

Datové struktury 1

10. přednáška 9.12.

Pavel Veselý

Plán: řetězcové a geometrické DS

- Konstrukce LCP pole ze sufixového v lineárním čase
- Konstrukce sufixového pole v lineárním čase (jen skeč, nezkouší se)
- FM-index: Ještě lepší textový index
 - Burrows-Wheelerova transformace + efektivní ranky na bitovém vektorem
- Geometrické DS: úvod

Sufixové pole X a spol.

- Udává lexikografické pořadí sufixů S
 - $X[i]$ = pozice začátku i -tého sufixu S v lex. pořadí
- Rankové pole R = inverzní permutace k X
 - $R[i]$ = kolikátý v lexikografickém pořadí je sufix $S[i :]$
- LCP pole L (pole společných prefixů, “longest common prefix”)
 - $LCP(\alpha, \beta)$ = nejdelší společný prefix slov α a β
 - $L[i] = LCP(S[X[i] :], S[X[i + 1] :])$
- Aplikace:
 - Vyhledávání výskytu jehly
 - Počet k -gramů = počet různých podslov délky k
 - Nejdelší opakující se podслово
 - Nejdelší společné podслово
 - ...

i	$X[i]$	$R[i]$	$L[i]$	$suffix$
0	13	3	0	ε
1	1	1	5	<u>aroko</u> arokoko
2	6	12	0	arokoko
3	0	10	0	barokoarokoko
4	11	5	2	<u>ko</u>
5	4	8	2	<u>ko</u> arokoko
6	9	2	0	koko
7	12	13	1	<u>o</u>
8	5	11	1	<u>o</u> arokoko
9	10	6	3	<u>oko</u>
10	3	9	3	<u>oko</u> arokoko
11	8	4	0	okoko
12	2	7	4	<u>roko</u> arokoko
13	7	0	—	<u>roko</u> ko

Algoritmy pro sufixové pole

1. Výpočet **sufixového pole** X :

- Tedy seřazení všech sufixů S

a) Zdvojováním v čase $O(n \log n)$

- Seřadíme dle prvních 2^i písmen pro $i = 0, 1, 2, \dots, \lceil \log_2 n \rceil$

b) Algoritmus Skew v čase $O(n)$ – pro abecedy, které lze setřídít v $O(n)$

- [Kärkkäinen&Sanders '03]

2. Výpočet **LCP pole** ze sufixového pole X

- Kasaiův algoritmus

i	$X[i]$	$R[i]$	$L[i]$	$suffix$
0	13	3	0	ε
1	1	1	5	<u>a</u> rokoarokoko
2	6	12	0	a <u>r</u> okoko
3	0	10	0	ba <u>r</u> okoarokoko
4	11	5	2	<u>k</u> o
5	4	8	2	<u>k</u> oarokoko
6	9	2	0	k <u>o</u> ko
7	12	13	1	<u>o</u>
8	5	11	1	<u>o</u> arokoko
9	10	6	3	<u>o</u> ko
10	3	9	3	<u>o</u> koarokoko
11	8	4	0	ok <u>o</u> ko
12	2	7	4	<u>r</u> okoarokoko
13	7	0	–	ro <u>k</u> oko

Alg. Skew – lineární konstrukce sufixového pole

- Seřadíme 2/3 sufixů slova α rekurzivně
- Zbytek dotřídíme v lineárním čase

Doplnění: porovnávání sufixů pro slití $X^{(01)}$ a $X^{(2)}$

$$\begin{aligned}\alpha_0[i:] &\leq \alpha_2[j:] \\ \alpha[3i:] &\leq \alpha[3j+2:] \\ (\alpha[3i], \alpha[3i+1:]) &\leq (\alpha[3j+2], \alpha[3j+3:]) \\ (\alpha[3i], \alpha_1[i:]) &\leq (\alpha[3j+2], \alpha_0[j+1:]) \\ (\alpha[3i], R_{01}[|\alpha_0|+i]) &\leq (\alpha[3j+2], R_{01}[j+1])\end{aligned}$$

Podobně porovnáme suffix z α_1 se suffixem z α_2 :

$$\begin{aligned}\alpha_1[i:] &\leq \alpha_2[j:] \\ \alpha[3i+1:] &\leq \alpha[3j+2:] \\ (\alpha[3i+1], \alpha[3i+2], \alpha[3i+3:]) &\leq (\alpha[3j+2], \alpha[3j+3], \alpha[3j+4:]) \\ (\alpha[3i+1], \alpha[3i+2], \alpha_0[i+1:]) &\leq (\alpha[3j+2], \alpha[3j+3], \alpha_1[j+1:]) \\ (\alpha[3i+1], \alpha[3i+2], R_{01}[i+1]) &\leq (\alpha[3j+2], \alpha[3j+3], R_{01}[|\alpha_0|+j+1])\end{aligned}$$

Textové indexy pro podřetězce

= DS pro text α , která umožňuje vyhledání jehly J

- Sufixový strom: $\approx 2 \cdot n \cdot (|\Sigma| + 2) \cdot \lceil \log_2 n \rceil$ bitů

- Vyhledávání v $O(|J|)$


- Sufixové+LCP pole: $\approx 2 \cdot n \cdot \lceil \log_2 n \rceil$ bitů

- Vyhledávání v $O(|J| + \log n)$ za použití LCP

- FM-index: $\approx (1 + o(1)) \cdot n \cdot \lceil \log_2 |\Sigma| \rceil$ bitů

- Počet výskytů v $O(|J|)$

- S pamětí navíc lze najít i pozice výskytů



Obrázek 13.4: Suffixový strom pro slovo barokoarokoko

FM-index (zjednodušený)

[Ferragina & Manzini '05]

- Burrowsova–Wheelerova transformace
 - Permutace $\alpha\$$
 - Seřadíme sufixy $\alpha\$$ a uložíme poslední sloupec
 - Používá se ke kompresi (např. bzip2)
- Occurrence function $\text{occ}(x, i)$
 - Počet výskytů znaku x v $\text{BWT}(\alpha)[1:i]$
 - Stačí prostor $o(n)$ navíc k $\text{BWT}(\alpha)$
 - A vyhodnotíme v $O(1)$

I	F	L
1	\$	abracadabra
2	a	\$abracadabr
3	ab	\$abracad
4	abracad	abra\$
5	ac	adabra\$abr
6	ad	abra\$abrac
7	bra	\$abracada
8	br	acadabra\$a
9	ca	dabra\$abra
10	da	bra\$abraca
11	ra	\$abracadab
12	rac	adabra\$ab

Příště

- DS pro reprezentaci množiny bodů a intervalové dotazy
 - k-d stromy
 - Range trees

