

## 10. cvičení

Datové struktury I, 11. 12. 2025

<https://iuuk.mff.cuni.cz/~chmel/2526/ds1/>

### Úloha 1 (Sufixové a LCP pole v praxi)

Společně si ukážeme jak sestavit obě pole na řetězci `barokoarokoko`.

Budete-li mít chuť, můžete si to pak sami zkusit na řetězcích `CAGTAGCTGTA`, `TATGTCAGTATCTC`.

### Úloha 2 (Ze stromu na pole a zpět)

Ukažte, že ze sufixového stromu umíte v lineárním čase vytvořit sufixové pole s LCP polem, a naopak.

### Úloha 3 (Ano, stále recykluji tutéz pohádku)

Ze sopky se vám podařilo zachránit hromadu slonů<sup>1</sup>. Díky vašim expertním znalostem různých sloních druhů jste upozorovali, že ve skutečnosti máte slony dvou různých druhů, a protože oba druhy mají jiné preference potravy, chcete je od sebe rozdělit, ať se na vás některý ze slonů nenaštve. Bohužel je od sebe nejste schopni odlišit přímo, ale víte, že se liší svou DNA. Navíc jako správní matfyzáci s sebou máte přístroj na sekvenování DNA, který zároveň automaticky vygeneruje i sufixové a LCP pole daného řetězce DNA.

Každému slonovi tedy (s jejich souhlasem) vysekvujete relevantní kousek DNA, který si můžeme představit jako řetězec. Po důkladném prostudování příručky *Jak se liší sloni* jste zjistili, že hlavní rozdíl jejich DNA je v délce nejdelší opakující se podposloupnosti bází DNA. Konkrétně, pokud je délka takového řetězce lichá, jedná se o slona indického, zatímco slon africký má nejdelší takovou podposloupnost sudé délky. Pro každého slona určete, zda se jedná o slona afrického či slona indického.

Pokud vás nezajímají příběhy: nalezněte v řetězci, když máte jeho sufixové i LCP pole, délku nejdelšího opakujícího se podřetězce.

### Úloha 4 (Hledáme palindrom)

Máte řetězec  $\alpha$ . Nalezněte pomocí LCP pole či sufixového pole nejdelší palindromický (souvislý) podřetězec  $\alpha$ . (Řetězec je palindromický, jestliže je stejný, když jej čteme zepředu i zezadu.)

### Úloha 5 (Sloni jsou nějak zvědaví)

Když se sloni dozvěděli, co všechno váš sekvencer umí, zajímala by je ještě další věc: přečetli si, že podřetězec  $P$  délky  $n$  odpovídá zvýšené inteligenci, a tak by je zajímalo, jestli mají takové predispozice. Když máte relevantní část jejich genomu  $G$  délky  $m$ , nejprve si připomeňte triviální algoritmus hledání jehly v seně v čase  $\mathcal{O}(n \log m)$  (můžete předpokládat, že sufixové pole máte už sestavené).

Dále si představte, že pro libovolné dva řetězce  $x, y$  umíte spočítat  $\text{LCP}(x, y)$  v konstantním čase. Upravte triviální algoritmus tak, aby trval jenom  $\mathcal{O}(\log m)$ .

---

### Bonusové úlohy

### Úloha 6 (Advent of code intensifies)

Sloni jsou ale realisté, takže si jsou vědomi toho, že obecné LCP nejde spočítat v konstantním čase. Na druhou stranu ale objevili hromadu dalších podřetězců, které údajně odpovídají všem možným vlastnostem, takže by byli moc rádi, kdyby algoritmus byl co nejrychlejší.

Co ale kdybychom uměli v konstantním čase spočítat LCP libovolných dvou sufixů v genomu (seně)?<sup>2</sup> Nalezněte v tom případě algoritmus na hledání jehly délky  $n$  v seně délky  $m$  běžící v čase  $\mathcal{O}(n + \log m)$ .

Hint: V sufixovém poli máme všechny sufixy  $G$  lexikograficky seřazené, takže v něm můžeme binárně vyhledávat a zajímá nás takový sufix, jehož prefixem je právě  $P$ . Jenom je potřeba při porovnání řetězců porovnávat jenom ty správné části, aby nás všechna porovnání dohromady stála  $\mathcal{O}(n)$ . Cílem je tedy využívat informace o společných prefixech mezi prvky sufixového pole k udržování informací o společném prefixu  $P$  s relevantními řetězci v  $S$ .

### Úloha 7 (Vlastně můžeme trochu zeslabit předpoklady)

Víme, že v lineárním čase lze k  $S$  dopočítat pole LCP (Kasaiovým algoritmem). Ukažte, že potom je v lineárním čase možné dopočítat všechny hodnoty, které algoritmus v předchozí úloze potřebuje.

---

<sup>1</sup>Viz příběh Advent of code 2022, dny 16-18: <https://adventofcode.com/2022/day/16>. Vzpomeňme navíc na roky, kdy AoC opravdu měl 24 dní.

<sup>2</sup>Tento předpoklad je silnější než jenom mít LCP pole, protože umíme počítat i LCP lexikograficky nesousedních sufixů.

## Tahák

- Pro řetězec  $\alpha$  s pythoním značením podřetězců (tj. indexujeme od nuly,  $\alpha[i : j]$  obsahuje všechny znaky od indexu  $i$  po index  $j - 1$ , vynechání jedné souřadnice znamená "od začátku", resp. "do konce") máme následující:
- sufixové pole  $S$ :  $S[i]$  říká index takový, že  $\alpha[S[i] : ]$  je lexikograficky  $i$ -tý sufix řetězec  $\alpha$
- rankové pole  $R$ :  $R[i]$  říká, kolikátý je lexikograficky sufix  $\alpha[i : ]$
- LCP pole  $L$ :  $L[i]$  říká, kolik znaků na začátku spolu sdílejí  $\alpha[S[i] : ], \alpha[S[i + 1] : ]$  (tedy lexikograficky  $i$ -tý a  $(i + 1)$ -ní sufix  $\alpha$ )
- sufixový strom: komprimovaná trie obsahující všechny sufixy slova  $\alpha\$$ , kde  $\$$  je znak mimo abecedu, který je lexikograficky první.