Тема лекции:

Алгоритмы поиска в строке

Поиск подстроки в строке — типичная задача поиска информации. На сегодняшний день существует огромное разнообразие алгоритмов поиска подстроки. Программисту приходится выбирать подходящий в зависимости от следующих факторов.

- Нужна ли вообще оптимизация, или хватает примитивного алгоритма? Как правило, именно его реализуют стандартные библиотеки языков программирования.
- «Враждебность» пользователя. Другими словами: будет ли пользователь намеренно задавать данные, на которых алгоритм будет медленно работать?
- Грамматика языка может быть недружественной к тем или иным эвристикам, которые ускоряют поиск «в среднем».
- Архитектура процессора. Некоторые процессоры имеют автоинкрементные или SIMD-операции, которые позволяют быстро сравнить два участка ОЗУ (например, rep cmpsd на x86).
- Размер алфавита. Многие алгоритмы имеют эвристики, связанные с несовпавшим символом. На больших алфавитах таблица символов будет занимать много памяти, на малых — соответствующая эвристика будет неэффективной.
- Возможность проиндексировать исходный текст. Если таковая есть, поиск серьёзно ускорится.
- Требуется ли одновременный поиск нескольких строк? Приблизительный поиск?

ГДЕ ПРИМЕНЯЮТСЯ АЛГОРИТМЫ ПОИСКА В СТРОКЕ?

ГДЕ ПРИМЕНЯЮТСЯ АЛГОРИТМЫ ПОИСКА В СТРОКЕ?

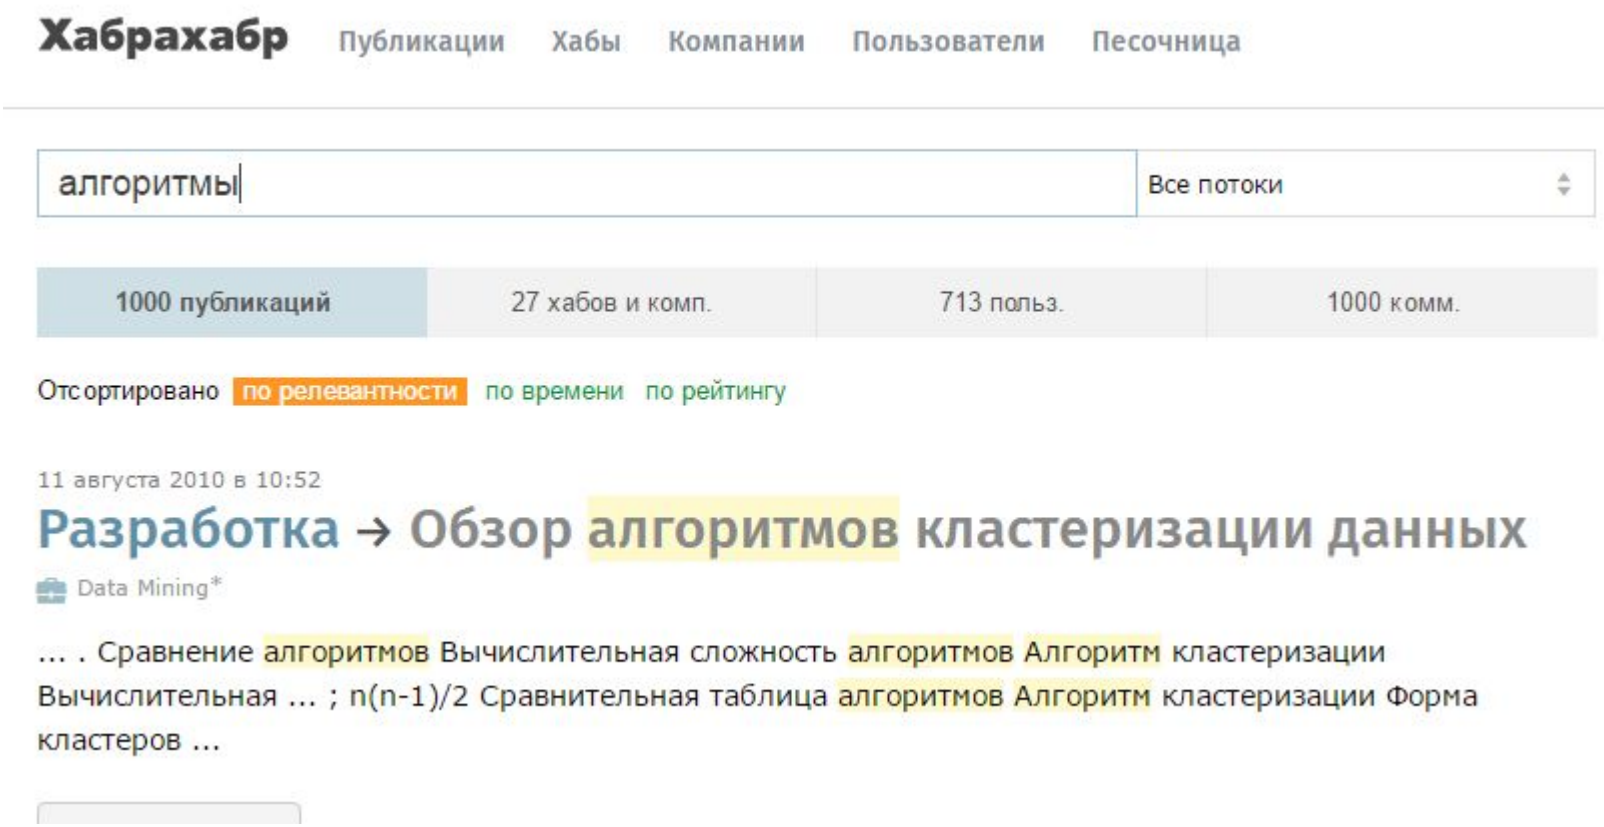

ГДЕ ПРИМЕНЯЮТСЯ АЛГОРИТМЫ ПОИСКА В СТРОКЕ?

DOU ГЛАВНАЯ ФОРУМ ЛЕНТА ЗАРПЛАТЫ РАБОТА КАЛЕНДАРЬ ДЖИНН

алгоритмы

Найдено результатов: примерно 4 650 (за 0,32 сек.)

Насколько важно знать **алгоритмы**? | DOU

5 июн 2016 ... Знание алгоритмов программисту нужно в двух случаях: 1) Он собеседуется в .... Мы ж говорим про алгоритмы, а не про архитектуру.

Обсуждения по теме «**алгоритмы**» | DOU

Обсуждения по теме «алгоритмы». RSS · Сергей Артюх 5 июня 2016. Насколько важно знать алгоритмы? 268 ... Какие алгоритмы нужны в наше время?

Алгоритмы в профессии программиста и можно ли без них ...

21 июн 2016 ... Затем поговорим о том, какие вообще алгоритмы бывают, как они применяются на реальных проектах, и с чего начинать их изучение.

Игра в **алгоритмы** | DOU

Друзья, я разрабатываю игру для изучения базывых алгоритмов - Поиск, сортировка, графы. Очень часто традиционный путь вызывает ...

Книги по **алгоритмам** | DOU

Всім доброї пори дня! Власне цікавлять ваша думка та поради стосовно хороших книг по алгоритмам, а саме: робота з деревами, ...

Обсуждения по теме «**алгоритмы**» | DOU

28 авг 2016 ... Обсуждения по теме «алгоритмы». RSS ... Насколько важно знать алгоритмы ? 268 ... Какие алгоритмы нужны в наше время? 161.

ЛИНЕЙНЫЙ ПОИСК

Линейный, последовательный поиск (***поиск методом полного перебора или брутфорса***) — алгоритм нахождения заданного значения произвольной функции на некотором отрезке.

Данный алгоритм является простейшим алгоритмом поиска и, в отличие, например, от двоичного поиска, не накладывает никаких ограничений на функцию и имеет простейшую реализацию.

Поиск значения функции осуществляется простым сравнением очередного рассматриваемого значения (как правило, поиск происходит слева направо, то есть от меньших значений аргумента к большим) и, если значения совпадают (с той или иной точностью), то поиск считается завершённым.

ЛИНЕЙНЫЙ ПОИСК

В связи с малой эффективностью по сравнению с другими алгоритмами линейный поиск обычно используют, только если отрезок поиска содержит очень мало элементов, тем не менее, линейный поиск не требует дополнительной памяти или обработки/анализа функции, так что может работать в потоковом режиме при непосредственном получении данных из любого источника. Также линейный поиск часто используется в виде линейных алгоритмов поиска максимума/минимума.

Обычно линейный поиск очень прост в реализации и применим, если список содержит мало элементов, либо в случае одиночного поиска в неупорядоченном списке.

Если предполагается в одном и том же списке большое число раз, то часто имеет смысл предварительной обработки списка, например, сортировки и последующего использования бинарного поиска, либо построения какой-либо эффективной структуры данных для поиска. Частая модификация списка также может оказывать влияние на выбор дальнейших действий, поскольку делает необходимым процесс перестройки структуры.

ЛИНЕЙНЫЙ ПОИСК

Условие: дано два массива A и B. Нужно определить, является ли массив A подстрокой (фрагментом) массива B?

A = [3 5 8 12 3];
B = [3 5 17 1 9 3 5 8 12 3 4 9 11 6];

```
z=length(A)-1;
k=length(B)-z;

for i=1:k

  if A==B(i:i+z)
     disp('Да, является.');
  end

end
```

Сложность алгоритма - **O(n*m)**, где n и m – длины массивов A и B

АЛГОРИТМ БОЙЕРА-МУРА

Алгоритм поиска строки Бойера-Мура, считается наиболее быстрым среди алгоритмов общего назначения, предназначенных для поиска подстроки в строке.

Преимущество этого алгоритма в том, что ценой некоторого количества предварительных вычислений над шаблоном (но не над строкой, в которой ведётся поиск) шаблон сравнивается с исходным текстом не во всех позициях — часть проверок пропускаются как заведомо не дающие результата.

Общая оценка вычислительной сложности алгоритма **O(n + m*s)** n – алфавит, m – строка, s – шаблон.

Алгоритм основан на трёх идеях.

1. Сканирование слева направо, сравнение справа налево. Совмещается начало текста (строки) и шаблона, проверка начинается с последнего символа шаблона. Если символы совпадают, производится сравнение предпоследнего символа шаблона и т. д. Если все символы шаблона совпали с наложенными символами строки, значит, подстрока найдена, и поиск окончен.

Если же какой-то символ шаблона не совпадает с соответствующим символом строки, шаблон сдвигается на **несколько** символов вправо, и проверка снова начинается с последнего символа.

АЛГОРИТМ БОЙЕРА-МУРА

2. Эвристика стоп-символа. Предположим, что мы производим поиск слова «колокол». Первая же буква не совпала — «к» (назовём эту букву стоп-символом). Тогда можно сдвинуть шаблон вправо до последней его буквы «к».

```
Строка:           * * * * * * к * * * * * *
Шаблон:           к о л о к о л
Следующий шаг:        к о л о к о л
```

Если стоп-символа в шаблоне вообще нет, шаблон смещается за этот стоп-символ.

```
Строка:           * * * * * а л * * * * * * *
Шаблон:           к о л о к о л
Следующий шаг:                к о л о к о л
```

В данном случае стоп-символ — «а», и шаблон сдвигается так, чтобы он оказался прямо за этой буквой. В алгоритме Бойера-Мура эвристика стоп-символа вообще не смотрит на совпавший суффикс, так что первая буква шаблона («к») окажется под «л», и будет проведена одна заведомо холостая проверка. Если стоп-символ «к» оказался за другой буквой «к», эвристика стоп-символа не работает.

АЛГОРИТМ БОЙЕРА-МУРА

Если стоп-символ «к» оказался за другой буквой «к», эвристика стоп-символа не работает.

```
Строка:           * * * * к к о л * * * * *
Шаблон:             к о л о к о л
Следующий шаг:    к о л о к о л       ?????
```

В таких ситуациях выручает третья идея АБМ — эвристика совпавшего суффикса.

3. Эвристика совпавшего суффикса. Если при сравнении строки и шаблона совпало один или больше символов, шаблон сдвигается в зависимости от того, какой суффикс совпал.

```
Строка:           * * т о к о л * * * * *
Шаблон:           к о л о к о л
Следующий шаг:              к о л о к о л
```

В данном случае совпал суффикс «окол», и шаблон сдвигается вправо до ближайшего «окол». Если подстроки «окол» в шаблоне больше нет, но он начинается на «кол», сдвигается до «кол», и т. д.

АЛГОРИТМ БОЙЕРА-МУРА

Обе эвристики требуют предварительных вычислений — в зависимости от шаблона поиска заполняются две таблицы. Таблица стоп-символов по размеру соответствует алфавиту (например, если алфавит состоит из 256 символов, то её длина 256); таблица суффиксов — искомому шаблону. Именно из-за этого алгоритм Бойера-Мура не учитывает совпавший суффикс и несовпавший символ одновременно — это потребовало бы слишком много предварительных вычислений.

Опишем подробнее обе таблицы.

Таблица стоп-символов

В таблице стоп-символов указывается последняя позиция из строки (**исключая последнюю букву**) каждого из символов алфавита. Для всех символов, не вошедших в строку пишем 0. Например, если строка = ***«abcdadcd»*** , таблица стоп-символов будет выглядеть так

Символ	a	b	c	d	[все остальные]
Последняя позиция	5	2	7	6	0

АЛГОРИТМ БОЙЕРА-МУРА

Таблица суффиксов

Для каждого возможного суффикса *S* шаблона строки указываем наименьшую величину, на которую нужно сдвинуть вправо шаблон, чтобы он снова совпал с *S*. Например, для той же строки ***«abcdadcd»*** будет:

Суффикс	[пустой]	d	cd	dcd	...	abcdadcd
Сдвиг	1	2	4	8	...	8
Иллюстрация						
было	?	?d	?cd	?dcd	...	abcdadcd
стало	abcdadcd	abcdadcd	abcdadcd	abcdadcd	...	abcdadcd

АЛГОРИТМ КНУТА-МОРРИСА-ПРАТТА

Этот алгоритм – в общем случае самый быстрый из алгоритмов поиска подстроки в тексте (на практике алгоритм Боуера-Мура иногда бывает быстрее).

Вычислительная сложность алгоритма равна **O(m+n)**, где m – длина подстроки ***S***, а n – длина текста ***T***. Время работы алгоритма линейно зависит от объёма входных данных, то есть разработать асимптотически более эффективный алгоритм невозможно.

Даны образец (строка) ***S*** и строка ***T***. Требуется определить индекс, начиная с которого образец ***S*** содержится в строке ***T***. Если ***S*** не содержится в ***T*** вернуть индекс, который не может быть интерпретирован как позиция в строке (например, отрицательное число). При необходимости отслеживать каждое вхождение образца в текст имеет смысл завести дополнительную функцию, вызываемую при каждом обнаружении образца.

АЛГОРИТМ КНУТА-МОРРИСА-ПРАТТА

Шаг 1. Построение таблицы префиксов **TB**. **TB** – массив целых чисел длиной m. Объявим его (здесь и далее - синтаксис Матлаба) как TB=zeros(1,m);

Алгоритм построения таблицы префиксов.

Для первой буквы полагаем TB(1)=0;

Для каждого k от 2 до m находим максимальное j, при котором префикс S(1:j) совпадает с суффиксом S(k-j+1:k). Записываем полученное значение j в TB:

TB(k)=j;

Пример 1.

S=‘арарат’; % 6 букв

TB=zeros(1,6); % заполняем нулями таблицу префиксов. TB(1)=0.

k=2. S(1:2) = ‘ар’.

Никакой префикс не совпадает с суффиксом. j=0, TB(2)=0.

k=3. S(1:3)=‘ара’.

Префикс ‘а’ совпадает с суффиксом ‘а’. j=1 (длина совпадения). TB(3)=1.

k=4. S(1:4)=‘арар’;

Префикс ‘ар’ совпадает с суффиксом ‘ар’. j=2. TB(4)=2.

k=5. S(1:5)=‘арара’;

Префикс ‘ара’ совпадает с суффиксом ‘ара’. j=3 (длина совпадения). TB(5)=3.

k=6. S(1:6)=‘арарат’;

Никакой префикс не совпадает с суффиксом. j=0, TB(6)=0.

TB = [0 0 1 2 3 0];

```
% Matlab
% Быстрый алгоритм заполнения таблицы префиксов
% для строки S длиной m:

TB=zeros(1,m);  % TB(1) здесь уже равно 0
j=0;
for k=2:m
  while (j>0)&(S(k)~=S(1+j))
    j=TB(j);
  end
  if S(k)==S(1+j)
    j=j+1;
  end
  TB(k)=j;
end
```

Шаг 2. Быстрый поиск подстроки *S* в тексте *T* с использованием полученной таблицы префиксов *TB*, где *m* – длина *S*, а *n* – длина *T*.

Алгоритм:

1) j=1; i=1;
2) Если S(j) == T(i) то перейти на шаг 3, иначе перейти на шаг 6.
3) i=i+1; j=j+1;
4) Если j>m, значит подстрока в тексте найдена и алгоритм заканчивает работу. Иначе – перейти на шаг 5.
5) Если i>n, значит в тексте вообще нет этой подстроки и алгоритм заканчивает работу. Иначе – перейти на шаг 2.
6) Если j==1, то i=i+1 и перейти на шаг 2, иначе – на шаг 7.
7) j=TB(j-1)+1. Перейти на шаг 2.

Пример

```
   123456789012345
T='оконокнокнокаон'  n=15
S='окнока'           m=6
TB=[0 0 0 1 2 0]

j=1. i=1.
S(1)==T(1) □ j=2. i=2.      S(5)==T(9) □ j=6. i=10.
S(2)==T(2) □ j=3. i=3.      S(6)~=T(10)□ j=TB(6-1)+1=3
S(3)~=T(3) □ j=TB(3-1)+1=1.S(3)==T(10)□ j=4. i=11.
S(1)==T(3) □ j=2. i=4.      S(4)==T(11)□ j=5. i=12.
S(2)~=T(4) □ j=TB(2-1)+1=1.S(5)==T(12)□ j=6. i=13.
S(1)~=T(4) □ j==1 □ i=5.S(6)==T(13)□ j=7. i=14.
S(1)==T(5) □ j=2. i=6.      j>m □ подстрока найдена
S(2)==T(6) □ j=3. i=7.      в позиции i-m = 8
S(3)==T(7) □ j=4. i=8.
S(4)==T(8) □ j=5. i=9.
```

Алгоритм Рабина-Карпа

Нужно определить, входит ли хотя бы одна из N строк S_i (каждая из них одинаковой длины L) в текст T (длины M).

1) Вычисляем хэш-функции от каждой строки S_i (например, контрольную сумму).
2) Перебираем в цикле все подстроки T длины L.
3) Для каждой такой подстроки вычисляем хэш-функцию.
4) Сравниваем значение хэш-функции с значениями хэш-функций всех строк S_i.
5) Только если есть совпадение хэш-функций, то тогда сравниваем эту подстроку T с той строкой S_i, для которой было совпадение.

Таким образом, экономится время (сложность **O(L*M/N)**