sa_i и sa_{i+1} .

Утверждение $lcp_i = |sa_i|$ также означает, что $lcp_i < |sa_{i+1}|$, и весь суффикс sa_i является префиксом для суффикса sa_{i+1} . В зависимости от добавляемой строки ns можно получить: $sa_i + ns > sa_{i+1} + ns$, $sa_i + ns < sa_{i+1} + ns$ и $sa_i + ns = sa_{i+1}[1..|sa_i| + |ns|]$ (в зависимости от отношения ns и $sa_{i+1}[|sa_i| + 1..]$). ■




Рис. 1. Добавление новой строки изменяет положение суффиксов, только если $lcp_i = |sa_i|$

Из леммы следует, что для работы первой части алгоритма достаточно обработать суффиксы, для которых верно $lcp_i = |sa_i|$. Будем хранить эту информацию в массиве *bo* (от *bool* (булевский) и *boundary* (граница)).

Покажем, как определить отношение порядка для суффикса относительно следующего, для которого верно, что $lcp_i = |sa_i|$, после того как приписать к обоим суффиксам строку *ns*.

Вместо сравнения за линейное время предложим следующее. Сравнение можно разбить на следующие две части: сравнение между $ns[L..|sa_{i+1}| - |sa_i|]$ и $sa_{i+1}[|sa_i| + 1..]$, а также $ns[|sa_{i+1}| - |sa_i| + 1..]$ и *ns*.




Рис. 2. Сравнение суффиксов разбивается на два сравнения

Первое сравнение $ns[L..|sa_{i+1}| - |sa_i|]$ и $sa_{i+1}[|sa_i| + 1..]$ (обозначим как $\delta_{i,i+1}$) есть лексикографическое сравнение префикса *ns* и $\delta_{i,i+1}$. Так как во второй части алгоритма потребуется вставлять все суффиксы строки *ns* в суффиксный массив (и саму строку *ns* тоже), то вставим в суффиксный массив строку *ns* (так же поддерживаем значение *lcp*-массива). Тогда указанное сравнение сводится к поиску местоположения суффикса $\delta_{i,i+1}$ и сравнению местоположения *ns*.

Если $\delta_{i,i+1}$ совпадает с префиксом *ns*, то необходимо выполнить оставшуюся проверку $ns[|sa_{i+1}| - |sa_i| + 1..]$ и *ns*, что равносильно задаче о сравнении строки с собственным суффиксом. Такое сравнение потребуется для различных суффиксов строки *ns*, поэтому построим для строки *ns* суффиксный массив за линейное время [3]. Тогда задача сводится к сравнению местоположений суффикса строки *ns* и самой строки *ns* в суффиксном массиве для строки *ns*.

То есть мы можем сравнивать два суффикса без полного сравнения строк. Точные оценки алгоритмической сложности приводятся в последующих параграфах.

Если $sa_i + ns > sa_{i+1} + ns$, то необходимо переместить суффикс $sa_i + ns$ на новое место. Для определения нового местоположения суффикса $sa_i + ns$ воспользуемся следующей леммой.

Лемма 2.

Пусть дан суффиксный массив sa , массив lcp для суффиксного массива sa . К суффиксу sa_i приписали новую строку ns , так что $sa_i + ns > sa_{i+1} + ns$ и $lcp(sa_i + ns, sa_{i+1} + ns) = l$. Тогда для поддержания корректности суффиксного массива sa и структуры lcp необходимо прозвести следующие действия.

- при удалении суффикса $sa_i + ns$ обновить значение $lcp(sa_{i-1}) \leftarrow \min(lcp(sa_{i-1}),$
- при вставке $sa_i + ns$ на новое место позиция определяется как $np = \min\{k | k > i \wedge lcp(sa_i + ns, k) < l\}$.
- модифицировать $lcp[np] \leftarrow lcp[np - 1], lcp[np - 1] \leftarrow l$.

Доказательство.

Согласно свойствам lcp ([8], [5]) имеет место $lcp_{i,j} = \min_{k \in [i, j-1]} lcp_k$.

Откуда следует изменение значение элемента lcp при удалении суффикса.

Исходя из определения lcp определяется место для вставки суффикса (ближайшая позиция k , для которой $lcp_k < l$). На отрезке $[i + 1, k]$ вставить суффикс $sa_i + ns$ нельзя, так как на этом отрезке имеется общий префикс). ■

lcp suffixes

1 a
3 ana
0 anana
0 banana
2 na
- nana

lcp suffixes

1 a
3 ananaz
0 anaz
0 banana
2 na
- nana

Рис. 3. Ко второму и третьему суффиксу добавили символ «z»

Для того чтобы воспользоваться Леммой 2, необходимо получить значение $lcp(sa_i + ns)$. Это значение получим на этапе сравнения суффиксов. При первой части сравнения (префикс ns и некоторый суффикс sa) значение lcp получается при поиске в текущем суффиксном массиве sa . Если потребуется вторая часть сравнения (некоторый суффикс строки ns и сама строка ns), то значение lcp определяется из суффиксного массива для строки ns (lcp строится за линейное время от длины строки [5]).

Перейдем ко второй части алгоритма, вставке в суффиксный массив всех суффиксов добавляемой строки *ns*. Очевидная реализация (для каждого суффикса строки *ns* найти местоположение в текущий суффиксный массив за $O(k + \log(n))$ [8]) данной части алгоритма приводит к квадратичной сложности.

Строка *ns* уже была добавлена в суффиксный массив на предыдущем шаге. Осталось добавить все собственные суффиксы строки *ns*. Напомним, что мы выбрали *ns* так, чтобы строка была минимальной, еще не входящей в суффиксный массив *sa*. Это означает, что строка *ns*[1..*ns*] – 1 присутствует в суффиксном массиве. Так же это означает, что для всех суффиксов строки *ns* после вставки в суффиксный массив будет выполнено $lcp(ns_{suffix}) = |ns_{suffix}| \vee lcp(ns_{suffix}) = |ns_{suffix}| - 1$ (так как за исключением последнего символа подсуффикс уже содержится в суффиксном массиве).

sa suffixes		
a	<u>az</u>	2 anananaz
ana		4 ananaz
anana		6 anaz
banana	<u>naz</u>	1 banananaz
na		3 nananaz
nana		5 nanaz

ns = "naz" inv_sa = 4 1 5 2 6 3

Рис. 4. К суффиксному массиву для слова «banana» добавляем строку «naz»

sa suffixes		
a	<u>aa</u>	6 anaa
ana		4 ananaa
anana		2 anananaa
banana	<u>naa</u>	1 banananaa
na		5 nanaa
nana		3 nananaa

ns = "naa" inv_sa = 4 3 6 2 5 1

Рис. 5. К суффиксному массиву для слова «banana» добавляем строку «naa»

Найдем положение суффикса, префикс которого совпадает с $ns[2..|ns|-1]$. Если таких суффиксов несколько, то выберем лексикографически наименьший. Обозначим местоположение такого суффикса как $pos_{ns,2}$. Тогда вставлять $ns[2..]$ надо перед позицией $pos_{ns,2}$ (в зависимости от последнего символа ns , возможно $ns[2..]$ надо будет переместить по аналогии с перемещением суффикса в первой части алгоритма). Для перехода к $ns[3..]$ можно не искать местоположение как на предыдущей итерации. Достаточно перейти к суффиксу, чья длина на 1 меньше суффикса $sa_{pos_{ns,2}}$, и произвести аналогичные операции.

Для перехода к суффиксам нужной длины будем поддерживать массив (обозначим как inv_{sa}), являющийся обратной перестановкой к суффиксному массиву sa (при любой операции вставки, удаления из sa производим аналогичную над inv_{sa}).

Теперь осталось только добавить в суффиксный массив еще один суффикс, а именно $ns[|ns|]$.

2.1. Описание алгоритма

```

1  procedure Preprocessing
2  Создание lcp.
3  Создание bo.
4  Создание RMQ.
5  Создание  $inv_{sa}$ .
   end procedure
procedure AddString(string  $ns$ )
6  Построение суффиксного массива для  $ns$  ( $sa_{ns}$ )
7  Вставка в суффиксный массив  $sa$  строку  $ns$ .
8  Обновление lcp.
9  Для всех суффиксов  $sa_i$ , помеченных  $bo_i$ 
10     Сравнение  $sa_i + ns$  и  $sa_{i+1} + ns$ .
11     Вычисление  $lcp(sa_i + ns, sa_{i+1} + ns)$ .
12     Если  $sa_i + ns > sa_{i+1} + ns$ , то
13         перемещение  $sa_i + ns$ , обновление значения lcp
14     иначе
15         обновление значений lcp.
16  Очистка массива bo
17  Поиск местоположения суффикса, префикс которого
    совпадает с  $ns[2..|ns|-1]$ 
18  For  $i$  in  $|ns|-1$  downTo 2 do
19     Вставка суффикса  $ns[|ns|-i+1..]$ 

```

```
20      Обновление lcp
21      Обновление bo
22      Вставка ns[|ns|]
23      Обновление lcp
24      Обновление bo
      end procedure
```

2.2. Структуры данных

Заметим, что в алгоритме используются операции вставки и удаления элементов из линейной структуры. Операции вставки и удаления в линейном массиве или списке требуют $O(n)$ операций. Будем использовать структуру данных (основанную, например, на красно-черном дереве или AVL-дереве [11]) с доступом к элементу и операцией вставки, удаления за время $O(\log(n))$.

Для вычисления $lcp(i, j)$ найдем минимальное значение на отрезке lcp_k , $k \in [i, j-1]$, [8]. На массиве постоянного размера за время препроцессинга $O(n \log(n))$ и время запроса $O(\log(n))$ можно решить задачу при помощи дерева отрезков [12]. Использование дерева отрезков также позволяет решать расширенную задачу с возможностью модификации значений элементов массива (время препроцессинга и запроса прежние, время на модификацию значения равно $O(\log(n))$).

Так как нам необходимо производить операции вставки и перемещения элемента, то дерево отрезков использовать нельзя. В качестве решения воспользуемся [1]. В работе используется структура данных, основанная на сбалансированном дереве, позволяющая вставлять, перемещать, модифицировать элемент и искать минимум на отрезке за $O(\log(n))$ операций.

2.3. Структуры данных

Оценим алгоритмическую сложность построенного алгоритма.

На строке 6 (построение суффиксного массива для строки *ns*) требуется $O(k)$ операций [5].

На строке 7 (вставка в суффиксный массив *sa* строки *ns*) потребуется $O(k + \log(n))$ на вставку [8]. Строка 8 затратит $O(n)$ операций (линейный подсчет *lcp* для вставленного и предыдущего элемента. Можно быстрее, но ускорение на данном шаге не улучшит общую асимптотику алгоритма).

Сравнение и вычисление lcp (10–11 строки) разбивается на два подсравнения. Оба сравнения вычисление lcp происходит за $O(\log(n))$ (сравнение индексов в соответствующих суффиксных массивах, вычисление lcp как запрос к структуре RMQ) [1, 8].

В случае перемещения суффикса sa_i (строка 13) для поиска нового положения необходимо вычислить $\min\{k | k > i \wedge lcp(sa_i + +ns, k) < lcp\}$. Применим бинарный поиск для поиска минимума на отрезке $[i + 1, x]$ по аргументу x . Тогда поиск нового положения суффикса займет $\log^2(n)$ (бинарный поиск и вычисление lcp).

Обновление значений lcp на строках 13, 15 занимает $O(1)$ (Лемма 2).

Так как число суффиксов, помеченных bo , может достигать $O(n)$, то блок 9–15 строки выполняется за $O(n \log^2(n))$.

Так как ns является строкой, не входящей в качестве подстроки в s , то после приписывания ко всем суффиксам новой строки ns не будет суффикса, для которого верно $|sa_i| = lcp$. На строке 16 очистим массив bo за $O(1)$.

Вставка всех суффиксов строки ns занимает $O(k \log^2(n))$. Так как поиск первоначального места (строка 17) требует $O(k + \log(n))$ ([8]), тело цикла (строки 19–21) выполняется за $O(\log^2(n))$, а количество итераций цикла составляет $O(k)$. Вставка последнего символа строки ns занимает $O(\log(n))$ операций.

Сложность всего алгоритма составляет $O(n \log^2(n))$.

2.4. Препроцессинг

Алгоритм можно использовать для модификации суффиксных массивов, уже построенных другими алгоритмами. Для этого на шаге препроцессинга (строки 1–5) достаточно создать все необходимые дополнительные структуры данных.

Оценим алгоритмическую сложность шага препроцессинга.

Массив lcp строится за $O(n)$ [5].

Массив bo также строится за $O(n)$, линейный проход по всем суффиксам $bo_i \leftarrow (lcp_i == \text{length}(sa_i))$. Заметим, что число помеченных суффиксов может составлять $O(n)$.

Структура RMQ нам требуется при основной работе алгоритма. Построение занимает $O(n \log(n))$ операций [1]. При каждом изменении суффиксного массива sa (вставка или удаление элемента) или массива lcp (изменение значения) необходимо модифицировать структуру RMQ . Это требует $O(\log(n))$ операций [1].

Обратная перестановка для суффиксного массива inv_{sa} строится за линейное время. При каждом изменении суффиксного массива (вставка или удаление элемента) производим аналогичное действие над inv_{sa} .

Общая асимптотика препроцессинга составляет $O(n \log(n))$ операций.

2.5. Оценка использование памяти

В процессе работы алгоритма используются только структуры данных с объемом памяти $O(n)$ (lcp , bo , inv_{sa} , RMQ , суффиксный массив, $[1, 8, 11]$).

3. Недостатки алгоритма

Для добавления одного символа может потребоваться $O(n \log^2(n))$ операций (в случае, если число суффиксов, помеченных bo , составляет $O(n)$). То есть использование линейного алгоритма построения суффиксного массива (например [3]) заново для всей строки асимптотически окажется лучше, чем модификация существующего суффиксного массива алгоритмом блочного построения суффиксного массива.

Этот недостаток не устраним, так как, например, добавление символа « b » к строке « $aa..a$ » «переворачивает» суффиксный массив, что потребует не меньше чем $O(n)$ операций.

4. Преимущества алгоритма

Для работы алгоритма необязательно иметь исходную строку целиком. Это позволяет использовать предложенный алгоритм в задачах с потоковыми данными (например преобразование Барроуза Уилера [2] в базах данных).

В отличие от [9], мы добавляем к суффиксному массиву не один символ, а строку. Это позволяет уменьшить асимптотику от квадратичной до $O(n \log^2(n))$ для наихудшего случая.

Для суффиксного массива (созданный любым другим алгоритмом) можно за время $O(n \log(n))$ построить дополнительные структуры данных lcp , $bool$, RMQ [5], [1] и продолжить его построение предложенным методом.

На каждой итерации алгоритма поддерживается массив lcp . Это можно использовать, например, для поиска наибольшей подстроки. Достаточно хранить значения массива lcp в структуре данных для поддержки максимального значения (например двоичная куча, сбалансированное дерево [11])

Заключение

В статье построен алгоритм блочного построения суффиксного массива с временем работы $O(n \log^2(n))$ и линейным размером памяти. Алгоритм можно использовать для потоковых данных.

Список литературы

1. *Benson Gary, Roderic D.M. Page.* Algorithms in Bioinformatics. Third International Workshop, WABI 2003, Budapest. (Т. Shibuya, I. Kurochkin. Match chaining algorithm for cDNA Mapping).
2. *Burrows M., Wheeler D.* A block sorting lossless data compression algorithm, Technical Report 124, Digital Equipment Corporation, 1994.
3. *Karkkainen Juha and Sanders Peter.* Simple Linear Work Suffix Array Construction, Proceedings of the 30th International Colloquium on Automata, Languages and Programming, LNCS 2719, Springer. P. 943 955, 2003.
4. *Karkkainen Juha.* Fast BWT in Small Space by Blockwise Suffix Sorting. Theoretical Computer Science, 2006.
5. *Kasai T., Lee G., Arimura H., Arikawa S., Park K.* Linear-Time Longest-Common-Prefix Computation in Suffix Arrays and Its Applications. CPM 2001: 181 192.
6. *Kitajima Joao Paulo, Gonzalo Navarro, Berthier Ribeiro and Nivio Ziviani.* Distributed Generation of Suffix Arrays: a Quicksort-Based Approach, Proceedings of the 4th South American Workshop on String Processing, Valparaíso, Chile. P. 53 59, 1997.
7. *Navarro Gonzalo, Kitajima Joao Paulo, Ribeiro Berthier and Ziviani Nivio.* Distributed Generation of Suffix Arrays, Proceedings of the 8th Annual Symposium on Combinatorial Pattern Matching, LNCS 1264. P. 102 115, 1997.
8. *Manber U., Myers G.* Suffix arrays: a new method for on-line string searches // SIAM Journal on Computing 22, 953 948, 1993.
9. *Айткулов П.* Последовательное построение суффиксного массива // Удмуртский вестник (неопубликовано).
10. *Гасфилд Д.* Строки, деревья, последовательности в алгоритмах. СПб.: Невский Диалект; БХВ Петербург, 2003.
11. *Кормен Т., Лейзерсон Ч., Ривест Р.* Алгоритмы: построение и анализ. М.: МЦНМО, 1999.
12. *Препарата Ф., Шеймос М.* Вычислительная геометрия: введение. М.: Мир, 1989.