

# ANALÝZA LINEÁRNÍHO PŘÍDAVÁNÍ

(1)

Věta [Knuth 1968]: Pokud  $m \geq (1+\epsilon) \cdot n$ , očekávaný # porovnání při neúspěšném hledání je  $O(1/\epsilon^2)$  pro plně náhodnou hesovací fci.


Dokážeme o něco slabší tvrzení: Pokud  $m=3n$ ,  $E[\# \text{porovnání}] \in O(1)$ .  
(snadno lze upravit na  $(1+\epsilon)$  místo 3)

Bude se hodit Chernoffova nerovnost & Necht  $X_1 \dots X_n$  jsou ~~nezávislé~~ nezávislé náhodné veličiny s hodnotami  $\{0,1\}$ ,  $X = \sum_i X_i$  a  $\mu = E[X]$ .

Potom:  $\Pr[X > c \cdot \mu] < \left(\frac{e^{c-1}}{c^c}\right)^\mu$  pro  $c > 1$

$\Pr[X < c \cdot \mu] < \left(\frac{e^{c-1}}{c^c}\right)^\mu$  pro  $c \in (0,1)$ .

Uvažujme binární strom postavený nad přírůdkami:



$m=3n$  přírůdek

vnitřní vrchol ve výšce  $h$  odpovídá zaranžovanému intervalu délky  $2^h$   
ten obsahuje bloky délky  $2^h$

Df: vrchol je nebezpečný

$\equiv$  do jeho intervalu podle hesovací funkce ~~neobsahuje~~ více než  $\frac{2}{3} \cdot 2^h$  prvků

$\uparrow$  nepočítáme prvky přesunuté kvůli kolizím

Lemmas  $\Pr[\text{vrchol ve výšce } h \text{ je nebezpečný}] < (e/4)^{2^h/3}$ .

Df: Necht  $I$  je ~~blok~~ interval délky  $2^h$  pokrytý vrcholem.

Pro prvky  $x_1 \dots x_n$  definujeme indikátory  $C_i = \begin{cases} 1 & \text{pokud } h(x_i) \in I \\ 0 & \text{jinak} \end{cases}$

$C = \sum_i C_i$  je # prvků zahrnutých do intervalu  $I$

$E[C_i] = 2^h/m \dots \Pr[h(x_i) \in I]$

$\mu = E[C] = \sum_i E[C_i] = n \cdot \frac{2^h}{m} \leq \frac{2^h}{3}$ .

Chernoff



$\Pr[\text{vrchol je nebezpečný}] = \Pr[C > \frac{2}{3} \cdot 2^h] = \Pr[C > 2\mu] < \left(\frac{e}{4}\right)^\mu = \left(\frac{e}{4}\right)^{2^h/3}$ .

Df: Běh je maximální interval přírůdek zaplněných prvků.  $\leftarrow$  Tady už počítáme i přesunuté  
indexujeme mod  $m$

Lemmas Necht  $R$  je běh délky alespoň  $2^{4t+2}$ . Pak aspoň jeden z prvních 4 bloků velikosti  $2^t$  ~~je~~ protínající  $R$  je nebezpečný.

Df: Necht  $B_0 \dots B_3$  jsou zmiňované bloky.

$B_0$  zasahuje do  $R$  aspoň 1 prvkem,  $B_1 \dots B_3$  jsou celé uvnitř  $R$ .

necht  $L := (\cup B_i) \cap R$   $|L| \geq 3 \cdot 2^{t+1}$

Navíc všechny prvky ~~uložené~~ <sup>uložené</sup> do  $L$  jsou opravdu ~~uloženy~~ <sup>zahrnovány do</sup>  $L$  ← jinak by slo  $R$  rozšířit dolů, tedy by to nebyl běh (2)

$\Rightarrow$  do  $\bigcup_i B_i$  se zahrnovalo aspoň  $|L|$  prvků

... a stačí použít princip holubníku: kdyby žádný  $B_i$  nebyl nebezpečný, bylo by v  $\bigcup_i B_i$  max.  $\frac{8}{3} 2^l$  prvků, což je  $< |L|$  ↓

Lemmas Pokud běh obsahující daný prvek  $x$  má délku  $\in [2^{l+2}, 2^{l+3})$ , pak aspoň 1 z ~~následujících~~ <sup>předchozích</sup> 12 bloků délky  $2^l$  je nebezpečný: blok obsahující  $h(x)$ , 8 předchozích bloků a 3 následující.

Důk: Jelikož běh dané délky obsahuje max. 9 bloků délky  $2^l$ , leží jeho začátek nejvýše 8 bloků před  $h(x)$ , takže nebezpeč. blok  $\neq$  předch. lemmatu leží mezi určenými 12 bloky.

Nyní počítáme:

$$\begin{aligned} & \Pr[\text{běh obsahující } x \text{ má délku } \in [2^{l+2}, 2^{l+3})] \\ & \leq \Pr[\text{některý z 12 bloků z lemmatu je nebezpečný}] \\ & \leq 12 \cdot \Pr[\text{daný blok velikosti } 2^l \text{ je nebezpečný}] \\ & \leq 12 \cdot (e/4)^{2^{l+3}} \end{aligned}$$

$$\begin{aligned} \downarrow \\ \mathbb{E}[\underbrace{\text{délka běhu obsahujícího } x}_{L}] & \leq \sum_{l=0}^{1+2^l} 2^{l+3} \cdot \Pr[L \in [2^{l+2}, 2^{l+3})] \\ & \leq c + \sum_{l=0} 2^{l+3} \cdot \left( (e/4)^{1/3} \right)^{2^l} \\ & \leq c + c' \cdot \sum_{l=0} 2^l \cdot q^{2^l} \quad q \in (0,1) \\ & \leq c + c' \cdot \left( \sum_{i=0} i \cdot q^i \right) \quad \text{konverguje pro každé } q \in (0,1) \\ & \in O(1). \end{aligned}$$

Poznámky:

- pro 2-nezávislost se můžeme pokusit použít Markovovu nerovnost  
 $\rightarrow$  vyjde  $\Pr[\text{blok nebezp.}] \leq 1/2$ , což je příliš slabé ... dostaneme  $\mathbb{E}[L] \in O(n)$ .
- pro 3-nezávislost použijeme Čebyševovu nerovnost (1 stupeň volnosti sebere fixace  $x$ , zbylé 2 stačí na odhad rozptylu)  $\rightarrow \Pr[\dots] \leq 3 \cdot 2^{-l}$  ... dostaneme  $\mathbb{E}[L] \in O(\log n)$ .
- pro 5-nezávislost použijeme analogickou nerovnost pro momenty 4. řádku, z ní dostaneme  $\Pr[\dots] \leq 36 \cdot 2^{-2^l}$  ... a to stačí na  $\mathbb{E}[L] \in O(1)$ .