Алгоритм Ахо-Корасик

29 ноября 2021 г. 2:38

Алгоритм Ахо — Корасик

Пётр Смирнов

ВШЭ

29 ноября 2021 года

Бор как Map

Бор (aka префиксное дерево, aka trie) — реализация интерфейса Set/Map для ключей-строк

```
class Node:
  def __init__(self):
    # Алфавит = {0, 1, ..., 25}
    self.next = [None] * 26
    self.value = None

root = Node()
```


Бор как Map

Бор (aka префиксное дерево, aka trie) — реализация интерфейса Set/Map для ключей-строк

```
class Node:
  def __init__(self):
    # Алфавит = {0, 1, ..., 25}
    self.next = [None] * 26
    self.value = None

root = Node()
def set(S, value):
  cur = root
  for c in S:
    if cur.next[c] is None:
      cur.next[c] = Node()
    cur = cur.next[c]
  cur.value = value
```


Бор как Map

Бор (aka префиксное дерево, aka trie) — реализация интерфейса Set/Map для ключей-строк

```
class Node:
  def __init__(self):
    # Алфавит = {0, 1, ..., 25}
    self.next = [None] * 26
    self.value = None

root = Node()
def set(S, value):
  cur = root
  for c in S:
    if cur.next[c] is None:
      cur.next[c] = Node()
    cur = cur.next[c]
  cur.value = value
```

```
def get(S):
  cur = root
  for c in S:
    if cur.next[c] is None:
      return None
    cur = cur.next[c]
  return cur.value
```


Бор как Set

```
class Node:
  def __init__(self):
    # Алфавит = {0, 1, ..., 25}
    self.next = [None] * 26
    self.value = False

root = Node()
def add(S):
  cur = root
  for c in S:
    if cur.next[c] is None:
      cur.next[c] = Node()
    cur = cur.next[c]
  cur.value = True
```

```
def get(S):
  cur = root
  for c in S:
    if cur.next[c] is None:
      return False
    cur = cur.next[c]
  return cur.value
```


Бор как Set

```
class Node:
  def __init__(self):
    # Алфавит = {0, 1, ..., 25}
    self.next = [None] * 26
    self.value = False

root = Node()
def add(S):
  cur = root
  for c in S:
    if cur.next[c] is None:
      cur.next[c] = Node()
    cur = cur.next[c]
  cur.value = True
```

```
def get(S):
  cur = root
  for c in S:
    if cur.next[c] is None:
      return False
    cur = cur.next[c]
  return cur.value
```

Вершины с `value = True` будем называть *терминальными*

Поиск словарных слов

Задача

Дано множество (словарь) шаблонов (словарных слов) $s_1, \ldots, s_k$ и текст T. Найти вхождение хотя бы одного шаблона в текст.

- Уже получили алгоритм за $\mathcal{O}(|\Sigma| \cdot \sum_i |s_i| + |T| \cdot \max_i |s_i|)$
- Можно хранить переходы в хеш-таблице, тогда получим $\mathcal{O}(\sum_i |s_i| + |T| \cdot \max_i |s_i|)$
- Но хотим быстрее

Поиск словарных слов

Задача

Дано множество (словарь) шаблонов (словарных слов) $s_1, \ldots, s_k$ и текст T. Найти вхождение хотя бы одного шаблона в текст.

- Уже получили алгоритм за $\mathcal{O}(|\Sigma| \cdot \sum_i |s_i| + |T| \cdot \max_i |s_i|)$
- Можно хранить переходы в хеш-таблице, тогда получим $\mathcal{O}(\sum_i |s_i| + |T| \cdot \max_i |s_i|)$
- Но хотим быстрее
- Алгоритм Ахо — Корасик (Альфред Ахо, Маргарет Корасик, 1975)
- Идея та же, что в КМП: поддерживаем наибольший суффикс уже прочитанного текста, который совпадает с префиксом *какого-нибудь* словарного слова
- Но сначала надо сложить словарь в удобную структуру данных — бор

Алгоритм КМП

```
S = pattern + '$' + text

k = 0
# Нумерация символов с единицы
for i = 1..len(S):
  while k > 0 and S[i] != S[k + 1]:
    k = p[k]
  if S[i] == S[k + 1]:
    ++k
  p[i] = k
```

Число `k` — длина максимального суффикса уже прочитанного текста, совпадающего с префиксом шаблона

ababa $ abbab

Алгоритм Ахо — Корасик, схема

```
for pattern in patterns:
  add(pattern)

cur = root
for c in text:
  cur = go(cur, c)
  if '''cur соответствует вхождению''':
    # обнаружено вхождение
```

`cur` — вершина бора, соответствующая суффиксу уже прочитанного текста, совпадающему с максимальным префиксом какого-нибудь из шаблонов

Осталось:

- написать функцию *go*
- понять, когда `cur` соответствует вхождению

Суффиксные ссылки

- Суффиксные ссылки — обобщение префикс-функции
- Каждой вершине v бора соответствует строка по пути от корня до v, обозначим её $path(v)$

Определение

Пусть T — бор, v — вершина в нём. *Суффиксная ссылка* v ($suf(v)$) указывает на вершину u бора такую, что:

- $u \neq v$
- $path(u)$ является суффиксом $path(v)$;
- $|path(u)|$ максимальна

Для корня бора суффиксная ссылка не определена, поэтому удобно добавить фиктивный корень.

Наивная реализация *suf* и *go*

```
class Node:
  def __init__(self, parent, char):
    self.next = [None] * 26
    self.value = False
    self.parent = parent
    self.char = char
fake_root = Node(None, '')
root = Node(fake_root, '')
fake_root.next = [root] * 26
```

Наивная реализация *suf* и *go*

```
class Node:
  def __init__(self, parent, char):
    self.next = [None] * 26
    self.value = False
    self.parent = parent
    self.char = char
fake_root = Node(None, '')
root = Node(fake_root, '')
fake_root.next = [root] * 26
def suf(node):
  if node == root:
    return fake_root
  cur = suf(node.parent)
  while cur.next[node.char] is None:
    cur = suf(cur)
  return cur.next[node.char]
```


Наивная реализация *suf* и *go*

```
class Node:
  def __init__(self, parent, char):
    self.next = [None] * 26
    self.value = False
    self.parent = parent
    self.char = char
fake_root = Node(None, '')
root = Node(fake_root, '')
fake_root.next = [root] * 26
def suf(node):
  if node == root:
    return fake_root
  cur = suf(node.parent)
  while cur.next[node.char] is None:
    cur = suf(cur)
  return cur.next[node.char]
```

```
def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```

За счёт добавления фиктивного корня код работает и для случая, когда максимальный суффикс пуст.

Наивная реализация *suf* и *go*

```
class Node:
  def __init__(self, parent, char):
    self.next = [None] * 26
    self.value = False
    self.parent = parent
    self.char = char
fake_root = Node(None, '')
root = Node(fake_root, '')
fake_root.next = [root] * 26
def suf(node):
  if node == root:
    return fake_root
  cur = suf(node.parent)
  while cur.next[node.char] is None:
    cur = suf(cur)
  return cur.next[node.char]
```

```
def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```

За счёт добавления фиктивного корня код работает и для случая, когда максимальный суффикс пуст.

Корректность — как в префикс-функции.

suf через *go*

```
def suf(node):
  if node == root:
    return fake_root
  cur = suf(node.parent)
  while cur.next[node.char] is None:
    cur = suf(cur)
  return cur.next[node.char]
```

```
def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```


suf через *go*

```
def suf(node):
  if node == root:
    return fake_root
  cur = suf(node.parent)
  while cur.next[node.char] is None:
    cur = suf(cur)
  return cur.next[node.char]
```

```
def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```

Как посчитать *suf*, используя *go*?

suf через *go*

```
def suf(node):
  if node == root:
    return fake_root
  cur = suf(node.parent)
  while cur.next[node.char] is None:
    cur = suf(cur)
  return cur.next[node.char]
```

```
def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```

Как посчитать *suf*, используя *go*?

```
def suf(cur):
  if node == root:
    return fake_root
  return go(suf(node.parent), node.char)
```


go через *suf* и *go*

```
def suf(cur):
  if node == root:
    return fake_root
  return go(suf(node.parent), node.char)

def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```


go через *suf* и *go*

```
def suf(cur):
  if node == root:
    return fake_root
  return go(suf(node.parent), node.char)

def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```

Напишем *go* рекурсивно:

go через *suf* и *go*

```
def suf(cur):
  if node == root:
    return fake_root
  return go(suf(node.parent), node.char)

def go(cur, c):
  while cur.next[c] is None:
    cur = suf(cur)
  return cur.next[c]
```

Напишем *go* рекурсивно:

```
def go(cur, c):
  if cur.next[c] is None:
    return go(suf(cur), c)
  return cur.next[c]
```


Итоговая версия

Добавим мемоизацию:

```
root.suf = fake_root
def suf(cur):
  if cur.suf is None:
    cur.suf = go(suf(node.parent), node.char)
  return cur.suf

def go(cur, c):
  if cur.go[c] is None:
    if cur.next[c] is None:
      cur.go[c] = go(suf(cur), c)
    else:
      cur.go[c] = cur.next[c]
  return cur.go[c]
```


Итоговая версия

Добавим мемоизацию:

```
root.suf = fake_root
def suf(cur):
  if cur.suf is None:
    cur.suf = go(suf(node.parent), node.char)
  return cur.suf

def go(cur, c):
  if cur.go[c] is None:
    if cur.next[c] is None:
      cur.go[c] = go(suf(cur), c)
    else:
      cur.go[c] = cur.next[c]
  return cur.go[c]
```

Корректность: всегда обращаемся к вершинам, которые находятся выше текущей.

Замечания по подсчёту *go* и *suf*

- Мемоизацию в Python можно делать с помощью `@functools.cache` (но константа времени работы будет больше)
- Можно пойти другим путём: убрать функции, обойти бор BFS-ом и подсчитывать значения `suf` и `go[]`.

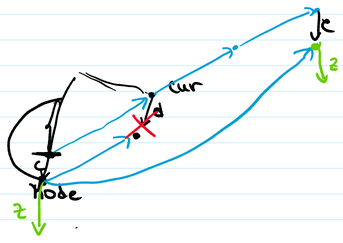

Подсчёт всех suf(v) и всех go(v,c) $\forall v, c$ работает за время $O(V \cdot |\Sigma|)$

@functools.lru_cache(maxsize=None)

Замечания по подсчёту *go* и *suf*

- Мемоизацию в Python можно делать с помощью `@functools.cache` (но константа времени работы будет больше)
- Можно пойти другим путём: убрать функции, обойти бор BFS-ом и подсчитывать значения `suf` и `go[]`.

@functools.lru_cache(maxsize=None)

Алгоритм Ахо — Корасик, схема

Вернёмся к схеме алгоритма:

```
for pattern in patterns:
  add(pattern)

cur = root
for c in text:
  cur = go(cur, c) # работает за "O(1)"
  if '''cur соответствует вхождению''':
    # обнаружено вхождение
```

суммарно отработает за $O(v \cdot |\Sigma| + |text|)$

Осталось:

- понять, когда `cur` соответствует вхождению

Вхождение словарного слова

Определение

$sufpath(v) = \{v, suf(v), suf(suf(v)), \ldots, \texttt{root}\}$. Иначе говоря, $sufpath(v) = \{v\} \cup sufpath(suf(v))$ для $v \neq \texttt{root}$ и $sufpath(\texttt{root}) = \{\texttt{root}\}$.

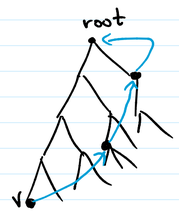

Вхождение словарного слова

Определение

$sufpath(v) = \{v, suf(v), suf(suf(v)), \ldots, \texttt{root}\}$. Иначе говоря, $sufpath(v) = \{v\} \cup sufpath(suf(v))$ для $v \neq \texttt{root}$ и $sufpath(\texttt{root}) = \{\texttt{root}\}$.

Утверждение

cur соответствует вхождению ⇔ на суффиксном пути cur есть терминальная вершина.

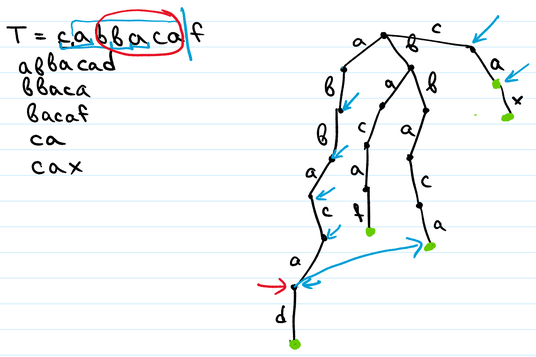

Вхождение словарного слова

Определение

$sufpath(v) = \{v, suf(v), suf(suf(v)), \ldots, \texttt{root}\}$. Иначе говоря, $sufpath(v) = \{v\} \cup sufpath(suf(v))$ для $v \neq \texttt{root}$ и $sufpath(\texttt{root}) = \{\texttt{root}\}$.

Утверждение

cur соответствует вхождению ⇔ на суффиксном пути cur есть терминальная вершина.

Таким образом, достаточно после построения бора для каждой вершины посчитать, есть ли в её суффиксном пути терминальная вершина:

```
v.has_terminal = v.value or suf(v).has_terminal
```



```
has_terminal(v):
    if v.has_terminal is None:
        v.has_terminal = v.value or has_terminal(suf(v))
    return v.has_terminal
```

Вхождение словарного слова

Определение

$sufpath(v) = \{v, suf(v), suf(suf(v)), \ldots, \texttt{root}\}$. Иначе говоря, $sufpath(v) = \{v\} \cup sufpath(suf(v))$ для $v \neq \texttt{root}$ и $sufpath(\texttt{root}) = \{\texttt{root}\}$.

Утверждение

cur соответствует вхождению ⇔ на суффиксном пути cur есть терминальная вершина.

Таким образом, достаточно после построения бора для каждой вершины посчитать, есть ли в её суффиксном пути терминальная вершина:

```
v.has_terminal = v.value or suf(v).has_terminal
```

Также бывает полезным посчитать сжатые суффиксные ссылки — ссылки до ближайшей терминальной вершины. Например, чтобы вывести все вхождения всех словарных слов.

(супер-суфф. ссылки)

Время работы (Э ли вхождение?): $O\left(\left(\sum |s_i|\right) \cdot |\Sigma| + |text|\right)$ — обработка текста

1). построение бора
2). подсчёт suf
3). подсчёт go
4). подсчёт has_terminal

алг. Ахо-Корасик