

О программе “Репетитор”

Д.В. Хмелёв

3 июля 2002

Аннотация

Описание программы “Репетитор” и её алгоритма.

Содержание

1	Введение	1
2	Описание алгоритма	2
2.1	Суффиксное дерево	2
2.2	Максимальных повторений	3
2.3	Нахождение всех леворазнообразных узлов за линейное время	3
2.4	Об упрощениях	4

1 Введение

В июне 2002 года у зарегистрированных авторов Самиздата (<http://zhurnal.lib.ru/>) появилась новая возможность анализа своих текстов: программа Репетитор, которая находит все повторяющиеся подстроки в тексте. В дальнейшем мы будем называть повторяющуюся строку просто *повторением*.

Имеется разумное ограничение на длину повторения: 10 для поэтических текстов и 20 для прозы. Более того, для того, чтобы исключить вывод повторяющихся длинных слов вроде “обороноспособности” для поэзии введено дополнительное ограничение: если имеется повторение длины от 10 до 15, то оно выводится только при наличии двух пробелов, разделяющих слова. Такое ограничение позволяет отлавливать повторения вроде “который сказал” и пр.

Текст предварительно преобразуется в “абзацы”, которые определяются с помощью специального конечного автомата. Новый абзац начинается после пустой строки, или знака препинания, за которым следует перевод строки и пробельный символ. Возможны некоторые отступления от указанного правила. Программа не ищет повторения, пересекающие границу абзаца.

Максимальное количество выдаваемых повторений составляет 3000.

Время работы и требуемая память пропорциональны длине входного текста. В следующем разделе дано описание алгоритма работы программы.

2 Описание алгоритма

Начнём с простейших определений [?]. *Строка* S называется упорядоченный список букв, записанных последовательно слева направо. Под $S[i..j]$ подразумевается *подстрока* строки S , которая начинается с символа с номером i и заканчивается номером j . *Длина* строки S обозначается через $|S|$. Подстрока $S[1..i]$ называется *префиксом* строки S , а подстрока $S[i..|S|]$ называется *суффиксом* строки S .

Например, “Мы все учились понемногу” — это строка, “все учились” — подстрока, “Мы все” — префикс, “понемногу” — суффикс.

$S(i)$ обозначает символ i строки S .

На входе алгоритм получает строку S длины n . Прежде, чем описывать алгоритм необходимо более строго сказать, что имеется ввиду под “повторением”. Точнее, нам следует сначала определить, что какие строки образуют “повторяющуюся пару”. Неправильный выбор определения “повторяющейся пары” может привести к бессмысленно повторяющимся результатам. Например, если вся строка состоит из n повторения строки n , то алгоритм, который ищет “все пары повторяющихся подстрок”, выдаст порядка n^4 пар, что совершенно нежелательно. Поэтому необходимо такое определение, которое каким-то образом отражало бы “максимальность” повторяющейся пары.

Максимальная пара (или максимальная повторяющаяся пара) в строке S есть пара таких одинаковых подстрок α и β , что буквы справа (и слева) от α и β различны. Таким образом, попытка расширить пару направо (налево) приведёт к её разрушению.

Максимальное повторение α есть подстрока S , которая встречается в какой-нибудь повторяющейся паре.

Репетитор ищет все максимальные повторения с использованием *суффиксного дерева*, с которого мы и начнём.

2.1 Суффиксное дерево

Напомним, что деревом называется неориентированный граф без циклов.

Суффиксным деревом T для подстроки S длины n называется дерево с корнем, у которого ровно n листьев, занумерованных числами от 1 до n . У каждой внутренней вершины, отличной от корня и называемой в дальнейшем *узлом*, имеется не меньше двух потомков, а каждое ребро помечено непустой подстрокой S . Метки разных рёбер, исходящих из любого узла (включая корень), начинаются с разных букв. Основной особенностью суффиксного дерева является то, что для любого листа i конкатенация строк на пути от корня к листу i в точности совпадает с суффиксом $S[i..n]$.

Существуют эффективные способы построения суффиксного дерева за время пропорционально длине входного текста с использованием памяти, также пропорциональной длине входного текста [?]. Число узлов (а следовательно, и вершин) в суффиксном дереве пропорционально длине входного текста.

2.2 Максимальных повторений

Используя суффиксное дерево, можно найти все максимальные повторения за время, пропорциональное длине строки. Следующая лемма [?] даёт необходимое условие для того, чтобы какая-либо строка была максимальным повторением.

Лемма 2.1. *Пусть T — суффиксное дерево строки S . Если строка α является максимальным повторением, то она является конкатнацией некоторого рёбер, ведущих к какому-нибудь узлу v в дереве T (узел — это не лист!)*

Доказательство. Если α — максимальное повторение, то оно встречается в S по меньшей мере дважды, причём буква справа от первого употребления α отличается от буквы справа во втором употреблении α . Из определения суффиксного дерева вытекает, что α является меткой пути, ведущей к какому-нибудь узлу. \square

Наложив простое дополнительное требование, можно получить необходимый и достаточный признак максимального повторения.

Для каждой позиции i в строке S обозначим через $S(i-1)$ левую букву суффикса $S[i..n]$. Левая буква листа j в дереве T есть левая буква суффикса $S[j..n]$.

Узел v дерева T называется леворазнообразным если хотя бы два листа в поддереве v отличаются левыми буквами. По определению, листья не являются леворазнообразными.

Заметим, что свойство леворазнообразности распространяется наверх. Если узел v леворазнообразен, то все его предки леворазнообразны.

Теорема 2.2 ([?]). *Строка α , являющаяся меткой пути к узлу v в дереве T является максимальным повторением тогда и только тогда, когда v леворазнообразен.*

2.3 Нахождение всех леворазнообразных узлов за линейное время

Для каждого узла v в дереве T алгоритм либо записывает, что узел v леворазнообразен, либо он записывает букву, которую мы обозначим x , которая является левой буквой всех листов в поддереве v . Вначале алгоритм записывает левые буквы для всех листов суффиксного дерева T . Далее он обходит дерево снизу вверх. Прежде обработки узла v , он рекурсивно вызывается для каждого из потомков

v . Если какой-нибудь из потомков оказывается леворазнообразным, то и v — леворазнообразен. Если ни один из потомков v не леворазнообразен, то сравниваются записанные ранее буквы непосредственных потомков v . Если все они равны, скажем, x , то алгоритм записывает x на узле v . Если же встретились разные буквы, то алгоритм записывает, что v леворазнообразен. Время для проверки, что все сыновья v имеют одинаковую записанную букву, пропорционально их числу, которое не превосходит числа букв в алфавите: а поскольку число узлов линейно по n алгоритм линеен по n .

2.4 Об упрощениях в изложении алгоритма

На самом деле Репетитор ищет повторения для набора абзацев-строк S_1, \dots, S_n и строит суффиксное дерево для всех строк. Это приводит к незначительным усложнениям алгоритма.

Список литературы

- [1] D.Gusfield, *Algorithms on strings, trees, and sequences*. Cambridge University Press, Cambridge, 1997.