

Busca de padrões em texto

Marco Alves de Alcantara

Supervisora: Cristina Gomes Fernandes

Introdução

Nesse trabalho iremos estudar algoritmos e estruturas de dados para buscas de padrões em textos. Estaremos pensando em aplicações onde desejamos buscar várias palavras em um texto que seja fixo e bastante longo. Um exemplo de aplicação com essas condições poderia ser buscar certas sequências de DNA no genoma humano.

Em vez de pré-processar cada palavra P a ser buscada, como seria feito em outros algoritmos como Boyer-Moore ou o KMP, iremos pré-processar o texto T uma única vez e realizar cada busca em tempo $\mathcal{O}(|P|)$ em vez de $\mathcal{O}(|T|)$.

Preliminares

Antes de começar o pré-processamento, é necessário acrescentar um caractere especial ao final do texto. Esse caractere tem a propriedade de que ele é lexicograficamente menor que qualquer outro caractere do alfabeto do texto e das palavras que serão buscadas nele. Iremos representá-lo com \$.

Para uma palavra P (que, em particular pode ser o texto T), denotaremos por $P[i]$ o caractere na i -ésima posição em P (indexada a partir de 0). Também denotaremos por $P[i..j]$ a palavra contida entre o i -ésimo e o j -ésimo caractere de P . Além disso, $P[i..]$ será o sufixo de P a partir do i -ésimo caractere, e $P[..j]$ será o prefixo de P até o j -ésimo caractere.

Vetor de Sufixos

Definimos o vetor de sufixos de T , denotado por $VS(T)$, ou simplesmente VS , como sendo o vetor dos índices dos sufixos de T ordenados lexicograficamente. Ou seja, para todo par de índices i e j de VS , se $i < j$, então $T[VS[i]..]$ é lexicograficamente menor que $T[VS[j]..]$.

Por exemplo, para $T = \text{"abracadabra\$"}$, temos o seguinte vetor de sufixos:

$T[i..]$	i	$VS[i]$	$T[VS[i]..]$
abracadabra\$	0	11	\$
bracadabra\$	1	10	a\$
racadabra\$	2	7	abra\$
acadabra\$	3	0	abracadabra\$
cadabra\$	4	3	acadabra\$
adabra\$	5	5	adabra\$
dabra\$	6	8	bra\$
abra\$	7	1	bracadabra\$
bra\$	8	4	cadabra\$
ra\$	9	6	dabra\$
a\$	10	9	ra\$
\$	11	2	racadabra\$

O Vetor de sufixos pode ser construído em tempo linear em $|T|$ por meio do DC3 Skew Algorithm[KS06], um algoritmo de divisão e conquista no qual o texto é dividido em três partes, sendo criado um alfabeto novo onde cada símbolo é uma tripla de caracteres. O VS é então calculado recursivamente para duas dessas três partes do texto, e o algoritmo realiza algumas comparações dos caracteres para construí-lo para a terceira parte. Esse algoritmo será explicado com mais detalhes na monografia pois ele foge ao escopo desse pôster.

Vetor LCP

Para realizar a busca eficientemente, é necessário também um outro vetor, denominado LCP (*longest common prefix*). Trata-se de um vetor de comprimento $|T| - 1$, indexado a partir de 1, tal que $LCP[i]$ é o comprimento do prefixo comum mais longo entre os sufixos de índices $VS[i - 1]$ e $VS[i]$.

Ainda para o texto $T = \text{"abracadabra\$"}$, tem-se o seguinte vetor LCP:

i	$VS[i]$	$LCP[i]$	$T[VS[i]..]$
0	11		\$
1	10	0	a\$
2	7	1	abra\$
3	0	4	abracadabra\$
4	3	1	acadabra\$
5	5	1	adabra\$
6	8	0	bra\$
7	1	3	bracadabra\$
8	4	0	cadabra\$
9	6	0	dabra\$
10	9	0	ra\$
11	2	2	racadabra\$

O vetor LCP pode ser construído em tempo linear em $|T|$ a partir do VS por meio do Algoritmo de Kasai[Kas+01], descrito abaixo.

Algoritmo: Construção linear do LCP

Dados: Texto T , vetor de sufixos VS

Resultado: Vetor LCP de T

```
i ← 0
enquanto i < |T| faça
  rank[VS[i]] ← i
  i ← i + 1
h, i ← 0
enquanto i < |T| faça
  se rank[i] > 0 então
    k ← VS[rank[i] - 1]
    enquanto T[i + h] = T[k + h] faça
      h ← h + 1
    LCP[rank[i]] ← h
    se h > 0 então
      h ← h - 1
    i ← i + 1
retorna LCP
```

Sobre a Busca

Tendo os vetores de sufixos e o LCP, podemos encontrar as ocorrências de P no texto. São feitas duas buscas binárias em VS , uma pelo predecessor de P , que é o maior sufixo de T que é lexicograficamente menor que P , e na segunda busca, incrementamos o último caractere de P e procuramos o predecessor dessa nova palavra. Esses predecessores nos fornecem o intervalo com os índices de todas as ocorrências de P em VS .


Em cada busca binária, além do intervalo $[L, R]$ de índices de VS onde a busca está sendo realizada, também são utilizadas variáveis auxiliares l e r com o comprimento do prefixo comum mais longo entre P e os sufixos iniciados em $VS[L]$ e $VS[R]$ respectivamente. Isso é, l e r servem para contar o número de caracteres casados entre P e as extremidades da busca binária.

	$T[VS[i]..]$	$T[VS[i]..]$
	(...)	(...)
L	<u>abc</u> bax...	L <u>abc</u> bax...
	abcbz...	abcbz...
	abcde...	⇒ M <u>abc</u> de...
	abcdy...	abcdy...
M	<u>abd</u> x...	R <u>ab</u> dx...
	abdz...	(...)
	adaz...	
	att...	
R	<u>ax</u> ...	
	(...)	

Acima temos uma ilustração de um passo da busca binária pela palavra "abcd" num texto. Em azul, estão os caracteres casados entre P e os sufixos L e R do VS ($l = 3$, e r aumenta de 1 para 2 nesse passo da busca). Dependendo dos valores de l , r , e das informações obtidas a partir do LCP (nesse caso sobre o intervalo entre L e M , os caracteres sublinhados), alguns passos da busca, como o exemplo acima, não precisam comparar caracteres diretamente. Com essa otimização, o algoritmo realiza uma busca em tempo $\mathcal{O}(|P| + \log(|T|))$.

Árvores de Sufixos

Uma alternativa ao vetor de sufixos para realizar as buscas é construir a árvore de sufixos do texto T . Numa árvore de sufixos, os nós filhos de um determinado nó são indexados por caracteres do texto T . A partir da raiz, cada aresta da árvore contém a descrição de um intervalo que deve ser "soletrado" quando a busca percorrer essa aresta.



A busca consiste em encontrar o nó menos fundo n cujo caminho até a raiz contém P . Se n não existir, então P não ocorre em T , e, caso contrário, os índices das ocorrências de P serão os índices das folhas da árvore a partir de n . A árvore pode ser construída a partir do vetor de sufixos e LCP, ou diretamente com o Algoritmo de Ukkonen, ambas as possibilidades em tempo linear em $|T|$.

Referências

- [Kas+01] Toru Kasai et al. "Linear-Time Longest-Common-Prefix Computation in Suffix Arrays and Its Applications". Em: (2001).
[KS06] Juha Kärkkäinen e Peter Sanders. "Simple Linear Work Suffix Array Construction". Em: (2006).