

Encontrando Sementes e Repeats

Katia Guimarães



Árvores de Sufixos

- Apresentadas por Weiner (1973)
- Construção linear demonstrada por McCreight (1976)
- Modelo apresentado
 - Ukkonen (1995)
 - Compacto
 - Intuitivo
 - Versátil
 - *On-line*



Árvores de Sufixos

- Definição


- Uma árvore- Σ^+ é uma árvore n-ária tal que
 - Cada aresta tem um rótulo associado (seqüência não vazia de símbolos)
 - Rótulos de duas arestas com origem no mesmo vértice não podem começar com o mesmo símbolo.



Árvores de Sufixos - Variações

- Árvore de Sufixos Compacta –
Cada aresta tem um rótulo maximal
- Árvore de Sufixos Expandida
Acrescenta-se um símbolo especial \$
ao final da cadeia

Construindo a Árvores de Sufixos da Seqüência CCTTTA






Árvores de Sufixos

- Para fazer uma construção eficiente:
 - Obter, durante a i -ésima iteração as referências para cada vértice de rótulo $X[j..i-1]$, $j= 1, 2, \dots, i-1$, na árvore T_{i-1}
 - *Suffix links*
 - Identificar a fronteira da árvore T_{i-1}
ou seja, a seqüência dos *loci* de todos os sufixos de X , do maior para o menor

Árvores de Sufixos da Cadeia BANANA com Suffix Links





Arrays de sufixos

- Manber and Myers (1993)
- Organiza todos os sufixos de uma seqüência em ordem lexicográfica crescente
- Possibilita busca binária
- Espaço
 - $O(n)$
- Tempo
 - $O(n \cdot \log n)$
- Tempo de busca por um padrão Y
 - $O(|Y| + \log n)$



Arrays de sufixos

- Tempo de construção um pouco mais longo do que as árvores de sufixo
- Vantagens
 - Construção simples
 - Econômico em termos de espaço

Arrays de sufixos

11	ϵ
10	A
7	ABRA
0	ABRACADABRA
3	ACADABRA
5	ADABRA
8	BRA
1	BRACADABRA
4	CADABRA
6	DABRA
9	RA
2	RACADABRA

X = ABRACADABRA
0 1 2 3 4 5 6 7 8 9 0 1

Pos:

11	10	7	0	3	5	8	1	4	6	9	2
----	----	---	---	---	---	---	---	---	---	---	---



Repetições com substituições

- Diferentes tipos de erros introduzem diferentes graus de dificuldade
 - Distância de Hamming
- Estratégia
 - Identificar repetições exatas de tamanho pequeno
 - Sementes
 - A partir destes, identificar trechos de tamanho maior

CDEFGHIJKLMATRIXGJKFSVECQMADRIXMNOPQRSTUVWXYZ
CDEFGHIJKLCARANDIRUFSVECQCATANVIRUPQRSTUVWXYZ



Repetições com substituições

- A computação das sementes pode ser feita em tempo $O(n)$ usando uma árvore de sufixos S
- A verificação das possíveis extensões de uma semente pode ser feita por programação dinâmica



Repetições com substituições

- Seqüência

$S = CCTTTAACCCGGGGCCAATTTCACTTGGGGTA.$

- Sementes na seqüência S de comprimento pelo menos 3

Seqüência	Par 1	Par 2
<i>GGGG</i>	(11,14)	(27,30)
<i>TTT</i>	(3,5)	(19,21)



Repetições com substituições

- Extensões da semente $GGGG$

Semente $GGGG$						
q	T_{esq}	Extensão 1	Extensão 2	Extensão 1	Extensão 2	T_{dir}
0	0	$GGGG$	$GGGG$	$GGGG$	$GGGG$	0
1	1	$CGGGG$	$TGGGG$	$GGGGC$	$GGGGT$	1
2	2	$CCGGGG$	$TTGGGG$	$GGGGCC$	$GGGGTA$	2



Repetições com substituições

- Extensões da semente TTT

Semente TTT						
q	T_{esq}	Extensão 1	Extensão 2	Extensão 1	Extensão 2	T_{dir}
0	0	TTT	TTT	TTT	TTT	0
1	1	$CTTT$	$ATTT$	$TTTAAC$	$TTTCAC$	3
2	2	$CCTTT$	$AATTT$	$TTTAACC$	$TTTCACT$	4



Considerando inserções e remoções

- Modelo mais complexo, porém, mais realístico
- Distância de Levenshtein
- k -erro repetição

CDEFGHIJKLCARANDIRUFSVECQCARAVIRUPQRSTUVWXYZ



Considerando inserções e remoções

- U e V cadeias de comprimento m e n respectivamente
- $q \in [0, k]$
- Em direita_E (esquerda_E) as cadeias U e V representam as extensões à direita (respectivamente, à esquerda) das sementes que são maximais com relação ao erro, considerando a distância de edição

Considerando inserções e remoções

- Valores de U e de V para extensões à esquerda e à direita de

GGTATGCAGGGGCGAACTATAGCGGGGGGACTTAGAT

- semente GGGG e $q \leq 2$

Semente GGGG				
q	$U(esquerda)$	$V(esquerda)$	$U(direita)$	$V(direita)$
0	GGGG	GGGG	GGGG	GGGG
1	GCAGGGG	GC'GGGG	GGGGCGA	GGGGGGA
2	TATGCAGGGG	TATAGC'GGGG	GGGGCGAACT	GGGGGGACT



Considerando inserções e remoções

Algoritmo *MDR* (S, l, k)

início

Compute todas as sementes

Para cada semente $((i_1, j_1), (i_2, j_2))$ faça

 Compute as tabelas $T_{\text{dir}}(q) = \text{direita}_E(s[j_1+1, n], s[j_2+1, n], q)$

$T_{\text{esq}}(q) = \text{esquerda}_E(s[1, i_1-1], s[1, i_2-1], q)$

Para cada $q \in [0, k]$ faça

 Para cada par $(x_1, y_1) \in \text{esquerda}(q)$ e

 cada par $(x_r, y_r) \in \text{direita}(k-q)$ faça

 Se $(j_1 - i_1 + 1 + x_1 + x_r \geq l)$ e $(j_2 - i_2 + 1 + y_1 + y_r \geq l)$ então

 reporte a k -erro repetição $((i_1 - x_1, j_1 - x_r), (i_2 - y_1, j_2 - y_r))$

fim MDR



Considerando inserções e remoções

- As sementes podem ser estendidas em tempo
 - $O(n^2)$
 - Programação dinâmica simples
 - $O(kn)$
 - Algoritmo em [Ukkonen, 1985].