

Datové struktury 1

9. Přednáška 2.12.

Pavel Veselý

Plán: řetězcové DS


Sufixové stromy a pole

- ... aneb seřadíme sufixy a vyřešíme téměř vše v lineárním čase 😊



Vyhledávání v textu (jehly v kupce sena)

- Dán text S („seno“) a jehla J
- Cíl: najít všechny výskyty J v textu = sufixy S začínající na J
- Algoritmy:
 - Knuth–Morris–Pratt (KMP):
 - pomocí automatu
 - Rabinův-Karpův
 - Pomocí „rolling hash“
 - Aho-Corasick: rozšíření KMP na více jehel
- Co když nám chodí jehly jako dotazy?
 - Z textu tedy chceme vytvořit DS, která pro zadanou jehlu najde její výskyty




Obrázek 13.1: Vyhledávací automat pro slovo barbarossa

Značení pro řetězce

- Σ = abeceda znaků, Σ^* jsou konečné řetězce nad Σ
- S, α, β = text, řetězec, slovo, ...; $|S|$ = délka S (počet znaků)
- ε = prázdné slovo délky 0
- $S[i]$ = znak na pozici $i = 0, \dots, |S| - 1$
- $S[i : j]$ = **podřetězec** (**podслово**) znaků na pozicích $i, i + 1, \dots, j-1$
- $S[: j]$ = **prefix** z prvních j znaků
- $S[i :]$ = **suffix** z posledních $|S| - i$ znaků, tedy od znaku i

Opakování: trie = písmenkový strom (prefixový strom)


- Dána množina slov (řetězců)
- Každý uzel odpovídá prefixu nějakého slova
- Uzel:
 - Pole indexované písmeny Σ
 - Příznak konce slova
- **Komprimovaná trie**
 - Odstraníme uzly s jedním synem
 - **Hrana**
 - dva indexy na začátek a konec podslova



Obrázek 4.4: Písmenkový strom pro slova kocka, kocur, kote, koza, kozel, kuzle, mys, mysak, myska

Sufixový strom pro S

= komprimovaná trie všech sufixů $S\$$



Obrázek 13.4: Suffixový strom pro slovo barokoarokoko

Jak spočítat sufixový strom z S ?

- Snadno v kvadratickém čase ☹️
- V lineárním čase – později

K čemu je dobrý sufixový strom?

- Vyhledání výskytů jehly
- Nejdelší opakující se podslovo
- ...

Sufixové pole X (a spol.)

- Udává lexikografické pořadí sufixů S
 - $X[i]$ = pozice začátku i -tého sufixu S v lexikografickém 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”)
 - $\text{LCP}(\alpha, \beta)$ = nejdelší společný prefix slov α a β
 - $L[i] = \text{LCP}(S[X[i] :], S[X[i + 1] :])$
- **Aplikace:**
 - Vyhledávání výskytu jehly
 - Počet k -gramů = počet různých podslov délky k
 - Nejdelší opakující se podслово
 - Nejdelší společné podслово
 - ...

Jsou lepší sufixové stromy nebo pole?

Algoritmy pro sufixové pole/stromy

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	ko <u>o</u>
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

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

3. Sufixový strom $\leftrightarrow$ sufixové +LCP pole

- Lze v čase $O(n)$ – cvičení



Obrázek 13.4: Suffixový strom pro slovo barokoarokoko

Řazení sufixů zdvojením – pseudokód

Algoritmus SUFFIXOVÉPOLE

Vstup: Řetězec α délky $n > 0$

1. Vytvoříme pole $X[0 \dots n]$ a $R[0 \dots n]$.
2. První fáze:
3. $D \leftarrow \{(\alpha[i], i) \mid i = 0, \dots, n\}$, kde $\alpha[n]$ považujeme za nejmenší znak.
4. Setřídíme D lexikograficky.
5. Pro $j = 0, \dots, n$:
6. $X[j] = D[j][1]$
7. Je-li $j = 0$ nebo $D[j][0] \neq D[j-1][0]$:
8. $R[X[j]] = j$
9. Jinak:
10. $R[X[j]] = R[X[j-1]]$
11. $k \leftarrow 1$ $\triangleleft$ číslo aktuální fáze
12. Dokud $k \leq n$: $\triangleleft$ z polí X_k a R_k počítáme X_{2k} a R_{2k}
13. $D \leftarrow \{(R[i], R[i+k], i) \mid i = 0, \dots, n\}$, kde $R[i+k] = 0$ pro $i+k > n$.
14. Setřídíme D lexikograficky.
15. Pro $j = 0, \dots, n$:
16. $X[j] = D[j][2]$
17. Je-li $j = 0$ nebo $(D[j][0], D[j][1]) \neq (D[j-1][0], D[j-1][1])$:
18. $R[X[j]] = j$
19. Jinak:
20. $R[X[j]] = R[X[j-1]]$
21. $k \leftarrow 2k$

Příště

- Lineární algoritmus Skew pro konstrukci sufixového pole
 - stručně
- Ještě lepší DS pro řetězce:
 - Burrows-Wheelerova transformace
- Geometrické datové struktury