


KMP - obecněji (Aho-Corasick)



$i_1 \dots i_n := \text{jehly}$

$\sigma := \text{slovo}$

$\text{stav}_y := \text{prefixy všech jehel}$

hrany:
 - dopředná $\rightarrow$ prodlavení prefixu o jedno znaménko
 - zpětná $\rightarrow$ zkrácení prefixu na nejdelší vlastní suffix
 - zkratka $\rightarrow$ cesta po zpětných, jde na nejdelší koncový stav - tedy litera jehly již obsahuje

Reprezentace automatu:

stav_y očíslujeme, 0 = kořen (c)

$\text{slovo}(i) := \text{litera jehly končí ve stavu } i$

$\text{zpět}(i) := \text{kam vede zpětná hrana}$

$\text{zkratka}(i) := \text{kam vede zkratková hrana}$

$\text{Dopředn}(i, x) := \text{kam vede dopředná hrana pro písmeno } x$

Vždy maximálně jedna od každé na jednom místě

Krok (s, x) :

$\rightarrow$ To je ze pro zadání x ax už nemí současně řetězec

Dokud $\text{Dopředn}(s, x) = \emptyset$: $\rightarrow$ pokud už nemí kam dál jít, oba skončí zpět

Dokud $s = \text{kořen}$: vraťme s . $\rightarrow$ pokud jsem již v kořenu

$s = \text{zpět}(s)$ $\rightarrow$ jít na jeden po zpětných

Vraťme $\text{Dopředn}(s, x)$ $\rightarrow$ už existuje příslušná dopředná hrana

Hledí (σ) :

$s = \text{kořen}$

Pro $i = 0 \dots |\sigma| - 1$:

$s = \text{Krok}(s, \sigma[i])$

$t = s$ - temp. stav

Dokud $t \neq \emptyset$:

Jeli $\text{slovo}(t) \neq \emptyset$:

Hlási me výskyt...

$t = \text{zkratka}(t)$ $\rightarrow$ takhle funguje jen dokud je def.

Lemma: Hledí bývá v čase $O(|\sigma| + \# \text{výskytů})$

dopředných je nejvýše tolik co $|\sigma|$

zpětných je nejvýše tolik co dopředných

tedy $O(|\sigma|)$

výskytů je tolik, kolikrát se ohlásí.


s tím, že poprvé se může projít samým bez ohlášení...

Konstrukce automatu:

Myslenka: Stejně jako u KMP, myslí si, že bude počítat všechny jehly paralelně pro jednoho písmene a strom bude budovat po restách.

Konstrukce ($i_1 - i_n$):

- 1) Vybereme tři pro $i_1 - i_n \rightarrow 2$ toho máme dopředu
- 2) $zpět(n) (kořen) = \emptyset$, $zhrat(n) (kořen) = \emptyset$
- 3) $zpět(n) (\forall \text{ syn kořene}) = \text{kořen}$, $zhrat(n) (\forall \text{ syn kořene}) = \emptyset$
- 4) $F = \text{fronta se syny kořene}$:
- 5) Dokud $F \neq \emptyset$:
- 6) $V = \text{dequeue}(F)$
- 7) Pro s syny V :
- 8) $zpět(s) = \text{vlož}(zpět(V), \text{písmeno na hraně } vs)$
- 9) $F.add(s)$
- 10) Pokud $\text{Slovo}(zpět(s)) \neq \emptyset$:
- 11) $zhrat(s) = zpět(s)$
- 12) Jinak $zhrat(s) = zhrat(zpět(s))$.



Využití funkce, že se chodí po zpět(n) a předem je máma nalezená a propojování

Lemmy: Konstrukce běží v čase $O(\sum i_i)$

Běžící úroveň je vyhledávání tří asympt. lineární. Zbytek je BFS.

Jehly procházíme paralelně a procházíme jednou jehlou je lineární.


A tedy i celý paralelní přístup je lineární. $\rightarrow$ Dokonce často stav počítán jen jednou a u dalších jehel ho nemusíme počítat.

Věta: Nalezení všech výskytů jehel v sadě trvá $O(\sum i_i + |S| + \# \text{ výskytů})$.

Důkazy jsou spojené lemmaty.

Robinův - Karpiův alg.

$$h(x_0 - x_{j-1}) \rightarrow \partial \mathbb{Z}_H$$



musím umět přepočítat
hrušky v konstantním
čase po posunutí okénka
jinak bych nic nemohl!

$$h(x_0 - x_{j-1}) :=$$

$$(x_0 r^{j-1} + x_1 r^{j-2} + \dots + x_{j-1} r^0) \bmod H$$

posunutí okénka

$$h(x_1 - x_j) =$$

$$(x_1 r^{j-1} + x_2 r^{j-2} + \dots + x_j r^0) \bmod H$$

Dodit?

x_0 zmizelo, x_j přibýlo
ostatní se jen vynásobilo r -kem

Řešení:

$$h(x_1 - x_j) = h(x_0 - x_{j-1}) \cdot r - x_0 r^j + x_j$$

A tahle je
konstantní
čas $O(1)$

RL alg.

0) zvolíme r z tělesa náhodně

1) $c = h(\text{jablko})$, $a = h(5[1:j])$, spočítám r^j

2) Pro $i = 0, \dots, |S| - j$:

3) Pokud $a = c$ and $5[i:i+j] = c$

4) Hlásím výslyt jablka i na pozici i .

5) $a = (a \cdot r - 5[i] \cdot r^j + 5[i+j]) \bmod H$.

Složitost:

- počítání hrušek: $O(|S|)$

- skutečné výslyty: $O(j \cdot v)$ výslyty

- falešné výslyty =

$\hookrightarrow$ Pro jakýkoliv (obdobně náhodnou) h ,

$$P(\text{falešného výslytu}) = \frac{1}{H}$$

$$\hookrightarrow \text{průměrný čas} = O\left(\frac{|S| \cdot j}{H}\right)$$

$\frac{j}{H}$ pro jeden
drušek.
Celkem $|S|$
drušek.

$$\text{Pokud } H \geq j: O(|S|)$$

Mějme $P(x) := p_0 x^0 + p_1 x^1 + \dots + p_{n-1} x^{n-1}$ nad tělesem

Lemma: Pokud $x_1, \dots, x_n$ jsou všechny kořeny polynomu P , pak $P(x) = (x - x_1) \cdot (x - x_2) \cdot \dots \cdot (x - x_n) \cdot Q(x)$

kde $Q(x)$ je polynom bez kořenů.

Důsledek: Polynom stupně d má nejvýše d kořenů

Kdyby k bylo větší než stupeň P , vyšel by spor.

Lemma: Necht' P a Q jsou polynomy stupně $< n$, $x_1, \dots, x_n$ navzájem různá čísla t.j. $\forall i: P(x_i) = Q(x_i)$.
Pak $P \equiv Q$.

$R := P - Q$, stupeň opět $< n$ t.j. $\forall i: R(x_i) = 0$ $\rightarrow$ Jediný takový polynom je nulový polynom.

$$R \equiv 0 \Rightarrow P \equiv Q$$

Tedy nyní falešný výsledek doplníme:

$$P(r) = h(i)$$

$$Q(r) = h(\sigma[i:i+j])$$

- Ptáme se, že pokud jsou polynomy různé, tak pro konkrétní r jistě je pravděpodobnost, že se budou rovnat.

$$\text{tedy } P[P(r) \equiv Q(r)] \leq \frac{j}{H} \rightarrow \frac{1}{H} \text{ opět z velikosti kódu. Protože to je také pozice, kde se dva polynomy mohou rovnat, aby stále byly identické.}$$

Tedy H by muselo být alespoň j^2 velká.

Celková časová složitost je tedy $O\left(\frac{\kappa \cdot j^2}{H}\right) \rightarrow$ tedy pro $H \geq j^2$ je to $O(\kappa)$

$O(\kappa \cdot j) :=$ ověření jednotlivých v sémě

$\cdot O\left(\frac{j}{H}\right)$ počet falešných výsledků (kvůli tomu spínáme).