

2. CVIČENÍ Z ADS2

Vyhledávání jehel v seně

Algoritmus **Knuth-Morris-Pratt** v deseti slovech:

„Hledej po znacích, vracej se zpět chytřeji: zpětné hrany! Bootstrapping.“

Algoritmus **Aho-Corasicková** v deseti slovech:

„Postav trii, zpětné hrany jako KMP. Zkratky do nejdelších suffixů.“

Opakování óčkové notace:

$f \in O(g)$	f je asymptoticky stejná nebo menší než g
$f \in \Omega(g)$	f je asymptoticky stejná nebo větší než g
$f \in \Theta(g)$	f je asymptoticky stejná, jako g
$f \in \omega(g)$	f je asymptoticky ostře větší, než g (příklad: $n \log n \in \omega(n)$)
$f \in o(g)$	f je asymptoticky ostře menší, než g (příklad: $\sqrt{n} \in o(n)$)

PŘÍKLAD PRVNÍ Ještě jednou k rotacím: Naleznete algoritmus, který pro slova γ, δ na vstupu rozhodne, je-li γ rotací δ nebo nikoli.

PŘÍKLAD DRUHÝ Na vstupu máme jen jedno slovo σ , a hledáme jeho nejdelší prefix, který je zároveň i jeho suffixem. Jak na to?

PŘÍKLAD TŘETÍ Vyřešme teď jeden klasický řetězcový problém, který nesouvisí s hledáním jehel v seně: takzvaný **NEJDELŠÍ SPOLEČNÝ PODŘETĚZEC**. Na vstupu máme řetězec α délky a a β délky b a chceme najít co nejdelší řetězec, který je nejdelším podřetězcem jak α , tak β . (Nejdelších podřetězců může být víc, stačí nám jeden libovolný.)

1. Ukažte (jakkoli hloupě chcete), že problém je polynomiálně řešitelný.
2. Potom zkusíme najít řešení v $O(a \cdot b)$. Trénink: pokud vám prozradím tuto složitost, jaké typy algoritmů byste zkusili?

Zajímavý fakt na konec: problém jde řešit i v $O(a + b)$. Takové řešení ale je nad rámec ADS2.

Hledání více jehel v jednom seně: Na vstupu máme seno σ a několik jehel $\iota_1, \iota_2, \dots, \iota_k$. Celková délka sena je s , celková délka všech jehel $j_1 + j_2 + \dots + j_k = J$. Naším úkolem je vypsát dvojici (c, i) , kdykoli na pozici c v seně končí jehla ι_i . Inspirováni KMP bychom chtěli složitost $O(s + J)$.

PŘÍKLAD ČTVRTÝ Ukažte, že takhle snadno to nepůjde:

Naleznete příklad jehel a sena, v němž je asymptoticky více než lineární počet výskytů. Přesněji řečeno ukažte, že pro každé n existuje vstup, v němž je součet délek jehel a sena $\Theta(n)$ a počet výskytů je $\omega(n)$ (čili je jich asymptoticky více).

Dobrá, upravujeme svůj požadavek: chtěli bychom složitost $O(s + J + V)$, kde V je počet všech výskytů.

PŘÍKLAD PÁTÝ Uvažujme naivní algoritmus verze 1, který pracuje s trií, ale nepoužívá zkratkové hrany a vždy projde po zpětných hranách až do kořene. Ukažte, že tento algoritmus je asymptoticky pomalejší než náš požadavek.

PŘÍKLAD ŠESTÝ Druhý snadný způsob, jak si poradit s hlášením výskytů, je předpočítat si pro každý vrchol trie v množinu $M(v)$ indexů slov k ohlášení. Dokažte, že pro slovník velikosti J může být součet $M(v)$ v celé trii dokonce $\omega(J)$ – takže předpočítat je v čase $O(J)$ nestihneme.

(Pozor na to, že nám jde o součet velikostí množin, ne součet všech délek slov v těchto množinách. Když má $M(v)$ tři slova délky sto, tak $|M(v)|$ je stále 3.)