

# Úsporné datové struktury

- Chceme uložit prvek množiny  $C$  (třeba jeden ze stromu na  $n$  vrcholech) a parit těžen optimální prostor  $\dots \text{OPT} = \lceil \log |C| \rceil$  bitů } entropie při rovnoměrném rozdělení pravděpodobnosti
- Právou chceme rychlé operace
- Variandy:
  - implicitní DS - jen data samu ve vhodném pořadí (seznamy, pole, haldy) }  $\text{OPT} + O(1)$
  - úsporné (succinct) DS -  $\text{OPT} + o(\text{OPT})$
  - kompaktní DS -  $O(\text{OPT}) \dots$  ale pozor, třeba BVS nemusí být kompaktní levým pořadím - už podle slova, ale byť nebo trie

## Problém: Reprezentace řetězce nad obecnou abecedou

Příklad 8

- $[10] \rightarrow 4$  bitů ( $\log 10 \approx 3.322$ )
- $[10]^2 \dots$  mohu uložit jako  $2 \times 4$ , nebo jako  $[100] \rightarrow 7$  bitů
- $[10]^k \dots$  uložím jako  $[10^k] \rightarrow k \cdot \log_{10} 10 + 1$  navíc  $k \cdot (\log 10 + 1)$

↳ limitně se blížím  $k \cdot \log_{10} 10$  k každak (redundance = délka kódu - entropie)  
 ... ale ztrácím lokální dekódovatelnost } jde k 0

Praktické řešení: dělim na bloky o 9 znacích ... délka kódu = 30  
 entropie  $9 \cdot \log_{10} 10 \approx 29.897$   
 → redundance  $\approx 0.103$

Možné řešení:  
 → dělit do 1 slova  
 → počítám s nimi v  $O(1)$  času i prostoru

↳ pro string délky  $n \in [n/10^9] \leq \frac{n}{10^9} + 30$   
 ↳ redundance  $\leq 0.103 \cdot \frac{n}{10^9} + 30$

↳  $(a,b) \in X \times Y$  kódují po složkách  $\Rightarrow$  délky kódů i entropie se setkou → redundance také

Příklad H2: Posíláme proud bitů, ale dopředu nevíme, jak bude dlouhý. → instantní (prefixní) kód  
 [potřebujeme učit zdekóduvat znacku pro koniec, aniž by neustále "já mám to překračuje" zobrazeno dost nista]

Triviale řešení: rozdělme na bloky o  $b$  bitech,  
 za které připadne 1 bit znaku znaku, do posledního bloku padding  $10^k$   
 ↳ redundance  $\frac{1}{b} + b + 1$

## SOLE Encoding [Dodd, Patraşcu, Thorup 2010]

(Short-Odd-Long-Even)

- vstup rozdělme na bloky o  $b$  bitech  $\rightarrow$  pravé abecedy  $[B]$  pro  $B=2^b$
- poslední blok dopadne (10 — 0 na konci), ale potřebujeme přidat spec. blok označující EOF  
 ↳ převod  $[B+1]^* \rightarrow [B]^*$
- nastavime  $b \geq 2\log n + 2 \Rightarrow B \geq 4n^2$

↳ bloky se rejdou do  $O(1)$   
 Slov RAMu

(2)

číslo bloku	1.	2.	3.	4.	5.	6	... k
vstupní abeceda	B	B	B	B	B	B	- - EOF
+ EOF	B+1	B+1	B+1	B+1	B+1	B+1	- - B+1
1. průchod	B	B+3	B-3	B+6	B-6	B+9	- - 0
2. průchod	B	B	B	B	B	B	- - 0

sem si domyslejme nulový blok

$$\underline{1. \text{ průchod:}} \quad (B+1)(B+1) \leq (B-3i)(B+3i+3)$$

$$B^2 + 2B + 1 \leq B^2 + 3Bi + 3B - 3Bi - 9i^2 - 9i$$

$$-B+1 \leq -9i^2 - 9i$$

$$B-1 \geq 9i^2 + 9i$$

$$B \geq 9i^2 + 9i + 1, \text{ neboť } i \leq \frac{n+1}{2} \text{ a } B \geq 4n^2$$


$$\underline{2. \text{ průchod:}} \quad (B+3i)(B-3i) = B^2 - 9i^2 \leq B^2$$

- redundance  $\leq 3b$  (1 blok zadávání + 1 EOF + 1 extra na lichý # bloku)
- pravidelné kodování + dekódování
- lokální dekódování i závěry v O(1) na RAMu [potřebuje  $O(\log n)$  bitů]  $\hookrightarrow O(1)$  slov

zadáváním na celé bity je příložitelná redundance


Postupně z této odvodíme obecnou konverzi abecedy

- proč to vlastně funguje?




nechám třetí malející možnost informace  
a to v prvním kroku prvních  
k většinu, čemuž odpovídá redundance  
... zbytky se posílají zpět  
do zlepšení vzdálenosti  
 $\rightarrow$  lokálně dekódovatelné

Obecně:  
zbytek vstupu [y]  
vstup [x]



... pro referenci stále  
lok. dekódovatelné:



pro dekódování  
stačí znát obě •

Lemma: Nechť  $X, Y \leq 2^W$ . Pak  $\exists M, S$  a zobrazení  $f: [X] \times [Y] \rightarrow [2^M] \times [S]$  t. z.:

$$\textcircled{1} \quad S = O(\sqrt{X}), \quad 2^M = O(Y \cdot \sqrt{X}) \quad \text{a } S/M \text{ závisí pouze na } X, Y$$

\textcircled{2} f lze vyhodnotit (na RAMu) v čase  $O(1)$

\textcircled{3} x lze dekódovat z m, s v  $O(1)$

\textcircled{4} y lze dekódovat ze samotného m v  $O(1)$

\textcircled{5} Redundance je  $O(1/\sqrt{X})$  bitů


$$(M + \log S) - (\log X + \log Y)$$

entropie výstupu      entropie vstupu

(3)

### Dležitost M (přeději)

↳  $[2^M]$  musí obsahovat celé  $y$  a nejakou část  $x'$  cesta  $x \dots$  jakou?  $C_8 = [2^M]/Y$  lze vypočítat



dokud každý matrix je sledek posloupné  
jen 1x, redundance může se sčítat  
(stěleskopuj se)

- redundance rozkladu kodování  $x, y \rightarrow m$ :

$$R_1 = M - \log(Y \cdot C) \leq M - \log(2^M - Y) = \log \frac{2^M}{2^M - Y} = \log \frac{1}{1 - \frac{Y}{2^M}} = O\left(\frac{Y}{2^M}\right) = O\left(\frac{1}{C}\right)$$

$\hookrightarrow \log\left(Y \cdot \left[\frac{2^M}{2^M - Y}\right]\right) \geq 2^M - Y$

$e^x \geq 1+x$   
 $x \geq \log(1+x)$   
 $-x \leq \log \frac{1}{1+x}$   
 $x \geq -\log \frac{1}{1+x}$

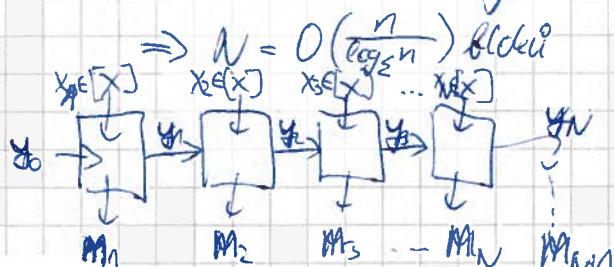
- redundance rozkladu  $x \rightarrow x', s$ :

$$R_2 = (\log C + \log S) - \log X = (\log C + \log \frac{x}{C}) - \log X = \log \frac{C \cdot \frac{x}{C}}{X} \leq \log \frac{x+C}{X} = \log\left(1 + \frac{C}{X}\right) = O\left(\frac{C}{X}\right).$$

- celkem tedy minimalizujeme  $O\left(\frac{1}{C} + \frac{C}{X}\right)$  ...  $C \approx \sqrt{X} \rightarrow S = O(\sqrt{X})$ ,  $2^M = O(Y \cdot \sqrt{X})$  ✓  
 → redundance  $O(1/\sqrt{X})$ , jde jsme slibili. [nezávislost na Y]

### První pokus o reprezentaci stringů

$A \in \{\epsilon\}^n$  ... rozdělíme na bloky o velikosti  $\Theta(\log n)$  tak, aby  $X \approx n^2$




$$y_i \in [O(\sqrt{X})] = [O(n)]$$

$$m_i \in [O(\sqrt{X} \cdot \sqrt{X})] = [O(n^2)]$$

### Zadíraná: stromové kodování

Opět vultime  $X \approx \Theta(n^2)$ ,  $N = O\left(\frac{n}{\log n}\right)$



$$\boxed{[Y_1] \times [Y_2] \cong [Y_1 \cdot Y_2]}$$

ooo redundance  $O(1/n)$  v každém kroku

↳ celkově  $O(1)$ , což je mille

ooo Celkového kodování / dekodování!

OOOPS! Každý blok má jiné parametry?


→ potřebuje tabulku  $O\left(\frac{n}{\log n}\right)$  konstant?

→ tělo v SOLE nedálo, protože  $X=2^{b+1}$ ,  
 takže jsou jednotlivá  $Y_i$  musí approximovat  
 aritmetickou posloupnost ... ale toto  
 to nebude fungovat

• dekódování je stále celkové

(z otce stáčí out, ten vrátí zbytek)

4



na každém kladiné 3 typy vrcholů, pro ně si pamatujeme:

- # vrcholů tohoto typu
- adresu dat 1. vrcholu
- parametry uživáře

Dekódování: pozice ve streamu  $\rightarrow$  číslo bloku = pozice ve stranu

adresa  
v paměti

typ

kladina

$\log i$  (v čase  $O(1)$ )

$\leq O(1)$

celkem  
 $O(\log n)$   
konstant  
(slov)

+ potřebujeme  
tabulku  $O(\log n)$   
mocnin  $|\Sigma|$   
na extrakci  
symbolů z bloku

Lokální změna též v  $O(1)$ .

Celková redundance  $O(1)$  [jako u předchozího] +  $O(1)$

za kódování bloku

za dekódování posledního bloku  
(nebude jít o kódované adresy)

Veta: Na Word-RAMu lze reprezentovat prvek  $[\Sigma]^n$

v prostoru  $\lceil n \log |\Sigma| \rceil + O(1)$  řádků

se čtením/zápisem prveku v čase  $O(1)$

s použitím  $O(\log n)$  konstant závislých na  $n$  a  $|\Sigma|$ .