


- Domácí úkol - 4-5 70% bodů na zápočet
- cvičení pátek 10:40 - nepovinné

Plán - Informace & komprese
 - samoopravné kódy
 - komunikační složitost

Informace

Scrabble



"Přidám slovo obsahující X_{10} " vs.
 "Přidám slovo obsahující E_1 "

- "Čeknu Vám velkou novinu:
 - a) náš prezident odstoupil
 - b) v Praze zavedou trolicovský
 - c) v poledne jsem byl na obědi
 - d) v poledne jsem byl na obědi
 - e) hadr snědl rozvířené koberec "

- překvapení vs význam
 - více překvapení = více informace
 - význam nemůžeme analyzovat
 - informaci přiřadíme k pravděpodobnostním událostem (např. vygenerované zprávy)

Informace - chceme

A událost, $I(A)$ informace obsažená v události.

1) $I(A)$ klesá s rostoucí $p(A)$.

Př. Zauvažujme balíček 32 karet, všech karet

- 1) červená A
- 2) sedma B
- 3) červená sedma C

$$P(A) \geq P(B) \geq P(C)$$

$$I(A) \leq I(B) \leq I(C)$$

2) $I(A \& B) = I(A) + I(B)$ pro A, B nezávislé
 $(P(A \& B) = P(A) \cdot P(B))$

$$3) I(A) \geq 0 \quad \text{pro } \forall A$$

$$\rightarrow I(A) = -\log_a P(A) \quad \text{pro pevné zvolení } a > 1.$$

$$-\log_a P(A) = \log_a \frac{1}{P(A)}$$

• Alternativní přístup - Kolmogorovův složitost
(uvádíme později.)

Opakovaná pta:

• pravděpodobnostní prostor Ω ... konečné nebo spočetné množině

s měrou pravděpodobnosti: $p: \Omega \rightarrow \mathbb{R}$

$$\forall \omega \in \Omega, p(\omega) \geq 0$$

$$\sum_{\omega \in \Omega} p(\omega) = 1$$

Pr: Ω ... množina možných zpráv, $\{0,1\}^n$

• jest (udává) $A \subseteq \Omega$ $Pr[A] = \sum_{\omega \in A} p(\omega)$.

• jsou A a B jsou nezávislé: $Pr[A \& B] = Pr[A] \cdot Pr[B]$.

• podmíněná pravděpodobnost A na B :

$$Pr[A|B] = \frac{Pr[A \& B]}{Pr[B]}$$

Pr: A & B jsou nezávislé $\Leftrightarrow Pr[A|B] = Pr[A]$.

• náhodná proměnná $X: \Omega \rightarrow \mathbb{R}$.
(včetně)

Pr: náhodná proměnná X definuje ruzné jevy

$$\forall S \subseteq \mathbb{R} \rightarrow \text{jev } [X \in S].$$

dvě náhodné proměnné X, Y jsou nezávislé
jestliže $\forall S, S' \subseteq \mathbb{R}$ $[X \in S]$ a $[Y \in S']$
jsou nezávislé

Pr: n. p. $X, Y: \Omega \rightarrow \{0,1\}^n$

1) X vybere náhodný řetězec $\in \{0,1\}^n$
 Y vybere nezávislý náhodný řetězec $\in \{0,1\}^n$

(P1)

$$\forall x, y \in \{0,1\}^n$$

$$Pr[X=x \& Y=y] = \frac{1}{2^{2n}}$$

2) vybereme náhodné řetězky $a, b, c \in \{0,1\}^{n/2}$
položíme $X = ab$ $Y = bc$

$$\forall x, z \in \{0,1\}^n \quad Pr[X=x] = \frac{1}{2^n}$$

$$Pr[Y=y] = \frac{1}{2^n}$$

(P2)

$$Pr[X=x \& Y=y] \neq \frac{1}{2^n}$$

$\Rightarrow X$ a Y jsou závislé

$$Pr[X=x \& Y=y] = \begin{cases} 0 & x_{2..n} \neq y_{1..n/2} \\ \frac{1}{2^{3n/2}} & x_{2..n} = y_{1..n/2} \end{cases}$$

• střední hodnota: $E[X] = \sum_{\omega \in \Omega} p(\omega) \cdot X(\omega)$
 $= \sum_{c \in \mathbb{R}} c \cdot Pr[X=c]$

• náhodné proměnné X, Y, Z :

$$E[X+Y+Z] = E[X] + E[Y] + E[Z]$$

"linearity střední hodnoty"

• Markovův nerovnost: pro nezápornou náhodnou proměnnou X a pro $\forall k \in \mathbb{R}$

$$Pr[X \geq k \cdot E[X]] \leq \frac{1}{k}$$

Entropie (neurčitost) X náhodná proměnná

$$H(X) = - \sum_x p(x) \cdot \log_2 p(x)$$

konvence $0 \cdot \log 0 = 0$

→ střední hodnota informace

• $H(X) \geq 0$ Dk: $\forall 0 < p < 1 \quad \log_2 p < 0$

$$\Rightarrow H(X) = - \sum_x p(x) \cdot \log p(x)$$

• $H(X) \leq \log |X|$ (Dk poradiji)
 $\hookrightarrow |\text{supp}(X)|$

Pr: X je náhodná proměnná s hodnotami z $\{0, 1\}^n$

1) $\forall x \in \{0, 1\}^n, \quad p(x) = 2^{-n} \quad (= Pr[X=x])$


$$H(X) = \sum_{x \in \{0, 1\}^n} \frac{1}{2^n} \log 2^n = n$$

2) $p(0^n) = \frac{1}{2} \quad \forall x \neq 0^n \quad p(x) = \frac{1}{2^{n+1}-2}$

$$H(X) = \frac{1}{2} \log 2 + \frac{1}{2} \log (2^{n+1}-2) = \frac{n}{2} + \Theta(1)$$

Pr: $H(p) = p \cdot \log \frac{1}{p} + (1-p) \log \frac{1}{1-p}$

$$X = \begin{cases} 0 & \text{s práz. } p \\ 1 & \text{s práz. } 1-p \end{cases}$$



společná entropie X, Y náhodné proměnné

$$H(X, Y) = \sum_{\substack{x \in X \\ y \in Y}} p(x, y) \cdot \log \frac{1}{p(x, y)}$$

$$= E_{X, Y} \log \frac{1}{p(X, Y)}$$

Pf: (P1) ušic X, Y
 $H(X, Y) = 2n$

(P2) ušic X, Y
 $H(X, Y) = \frac{3}{2}n$

• $\pi_x, \pi_y : \{0,1\}^n \rightarrow \{0,1\}^n$... pomocí zvolení permutace
 $X' = \pi_x(X) \quad Y' = \pi_y(Y) \quad H(X', Y') = \frac{3}{2}n$.

Podmíněná entropie

$$\begin{aligned} H(Y|X) &= \sum_{\substack{x \in X \\ p(x) > 0}} p(x) \cdot H(Y|X=x) \\ &= \sum_{x \in X} p(x) \sum_{y \in Y} p(y|x) \lg \frac{1}{p(y|x)} \\ &= \sum_{x \in X} \sum_{y \in Y} p(x,y) \lg \frac{1}{p(y|x)} \\ &= \mathbb{E}_{X,Y} \lg \frac{1}{p(Y|X)} \end{aligned}$$

- Pf:
- 1) $H(Y|Y) = 0$
 - 2) $H(Y|X) = H(Y)$ pokud X & Y jsou nezávislé
 - 3) (P1) $X, Y \quad H(Y|X) = H(Y) = n$
 - 4) (P2) $X, Y \quad H(Y|X) = \frac{n}{2}$
 $H(Y) = n$

Věta ("chain rule")

$$H(X, Y) = H(X) + H(Y|X)$$

Důkaz:

$$\begin{aligned} H(X, Y) &= - \sum_{x \in X} \sum_{y \in Y} p(x,y) \cdot \lg p(x,y) \\ &= - \sum_{x \in X} \sum_{y \in Y} p(x,y) \cdot \lg p(x) \cdot p(y|x) \\ &= - \sum_{x \in X} \sum_{y \in Y} p(x,y) [\lg p(x) + \lg p(y|x)] \\ &= \underbrace{- \sum_{x \in X} p(x) \lg p(x)}_{H(X)} - \underbrace{\sum_{\substack{x \in X \\ y \in Y}} p(x,y) \lg p(y|x)}_{H(Y|X)} \quad \square \end{aligned}$$

Důsledky:

$$\begin{aligned} H(X, Y|Z) &= H(X|Z) + H(Y|X, Z) \\ H(X) + H(X|Y) &= H(X, Y) = H(Y) + H(X|Y) \end{aligned}$$

Obecně: náhodní prom. X_1, X_2, \dots, X_k

$$H(X_1, X_2, \dots, X_k) = \sum_{i=1}^k H(X_i | X_1, X_2, \dots, X_{i-1})$$

Dk:

$$\begin{aligned}
&= H(x_1) + H(x_2, \dots, x_k | x_1) \\
&= H(x_1) + H(x_2 | x_1) + \\
&\quad H(x_3, \dots, x_k | x_1, x_2) \\
&= \dots
\end{aligned}$$

Význam entropie

- očekávaný počet bitů při kódování
(kompresi) ... ušetření
...

Vzájemná informace

Př: zprávy v řadě kanálu o stejných událostech.

N_1, N_2, \dots, N_k k periodik

kolik informace o zprávě N_1 nám již po přečtení N_2, N_3, \dots atd.

Def: náhodné proměnné X, Y

$$I(X:Y) = H(X) - H(X|Y) \dots$$

vzájemná informace X a Y

... o kolik se snížil neúspěch X , když znám Y

Poznámka: $I(X:Y) = I(Y:X)$... symetrická informace

Př: 1) $I(X:X) = H(X) - H(X|X) = H(X)$

2) X, Y nezávislé $I(X:Y) = H(X) - H(X|Y) = 0$

3) (P2) $I(X:Y) = H(X) - H(X|Y) = \frac{n}{2}$

4) X, Y nezávislé hodnoty kostek

$$Z = X + Y \pmod{6}$$

$$I(X:Y) = 0 \quad I(X:Z) = 0 \quad I(Y:Z) = 0$$

$$I(X, Y:Z) = H(X, Y) - H(X, Y|Z) = H(Y) = H(X)$$

$$\begin{aligned}
& \underbrace{H(X|Z)}_{H(X)} + \underbrace{H(Y|X, Z)}_{=0}
\end{aligned}$$

Vlastnosti:

$$I(X:Y) = H(X) + H(Y) - H(X, Y)$$

Def: Kullback - Leiblerova vzdálenost

náhodné proměnné X, Y se stejným oborem

$$p(x) = \Pr\{X=x\} \quad \mathcal{L}(x) = \Pr\{Y=x\}$$

$$D(X||Y) = D(p||\mathcal{L}) = \sum_x p(x) \log \frac{p(x)}{\mathcal{L}(x)}$$

lemona: $0 \cdot \log \frac{0}{0} = 0$ $0 \cdot \log \frac{0}{2} = 0$

$p \cdot \log \frac{p}{0} = \infty$

poznámka: $D(p||q) = \sum_x p(x) \log \frac{1}{q(x)} - \underbrace{\sum_x p(x) \log \frac{1}{p(x)}}_{H(x)}$

vidíme $D(p||q) \geq 0$

• možná interpretace: o kolik se prodlouží průměrná délka kódů při distribuci p , když přejdeme kódy pro distribuci q .

tvrzení: $I(X:Y) = D(p(x,y) || p(x) \cdot p(y))$

Důk. $= \sum_{x \in X} p(x) \log \frac{1}{p(x)} - \sum_{\substack{x \in X \\ y \in Y}} p(x,y) \log \frac{1}{p(x,y)}$

$\underbrace{\hspace{10em}}_{H(X)} \qquad \underbrace{\hspace{10em}}_{H(X|Y)}$

$= \sum_{\substack{x \in X \\ y \in Y}} p(x,y) \log \frac{1}{p(x)} - \text{---}$

$= \sum_{x,y} p(x,y) \log \frac{p(x,y)}{p(x)} \quad (*)$

$= \sum_{x,y} p(x,y) \log \frac{p(x,y) \cdot p(y)}{p(x) \cdot p(y)} \quad \Rightarrow p(x,y)$

tvrzení: $I(X:Y) = \mathbb{E}_{y \in Y} [D(X|Y=y || X)]$


Důk. $p_{y \in Y} \neq (*)$ $y \in Y$.

Michal Koucky at 14. 3. 2016 21:28

• f je konvexní na (a,b) pokud $\forall x_1, x_2 \in (a,b)$

$\forall 0 \leq \lambda \leq 1$

$f(\lambda x_1 + (1-\lambda)x_2) \leq \lambda f(x_1) + (1-\lambda)f(x_2)$



Věta (Jensenova nerovnost): f je konvexní f na (a,b) a X je náhodná proměnná s hodnotami z (a,b) pak

$\mathbb{E}[f(X)] \geq f(\mathbb{E}[X])$

Důk. pro $|X|$ konečný

1) $p(x_1) = \lambda$ $p(x_2) = 1 - \lambda$ $X \in \{x_1, x_2\} \subseteq (a,b)$

z definice konvexnosti ✓

$$2) p(x_i) = p_1, \dots$$

$$p(x_n) = p_n$$

(|supp(x)| = n)

inanka dle n

$$p_i = \frac{p_i}{1-p_n}$$

$$\begin{aligned} \sum_{i=1}^n p_i f(x_i) &= p_n f(x_n) + (1-p_n) \sum_{i=1}^{n-1} p_i' f(x_i) \\ &\stackrel{\text{ind. p' edp.}}{\geq} p_n f(x_n) + (1-p_n) f\left(\sum_{i=1}^{n-1} p_i' x_i\right) \\ &\stackrel{\text{konvexita}}{\geq} f\left(p_n x_n + (1-p_n) \sum_{i=1}^{n-1} p_i' x_i\right) \\ &= f\left(\sum_{i=1}^n p_i x_i\right) \quad \square \end{aligned}$$

Věta: Necht' $p(x), q(x)$ jsou přísl. rozdělení pro $x \in X$.

$$\text{Pak } D(p \| q) \geq 0$$

Dle: $A = \{x; p(x) > 0\}$

$$\begin{aligned} -D(p \| q) &= - \sum_{x \in A} p(x) \log \frac{p(x)}{q(x)} \\ &= \sum_{x \in A} p(x) \log \frac{q(x)}{p(x)} \\ &\leq \log \sum_{x \in A} p(x) \frac{q(x)}{p(x)} \\ &\leq \log \sum_{x \in X} q(x) \\ &= \log 1 = 0 \quad \square \end{aligned}$$

$$\rightarrow D(p \| q) = 0 \Leftrightarrow p = q$$

Důsledek: $I(X; Y) = 0$

Dle: $I(X; Y) = D(p(x, y) \| p(x) \cdot p(y)) \quad \square$

Důsledek: $H(X) \leq \log |X|$ s rovností právě pokud X je rovnoměrné rozdělení.

Dle: def $u(x) = \frac{1}{|X|}$ p je rozdělení X

$$\begin{aligned} D(p \| u) &= \sum p(x) \log \frac{p(x)}{u(x)} = \log |X| - H(X) \\ &\stackrel{0}{\geq} \Rightarrow \log |X| \geq H(X) \quad \square \end{aligned}$$

Důsledek: $H(X|Y) \leq H(Y)$ s rovností iff $\forall x \in X$ x a Y nezávislé

Dle: $0 \leq I(X; Y) = H(X) - H(X|Y) \quad \square$

Př: $\Pr[X = 0^n] = \frac{1}{2} \quad \forall x \in \{0, 1\}^n \setminus \{0^n\}$
 $\Pr[X = x] = \frac{1}{2^{(n-1)}}$
 $n \geq 1, x = 0^n$

$$\begin{aligned} \text{21 } X \neq 0^n \quad H(X) &= \frac{n}{2} + o(1) \\ H(X|Y) &\leq \frac{n}{2} + o(1) \end{aligned}$$

$$\begin{aligned} \text{ale: } H(X|Y=1) &= n + o(1) \\ H(X|Y=0) &= 0 \\ H(Y) &= 1 \end{aligned}$$


$$\bullet I(X:Y|Z) = \mathbb{E}_{z \in Z} [I(X:Y|Z=z)]$$

$$\text{Potomou: } I(x_1, x_2, \dots, x_n : Y) = \sum_{i=1}^n I(x_i : Y | x_1, \dots, x_{i-1})$$

$$\begin{aligned} \text{Dle: } I(x_1, \dots, x_n : Y) &= H(x_1, \dots, x_n) - H(x_1, x_2, \dots, x_n | Y) \\ &= \sum_{i=1}^n H(x_i | x_1, \dots, x_{i-1}) - H(x_1, \dots, x_n | Y) \\ &= \sum_{i=1}^n I(x_i : Y | x_1, \dots, x_{i-1}) \quad \square \end{aligned}$$

Algebra

Bez



$$I(X:Y) \text{ vs } I(X:Z) \quad ?$$

Def: X, Y, Z splývají Markovskou vlastností
pokud $\forall x, y, z$

$$P_r[Z=z | Y=y] = P_r[Z=z | Y=y \& X=x]$$

$$\text{" } X \rightarrow Y \rightarrow Z \text{"}$$

$$\bullet P(z|y) = P(z|y, x)$$

$$\begin{aligned} \bullet P(x, z | y) &= P(x|y) \cdot P(z|y, x) = P(x|y) P(z|y) \\ &= P(z|y) \cdot P(x|y, z) \end{aligned}$$

$$\Rightarrow P(x|y, z) = P(x|y)$$

$$\Rightarrow \text{" } X \rightarrow Y \rightarrow Z \text{" iff " } Z \rightarrow Y \rightarrow X \text{"}$$

... Syntetice

Věta: Pokud $X \rightarrow Y \rightarrow Z$ pak $I(X:Y) \geq I(X:Z)$

$$\begin{aligned} \text{DL: } I(X:Y, Z) &= I(X:Y) + I(X:Z|Y) \\ &= I(X:Z) + I(X:Y|Z) \end{aligned}$$

$$I(X:Z|Y) = 0 \quad \text{protože } X \& Z \text{ jsou} \\ \text{nezávislé podmíněně na } Y$$


$$I(X:Y|Z) \geq 0 \quad \text{tožso}$$

$$\Rightarrow I(X:Z) \leq I(X:Y) \quad \square$$

$$\Rightarrow \perp(x; z) = \perp(x; y) \quad -$$

Kódování

- $C: X \rightarrow \Sigma^*$
 \hookrightarrow abeceda chci $\forall x \neq y$
 $C(x) = C(y)$
- ... kódy
- průměrná délka kódu $C: L(C) = \sum_{x \in X} p(x) l(x)$
- uzávkový kód $C^*(x_1, \dots, x_k) = C(x_1)C(x_2) \dots C(x_k)$
- kód je jednoznačně dekódovatelný, pokud C^* nemá kolizi.
- bezprefixový kód: $\forall x \neq y \quad C(x)$ není prefix $C(y)$




Věta: (Kraftova nerovnost)

Pro bezprefixový kód C s délkami kódu l_1, l_2, \dots

$$\text{platí: } \sum 2^{-l_i} \leq 1$$

(Obecně $\sum |Z|^{-l_i} \leq 1$ pro n-ární abecedu.)

Důk:



každému slovu $a_1 a_2 \dots a_k$ přiřadíme interval $[0.a_1 a_2 \dots a_k, 0.a_1 a_2 \dots a_k + 2^{-k})$

interval přiřazení různým slovům sloven jsou disjointní, jejich sjednocení je podmnožina $[0; 1)$, tedy celková délka splňuje

$$\sum 2^{-l_i} \leq 1.$$

Podobně pro obecnou abecedu Σ . □

- Platí i opačná implikace: pokud máme $l_1, \dots, l_n \in \mathbb{N}$
 $\sum 2^{-l_i} \leq 1$, pak existuje bezprefixový kód požadované délky.

(Lze přičíst od nejmenší 2^{-l_1} do nejmenší:

$$l_1 \leq l_2 \leq l_3 \dots \leq l_n$$

$$\left(\begin{array}{c} \overbrace{2^{-l_1}} \quad \overbrace{2^{-l_2}} \quad \dots \quad \overbrace{2^{-l_n}} \end{array} \right)$$

• Optimální bezprefixový kód pro X , dle minimalizace průměrnou délkou obs.

$$C: X \rightarrow \{0,1\}^* \quad L = \mathbb{E}[|C(X)|]$$

$$l(x) = |C(x)|$$

$$L = \sum_x p(x) \cdot l(x)$$

$$\begin{aligned} L - H(X) &= \sum_x p(x) l(x) - \sum_x p(x) \frac{1}{p(x)} = \\ &= \sum_x p(x) \lg \frac{1}{2^{-l(x)}} - \sum_x p(x) \frac{1}{p(x)} = \\ &= \sum_x p(x) \lg \frac{p(x)}{2^{-l(x)}} = (*) \end{aligned}$$

$$c = \sum 2^{-l(x)} \quad g(x) = \frac{2^{-l(x)}}{c} \quad \begin{array}{l} \text{krajd.} \\ \downarrow \\ c \leq 1 \end{array}$$

$$\begin{aligned} (*) &= \sum_x p(x) \lg \frac{p(x)}{2^{-l(x)} \cdot c} = \sum_x p(x) \lg \frac{p(x)}{2^{-l(x)}} + \sum_x p(x) \lg \frac{1}{c} \\ &= \underbrace{D(p \parallel g)}_{\geq 0} + \underbrace{\lg \frac{1}{c}}_{\geq 0} \geq 0 \end{aligned}$$

$$\Rightarrow L \geq H(X) \quad \square$$

Shannonův kód:

$$l(x) = \lceil \lg \frac{1}{p(x)} \rceil$$

$$\rightarrow \lg \frac{1}{p(x)} \leq l(x) \leq \left(\lg \frac{1}{p(x)} \right) + 1$$

$$\rightarrow H(X) \leq L_{\text{Shannon}} \leq H(X) + 1$$

optimální ± 1 bit.

• kódování k symbolům x_1, x_2, \dots, x_k se stejnou $x_i \sim X$ "nezávisle"


$$H(x_1, x_2, \dots, x_k) \leq L_{x_1, \dots, x_k} \leq H(x_1, \dots, x_k) + 1$$

k $H(X)$ \rightarrow průměrně $\frac{1}{k}$ bitů navíc za každý symbol.

Pr: $p(x_1) = 0.9999$ $p(x_2) = 0.0001$
 $l(x_1) = 1$ $l(x_2) = 14$ (třelka:)

Huffmanův kód: opakovaně spojím dvě nejmenší pdk a stavím stranou od listů.


$$p_1 \geq p_2 \geq \dots \geq p_n$$



→ dá se ukázat, že dáte nejmenší možnou průměrnou délku

Fanův kód: staro stránka odshora, minimality rozdíl v poz. shora a spravo.

$$p_1, p_2, \dots, p_n \quad \min_k \left| \sum_{i=1}^k p_i - \sum_{i=k+1}^n p_i \right|$$



Fakt: průměrná délka slova $\leq H(x) + 2$

Věta (McMillan): jednoznačný dekadický kód C s délkami $l(x)$ splňuje

$$\sum_x 2^{-l(x)} = 1$$

Důk: Uvažme C^k $k \geq 1$

$$\begin{aligned} \left(\sum_x 2^{-l(x)} \right)^k &= \sum_{x_1} \dots \sum_{x_k} 2^{-l(x_1) - \dots - l(x_k)} \\ &= \sum_{\bar{x} \in X^k} 2^{-l(\bar{x})} \quad l_i \leq l_{\max} \end{aligned}$$

$$\sum_{\bar{x} \in X^k} 2^{-l(\bar{x})} \leq \sum_{m=1}^{k \cdot l_{\max}} c(m) \cdot 2^{-m}$$

$$c(m) = \# \text{ slov v } C^k \text{ s délkou } m$$

$$c(m) \leq 2^m$$

$$\Rightarrow \left(\sum_x 2^{-l(x)} \right)^k \leq \sum_{m=1}^{k \cdot l_{\max}} 2^m \cdot 2^{-m} = k \cdot l_{\max}$$

$$\sum_x 2^{-l(x)} \leq \left(k \cdot l_{\max} \right)^{1/k} \xrightarrow{k \rightarrow \infty} 1$$

• generální postřeho rozdělání pomocí nezávislých bitů $1/2, 1/2$.

• C libovolný kód $C: X \rightarrow \Sigma^*$

$$L(C) \text{ vs } H(x) ?$$

$$H(x) - 2 \leq H(x) - 2 \leq L(C)$$

Důk: $\exists C$ lze udělat bezprefixový kód

$$C(x) \rightarrow \underbrace{e(C(x))}_{\text{zaházení délky } C(x)} \text{ o } C(x)$$

v binárním ústředí

a zdaným každého bitu

$$0 \rightarrow 00$$

$$1 \rightarrow 11$$

→ komprimovaný

$$l(x) \rightarrow s(l(x)) = l(x) + 2 \lg l(x) + 2$$

$$H(x) \leq \sum p(x) l'(x) = L(c) + 2 \sum p(x) \lg l(x) + 2$$

samozřejmě $\leq L(c) + 2 + 2 \lg \sum p(x) l(x)$.

$$H(x) \leq L(c) + 2 + 2 \lg L(c)$$

Pak $H(x) \leq L(c)$ není co dokázat

$$\text{jinak } 2 \lg L(c) \leq 2 \lg H(x)$$

$$\Rightarrow H(x) \leq L(c) + 2 + 2 \lg H(x) \quad \square$$

Michal Koucky at 28. 3. 2016 21:07

Kolmogorovská složitost

σ : Co čím kódová řetěz $\{0,1\}^*$ nahodně?

$$3333333 \dots 3 \rightarrow 3^{10}$$

$$21415226535 \rightarrow \pi \dots \text{průměr deset čísel}$$

$$84354279521 \rightarrow \text{nahodně}$$

Odhady a další zprávy. Záleží však na jazyku.

f - částová rekursivní funkce $f: \{0,1\}^* \rightarrow \{0,1\}^*$

$$x \in \{0,1\}^*$$

Def: Kolmogorovská složitost x vzhledem k f :

$$C_f(x) = \min \{ |p|; p \in \{0,1\}^*, f(p) = x \}$$

Vol: Existuje univerzální částová rekursivní fun U

t.č. \forall č.r.f. $g \exists c > 0$ t.č. $\forall x \in \{0,1\}^*$

$$C_U(x) \leq C_g(x) + c$$

Dle:

ϕ_1, ϕ_2, \dots enumerace všech částových rekursivních fun

ϕ_i ... i "kód"

uvážeme párování $\langle i, z \rangle = 0^{i-1} 1 i z$

U definujeme programem:

na vstupu $\langle i, z \rangle$

dešifruj i z z ,

simuluj ϕ_i na z

pokud se zastaví, vykični, co vykičle ϕ_i na z .

And.

pro nějaký $j \quad \phi_j = g$

$$c = 2|j| + 1$$

Pohled p je optimální program pro x pro g ,
 pak $\langle j, p \rangle$ je kód pro x pro u ☒

→ u dává nejmenší složitost ze všech čir. f.
 (čir. na konstantě)

→ zafixujeme nějaké u $C \in C_u$.

Př: $C(x) \leq |x| + O(1)$
 $C(0^n) \leq |n| + O(1)$
 $\hookrightarrow n$ binárně... $O(\lg n)$ bitů
 $C(\pi_{1..n}) \leq |n| + O(1)$

$\forall n \exists x \in \{0,1\}^n; C(x) \geq |x|$
 Dk. \exists nejvíce $2^n - 1 = \sum_{i=0}^{n-1} 2^i$
 různých programů délky $< n$,
 ale je 2^n různých délek n ☒

Def: x je Kolmogorovský náhodný, pokud $C(x) \geq |x|$.

• Podmíněná Kolmogorovská složitost
 $x, y \in \{0,1\}^*$ f čir. f.
 $C_f(x|y) = \min \{ |p|; p \in \{0,1\}^*, f(\langle p, y \rangle) = x \}$

Věh: $\exists u; \forall$ čir. f. $g \exists c \forall x, y$
 $C_u(x|y) \leq C_g(x|y) + c$

→ zafixujeme u ... univerzální
 $C(x) \stackrel{\text{def}}{=} C(x|\varepsilon)$
 \hookrightarrow prázdny řetězec.

• $C(x, y) \stackrel{\text{def}}{=} C(\langle x, y \rangle)$

Věh: $C(x, y) \leq C(x) + C(y|x) + O(\lg C(x, y))$

Dk: program p pro x
 program z pro y , když známe x
 $\hookrightarrow C(y|x)$

$O(\lg C(x, y))$ pro separaci p a z ☒

Věh: $C(x, y) \geq C(x) + C(y|x) - O(\lg C(x, y))$

Dk: netriviální, viz standardní učebnice
 Kolmogorovské složitosti ☒

Kolmogorovská informace

$I_C(x : y) = C(x) - C(x|y)$

Symetrická informace: $I_C(x : y) = I_C(y : x) + O(\lg C(x, y))$

Př: $\forall n \exists x \in \{0,1\}^n$ t.č. $C(x|n) \geq n$
 Pokud $C(n) \geq \lg n$ pak

$$\bar{I}_c(x:n) = C(x) - C(x:n) \leq n - n = 0$$

$$I_c(n:x) = C(n) - C(n|x) = \lg n \pm O(1)$$

→ logaritmicke ztrata nutna
 ↳ pgn pro aproximaci psh

Věta: X_1, X_2, \dots je rekurzivní podbýpnost pevné distribuce, X_n má $\{0,1\}^n$ rozložení. Pak

$$H(X_n) - O(\lg n) \leq \mathbb{E}[C(X_n)] \leq H(X_n) + O(\lg n)$$

Důk: $\mathbb{E}[C(X_n)] \leq H(X_n) + O(\lg n)$

vezmeme Huffmanův kód pro X_n ,

$x \in X_n$ má délku $l(x)$

$$C(x) \leq l(x) + O(\lg n)$$

pgn pro Huffmanův kód X_n

$$\mathbb{E}[C(X_n)] \leq \mathbb{E}_{x \in X_n} [l(x) + 2 \lg n + O(1)] \leq H(X_n) + O(\lg n)$$

$$\bullet H(X) \leq \mathbb{E}[C(X_n)] + O(\lg n)$$

pro každé $x \in X_n$, neboť p_x

je jeho nejkratší pgn.

$$|p_x| \leq n + O(1)$$

$$d_x = O(n^{1+O(1)}) \cdot |p_x|$$

↳ $(\lg n + O(1))$ bitový binární zápis $|p_x|$

$\{d_x, x \in X_n\}$... bezprefixový kód pro X_n

$$\begin{aligned} \Rightarrow H(X_n) &\leq \mathbb{E}_{x \in X_n} [d_x] = \\ &= \mathbb{E}_{x \in X_n} [C(x)] + O(\lg n) \end{aligned}$$

Samozprávné kódy

• hindu přednísta P. Gregar

- problem

- definice

- Shannonova věta

+ inverzní Shannonova věta

Michal Koucky at 12. 4. 2016 10:43

• Hammingův kód

$$n = 2^l - l - 1$$

x_1	...	x_n	
1	0	0	1
⋮	0	0	⋮
l	0	0	1

• očíslovíme si bity binárními čísly $1, \bar{1}$.

- obsahují alespoň dvě jednotky
- pro každé x l řádků spočítáme paritu bitů x_i , které mají v příslušném řádku bitů indexu i .

→ l parit a_1, \dots, a_l

kod $x_1, \dots, x_n \rightarrow x_1, \dots, x_n, a_1, \dots, a_l$

$$[2^l - 1, 2^l - l - 1, 3]_2$$

- rozšířený Hammingův kód přidá navíc paritu

$$a_0 = \sum_{i=1}^n x_i \pmod{2}$$

$$[2^l, 2^l - l - 1, 4]_2$$

důležitá! jediné chyby:

- pokud nastane chyba v úděli x_1, \dots, x_n , pak alespoň dvě parity a_i, a_j neodpovídají! chyba nastala v bitu, jehož bitový index je přímým úhlem $\{0, 1\}^l$ udávající, která parita nesedí!
- pokud nastane chyba v úděli a_1, \dots, a_l → nesedí právě jedna parita a to je špatně!

- kód lze reprezentovat maticí!

PF:

$$G = \begin{pmatrix} 1 & 0 & 0 & 0 & 1 & 1 \\ & 1 & 0 & 1 & 0 & 1 \\ & & 1 & 1 & 1 & 0 \\ & & & 1 & 1 & 1 \end{pmatrix}$$

$$l=3$$

$$[7, 4, 3]_2$$

↑
[Hamming 1950]

$$x \rightarrow xG$$

$$x \in \{0, 1\}^4$$

→ lineární kód $[n, k, d]_2$

$G \in \{0, 1\}^{k \times n}$ — generující matice

kontrolní matice $H \in \{0, 1\}^{n \times n-k}$

$$\forall y \quad yH = 0 \text{ iff } \exists x \quad xG = y$$

$$\Rightarrow GH = 0^{k \times n-k}$$

↳ bývá důležitý problém (ortogonální doplěk)

$$1. \quad \dim U = n - \dim G$$

Kontrolní matice Hammingova kódu:

$$H = \begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \left. \begin{array}{l} \text{část matice } G \dots \text{binární} \\ \text{inverze} \\ \text{jednotková matice} \end{array} \right\}$$

dekodování: $xG = y$ $y' = y + e_i$
 $\hookrightarrow (0, 1, \dots, 1, 0, 0)$
 i -tá pozice

$$\underbrace{y'H = (y + e_i)H = yH + e_iH = e_iH}$$

\hookrightarrow syndrom index bitů s chybami

• dle toho pro lineární kód

$$xG = y \quad y' = y + e \quad \hookrightarrow \text{chybný vektor}$$

$$y'H = yH + eH = eH$$

\hookrightarrow pro různé chybné vektory různé různé syndromy

- pokud chceme opravit d chyb musí platit že pro všechny vektory $e \in \{0, 1\}^n \setminus \{0^n\}$ s Ham. vzdáleností $\leq d$, eH jsou různé, tj. počet $\leq 2^d$ řádků z H musí být nenulový.

\rightarrow tabulka $eH \rightarrow e$ pro snadné dekodování

pro lineární kód platí: $[n, k, d]_2$

$$\forall x, y \in C \Rightarrow \begin{array}{l} x+y \in C \\ x-y \in C \end{array}$$

$$(aG = x, bG = y \quad (a+b)G = x+y)$$

$$\Rightarrow d_H(x, y) = |\{i; (x-y)_i \neq 0\}| = wt_H(x-y) \dots \text{Hammingova váha } x-y$$


$$d = \min_{x \neq y \in C} d_H(x, y) = \min_{\substack{x \in C \\ x \neq 0}} wt_H(x)$$

\Rightarrow u lineárních kódů se lze zaměřit na minimální váhu nenulových slov pro zjištění minimální vzdálenosti.

Věta (Singletonova): pro lineární kód C

$$[n, k, d]_2 \text{ nad } GF_2 \text{ platí: } n \geq k + d - 1$$

Důk:



$$\exists x, y \in \mathbb{C} \quad \forall z \in \mathbb{C} \quad x \mid (z^{k-1} - y) \mid (z^{k-1} - y)$$

$$d_H(x, y) \leq n - (k-1) = n - k + 1$$

$$d \leq n - k + 1 \quad \square$$

Reed-Solomonovy kódy

$$GF[2^q], \quad n, k \quad n \leq 2^q$$

$$\alpha_1, \alpha_2, \dots, \alpha_n \in GF[2^q]$$

$$m \in GF[2^q]^k \rightarrow p_m(x) = m_0 + m_1 x + \dots + m_{k-1} x^{k-1}$$

$$E(m) = \langle p_m(\alpha_1), p_m(\alpha_2), \dots, p_m(\alpha_n) \rangle$$

• RS kód je lineární:

$$G = \begin{pmatrix} 1 & \alpha_0^1 & \alpha_0^2 & \dots & \alpha_0^{k-1} \\ \alpha_1^1 & \alpha_1^2 & \dots & \alpha_1^{k-1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \alpha_{n-1}^1 & \alpha_{n-1}^2 & \dots & \alpha_{n-1}^{k-1} \end{pmatrix}$$

$$\rightarrow [n, k, n - k + 1]_2 \quad \text{kód}$$

↑
 polynom stupně $k-1$ má nejvýše
 $k-1$ kořenů, t.j. každé nenulové
 slovo má Ham. vzdálenost $\geq n - (k-1)$

Př: $k = n - 4 \quad [n, k, 5]_2$ kód

každý symbol $\in GF_2$ reprezentovaný binárně

$$\rightarrow [N, N - 4 \log n, 5]_2 \text{ kód}$$

... binární kód opravující 2 chyby

$$N = n \cdot \log n$$

□: Konkrétní řešení □

Dekódování Reed-Solomonových kódů

$$m = \langle m_0, m_1, \dots, m_{k-1} \rangle \quad \alpha_1, \dots, \alpha_n \in GF_2$$

$$p_m(x) = \sum_{i=0}^{k-1} m_i x^i$$

$$m \rightarrow \langle p_m(\alpha_1), p_m(\alpha_2), \dots, p_m(\alpha_n) \rangle$$

↓
... kód opraví

$$\langle r_1, \dots, r_n \rangle \in GF_2^n$$

... přijetí slova

chceme nalezt polynom stupne $\leq k-1$,
 ktery se vejde shoduje s $\langle r_1, \dots, r_n \rangle$.

Algoritmus Berlekamp-Welch (1986)

error lokaci polynom

r_1, \dots, r_n ... vime, ze existuje polynom p
 stupne $\leq k-1$, ktery se shoduje s r_1, \dots, r_n
 a alespon k pozic $\leq n-k$
 chceme nalezt polynom $E(x)$ stupne d_e t. \bar{E} .
 $\neq 0$
 $p(\alpha_i) \neq r_i \Rightarrow E(\alpha_i) = 0 \quad \forall i \in \{1, \dots, n\}$

- pokud mame tabul E , dekódování snadne:
 Řešime: $p(\alpha_i) = r_i, \dots, p(\alpha_{n-d_e}) = r_{n-d_e}$
 $d_e \leq n-k$.

$$L_{i, \beta_1, \dots, \beta_k}(x) = \frac{\prod_{j \neq i} (x - \beta_j)}{\prod_{j \neq i} (\beta_i - \beta_j)} = \begin{cases} 0 & \text{pro } \beta_j \\ 1 & \text{pro } \beta_i \\ x & \text{jinak} \end{cases}$$

... Lagrangeho polynom

$$p(x) = \sum_{i=1}^k r_i \cdot L_{i, \alpha_1, \dots, \alpha_{n-d_e}}(x)$$

Hledáme $E(x)$:

$$\forall i: (r_i - p(\alpha_i)) E(\alpha_i) = 0$$

$$\Rightarrow r_i E(\alpha_i) = p(\alpha_i) E(\alpha_i)$$

$$0 < d_e \leq \frac{n-k-1}{2} \approx \frac{d}{2}$$

$$p(x) \cdot E(x) \text{ je polynom st. } \leq \frac{n-k-1}{2} + k-1 = \frac{n+k-3}{2}$$

$$Q(x) = p(x) \cdot E(x) = \sum_{i=0}^{\frac{n+k-3}{2}} c_i x^i$$

$$E(x) = \sum_{i=0}^{\frac{n-k-1}{2}} c_i x^i$$

→ sestane n lineárních rovnic s n neznámými

$$\forall j \in \{1, \dots, n\}: \sum_{i=0}^{\frac{n+k-3}{2}} c_i \alpha_j^i = r_j \sum_{i=0}^{\frac{n-k-1}{2}} c_i \alpha_j^i \quad (*)$$

→ Gaussova eliminace $O(n^3)$

Pychla! Fast Fourier transformace $O(n \cdot \log^2 n)$
 (FFT)

• určíme Liberoňův převrácený součin $Q(x)$ a $E(x)$.

• Pokud $E(x)$ vedle $Q(x) \rightarrow$ FAIL
 (přičiň mnoho chyby)

• Spodí: $P(x) = \frac{Q(x)}{E(x)}$

• Pokud $d_H(\langle r_1, \dots, r_n \rangle, \langle P(\alpha_1), \dots, P(\alpha_n) \rangle) > d_e$

⇒ FAIR
(přibližně rovná se)

• Výchop: $P(x)$.

Tvrzení: Pokud $(Q_1(x), E_1(x)) + (Q_2(x), E_2(x))$
splňuje $(*)$ a $E_1(x), E_2(x) \neq 0$ pak

$$\frac{Q_1(x)}{E_1(x)} = \frac{Q_2(x)}{E_2(x)}$$

$Q_1(x) E_2(x)$ a $Q_2(x) E_1(x)$ mají stejné

největší $\frac{n+k-3}{2} + \frac{n-k-1}{2} = n-2$.

definj $R(x) = Q_1(x) E_2(x) - Q_2(x) E_1(x)$

$z(x) \quad Q_1(\alpha_j) = r_j E_1(\alpha_j) \quad Q_2(\alpha_j) = r_j E_2(\alpha_j)$

⇒ $\forall j \in \{1, \dots, n\} \quad R(\alpha_j) = 0. \quad (\text{st. } R \leq n-2 \text{ ale } n \text{ kořenů})$

⇒ $R(x) \equiv 0$

⇒ $Q_1(x) E_2(x) = Q_2(x) E_1(x)$ v n kódech
jelikož jsou to polynomy st. $\leq n-2$, mají
stejný rozklad na ireducibilní polynomy

⇒ $\frac{Q_1(x)}{E_1(x)} = \frac{Q_2(x)}{E_2(x)} \quad \square$


• Reed-Solomonovy kódy vyžadují velkou počet $\geq n$.

Zobecnění: Reed-Mullerovy kódy - polynomy ve více proměnných

• Jak z RS kódu udělat binární kódy?

→ kódot prvky z GF_2 binárně pomocí

Schöppnerova kódu.



$l \approx O(\log_2) \quad c \dots$ kód $[l, \log_2 + 1, d]_2$

pokud RS je $[n, k, D]_2$ kód, pak vznikl

kód je $[nl, k \cdot \log_2, dD]_2$ kód.

Dekódování:

- 1) dekódují každý mitterní symbol
- 2) dekódují RS - kód

→ opraví $\frac{dD}{4}$ chyb

• lze opravit až $\frac{dD}{2}$ - Forneyho alg.

• RS kód s min. vzdáleností D umí opravit

E chyb a S významů, pokud $2E+S < D$.

Forneyho alg.

in do kódu každé mitterní symbol $r_i \rightarrow r_i!$

vymaže každou pozici i s probí $\frac{2e_i}{d}$, (resp. $\min(\frac{2e_i}{d}, 1)$)

kde $e_i = d_H(r_i, r_i')$.

2) delší zbylé r_1', \dots, r_n' pomocí BW alg

Titul: Pokud E je počet nesprávně symbolů r_i'
a S je počet smazaných symbolů, pak

$$E[2E + S] < D,$$

pokud $\sum e_i < \frac{dD}{2}$.

Dk: Cívně \Rightarrow symbol i přispívá do střední hodnoty $\leq \frac{2e_i}{d}$
2 případy: a) $e_i \leq d/2$ b) $e_i > d/2$

[Derandomize — lze vybrat společný threshold r
v všechny pozice:



Náhodný lineární kód: (Varshamov)

• vyber náhodnou 0-1 matici G velikosti $k \times n$

kódový $x \in \{0,1\}^k \rightarrow xG$

Titul: Pokud d je takové, že $2^{k-1} \leq \frac{2^n}{\text{Vol}_2(n, d-1)}$,

pak s velkou probí $C = \{xG\}$ je kód s minimální vzdáleností d .

• $d = pn$ $k < n - H(p)n$

Dk: počet x ; xG je náhodný vektor v $\{0,1\}^n$

$$\Pr_{G \in \{0,1\}^{kn}} [xG \in \text{Vol}_2(n, d-1)] \leq \frac{\text{Vol}_2(n, d-1)}{2^n} \leq 2^{-(H(p)-1)n}$$

$$\Pr_G [\exists x \in \{0,1\}^k; xG \in \text{Vol}_2(n, d-1)] \leq 2^k \cdot 2^{-(H(p)-1)n} < 1$$

\rightarrow náhodný lineární kód je dobrý $[n, n(1-H(p)), pn]_2$.

(lze použít pro unitární kód RS)

první dva:	251, 257
(výbir)	1021, 1031
	4093, 4099

Gilbertova konstrukce $[n, k, d]_2$

- $C = \emptyset$
- dokud existuje slovo $w \in \{0,1\}^n$, které není ve vzdálenosti $< d$ od některého ze slov v C , přidej w do C .

Poznámka: algoritmus se zastaví po nejdelší

$$\frac{2^n}{\text{Vol}(n, d)}$$

krocích.

$$\Rightarrow |C| \geq 2^{n - H(\frac{d}{n})n}$$


→ $[n, (1-H(p))n, pn]_2$ kód.

- Varshamir kód je lepší v tom, že je lineární, jeho parametry mají stejný.

Hammingova mez: $[n, k, pn]_2$ kód

ma' $k \leq (1 - H(\frac{p}{2}))n$.

Důk:



- stejný Gilbert-Varshamov kód $[n, (1-H(p))n, pn]_2$ kód s Shannonovým kódem pro $\frac{pn}{2}$ chyb $[n, (1-H(p))n, ?]_2$ opravy činí pn chyb s velkou pdh'

Decodování se seznamem (list decoding)

- pro $[n, k, d]_2$ kód a přijatí slovo $y \in \{0,1\}^n$ hledat všechna slova do vzdálenosti d' od y .

$$\frac{d-1}{2} \leq d' \leq d$$

→ seznam $L \subseteq C$ $\forall y' \in L, d_H(y, y') \leq d'$.

pokud d' není příliš velké, seznam L není příliš velký (je polynomiální) v n

lokální decodování

$$x \xrightarrow{C} y \rightsquigarrow y'$$

chci zjistit souřadnici i tj. x_i , aniž bych mohl dekódovat celé x .
Zároveň ani nechci číst celý y .

Př: Hadamardovy kódy $[2^k, k, \frac{1}{2} \cdot 2^k]_2$
 $C: \{0,1\}^k \rightarrow \{0,1\}^n$ $n=2^k$

$$x \in \{0,1\}^n \quad C(x) = y_0 y_1 \dots y_{n-1} \quad y_a \quad a \in \{0,1\}^k$$

$$y_a = \sum_{i=1}^k x_i \cdot a_i \pmod{2}$$

$$\forall x, x' \quad d_H(x, x') = \frac{n}{2}$$

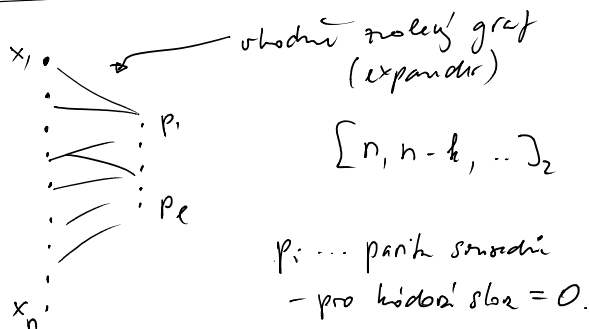
$$y \in \{0,1\}^n, \quad i \in \{1, \dots, 6\}, \quad d_H(y, C) \leq \frac{n}{6}$$

detekce chyb: nalezení zlo $a \in \{0,1\}^k$
 $e_i = (0, 0, \dots, 1, 0, \dots, 0)$
 výstup: $y_a \oplus y_{ae_i} \neq C(x)$

• Pokud $d_H(y, C(x)) \leq \frac{n}{6}$ pak $y = \overbrace{C(x)}^{[1/n]}$
 $\Pr \left[\bigcup_{a \in \{0,1\}^n} y_a \oplus y_{ae_i} = x_i \right] \geq \frac{2}{3}$

• Opakování a vzhledem k většinovému výsledku lze pro chyby snížit

• kombinatorické konstanty kódu



- vlastnosti závisí na vlastnostech grafu než \bar{x} a \bar{p} .
- chyby v kódovém slovu přepnou některé páry
- iterativně lze chyby odstranit.

Komunikační složitost

Aleka

Bob

$$x \in \{0,1\}^n$$

$$y \in \{0,1\}^n$$

Aleka a Bob chtějí spojit výjaton f

$$f: \{0,1\}^n \times \{0,1\}^n \rightarrow \{0,1\}$$

na vstup x, y , tedy $f(x, y)$.

Př:

$$EQ(x, y) = [x = y] \quad x \stackrel{?}{=} y$$


$$GT(x, y) = [x < y] \quad x \stackrel{!}{<} y$$

$$IP(x, y) = \sum_{i=1}^n x_i \cdot y_i \pmod{2}$$

A a B si vyměňují zprávy o svém vstupu, aby spočítali f .

• Zajímá nás počet bitů potřebných pro spočítání $f(x, y)$. (oba se mají dohodnout výsledek)

• protokol - obchodní postup komunikace, lze reprezentovat stromem



• každý uzel je přiřazen jednomu hráči,
 \forall Ahož uzel v je přiřazen nějaká f_v
 $m_v: X \rightarrow \{0,1\}$, která říká Ahož,
 co má poslat v závislosti na jejím vstupu
 \forall Bhož uzel obdrží

• listy jsou ohodnoceny výstupní hodnotou $f(x, y)$.

délka komunikace = hloubka stromu protokolu.
 = cena protokolu

$D(f)$ = minimální délka protokolu pro f .
 (minimum přes protokoly počítající f)

• $D(f) \leq n+1$. Důk: Ahož přečte svůj vstup x ,
 Bhož přečte $f(x, y)$

Př: 1) $x, y \in \{1, \dots, n\}$ min
 $f(x, y) = \min x \vee y$
 $D(f) \leq 2 \lg n$

2) medián
 $x, y \in \{1, \dots, n\}$
 $f(x, y) = \text{medián } x \vee y$
 $D(f) \leq n + \lg n$ triko
 $D(f) \leq O(\lg^2 n)$
 $D(f) \leq O(\lg n)$ těžší
 $D(f) \geq \Omega(\lg n)$... triko

Kombinatorický obdělání

$$X = \{0,1\}^n \quad Y = \{0,1\}^n$$

$A \subseteq X \quad B \subseteq Y \quad A \times B \dots$ kombinatorický obdělání


- $A \times B \subseteq X \times Y$
- $R \subseteq X \times Y$ je kombinatorický obdělání
 $\Leftrightarrow \forall (x,y), (x',y') \in R; (x,y') \in R$.

Důk: " \subseteq " $A = \{x; \exists y (x,y) \in R\}$ " \Rightarrow " triv.

$$B = \{y; \exists x (x,y) \in R\}$$

- $R \subseteq A \times B$ triv.
- $A \times B \subseteq R : (x,y) \in A \times B \Rightarrow \exists x',y' (x,y') \in R \ \& \ (x',y) \in R$
 $\Rightarrow (x,y) \in R$ \square
predpoklad

Problém P:



$R_P = \{(x,y); \text{na vstupě } x, y \text{ Alena \& Bob dojdou do } v\}$

• R_P je kombinatorický obdělání.

Důk: 1) inanké podle hlavy v .

nebo 2) "cut-and-paste" argument \square

- Problém P počítá f , pak pro každý list $l \in P$, vstup $v \in R$ má stejnou hodnotu $f(x,y)$.

\rightarrow jednobarevný obdělání

M_f


	00-0	111-1
00-0	0 1 0 1 1 0 1	
0-0	1 0 0 0 1 0 1	
0-1	0 1 0 1 1 0 1	
1111	1 1 1 0 1 1 0	

$\swarrow f(x,y)$


\rightarrow jednobarevný obdělání

\rightarrow každý problém dá se převést na jednobarevný obdělání

- Pokud f yřadí na pozici t jedobarejda obdělku, pak $D(f) \geq \log_2 t$.



Po: 1) $EQ(x, y) = [x \stackrel{?}{=} y]$



$\geq 2^n + 1$ obdělku - žádná dvě jednotky nemohou být ve stejném obdělku.
jedobarejda

$$\Rightarrow D(EQ) \geq \log_2 2^n + 1 > n$$

$$D(EQ) \leq n + 1 \Rightarrow D(EQ) = n + 1. \quad \square$$

2) $DISS(x, y) = [x_i; x_i = y_i = 1?]$

ustroj (x, \bar{x}) má n řádků jedobarejda obdělku

$$\Rightarrow \geq 2^n + 1 \text{ obdělku}$$

$$D(DISS) \geq n + 1 \Rightarrow D(DISS) = n + 1 \quad \square$$

- Pokud hodnost matice M_f je alespoň n , pak $D(f) \geq \log_2 n$.

Dk: vezměme si protokol P pro f .

$$M_f = \sum_{\substack{e \text{ list } P \\ \text{prohody } 1}} M_e$$

$$M_e(x, y) = \begin{cases} 1 & (x, y) \in R_e \\ 0 & \text{jinak} \end{cases}$$

$$\text{hodnota } (M_e) \leq 1$$

$$\Rightarrow \text{hodnota } M_f \leq \text{počet listů } P$$

$$\parallel$$

$$\log r \leq D(f) \quad \square$$

Pr: 1) hodnota $(M_{IP}) = 2^n$

2) hodnota $(M_{IP}) \geq 2^n - 1$

$$\Rightarrow D(IP) \geq n.$$

$$(M_{IP})^2 = \begin{array}{c} 0 \\ \hline \begin{array}{cc} 2^{n-1} & 2^{n-2} \\ \vdots & \vdots \\ 2^{n-2} & 2^{n-1} \end{array} \end{array}$$

Příklady polyh. matice M_f oddělení

Pr: 1)

1	0	0
1	1	1
0	0	1

∃ polyh. s oddělení, ale neexistuje protobol polyh. s oddělení.

2)

1	1	0
1	1	1
0	1	1

∃ přelýrající a polyh. s 4 oddělení

→ různé míry složitosti

$C^P(f)$... nejmenší množství prout dodělané dání celého protokolu pro f


$C^D(f)$... nejmenší množství prout obdelání pokrytí se nepřekrytí se matice M_f

$C(f)$... nejmenší množství prout obdelání pokrytí M_f

Propozice: $C(f) \leq C^D(f) \leq C^P(f) \leq 2^{D(f)}$

→ nedeterministický komunikační protokol:

P ... všemožný deterministický, který má x a y



m ... dílčí zpráva

$f(x, y) = z$

A

B

$x \in \{0, 1\}^n$

$y \in \{0, 1\}^n$

Alice a Bob si vymění 1 bit každý, zda souhlasí s dílkem.

PF: $EQ(x, y) = 0$... m je index k tomu, kde se liší

$|m| = \log_2 n$

$EQ(x, y) = 1$... m je celý řetězec x .

$|m| = n$ bitů

- každá zpráva m od P definuje z-barevné obdelání
- # prout množiny zpráv = # pokrytí obdelání

• $N(f) = \lg_2 C(f)$... nedeterministická složitost f

$$N'(f) = \lg_2 C'(f)$$

$$N^o(f) = \lg_2 C^o(f)$$

$C^z(f)$... nejmenší počet z -krokových zátok

Pr: $N^o(EQ) = \lg n$

$$N'(EQ) = n$$

$$N^o(DISC) = n$$


$$N'(DISC) = n$$

C vs D

Lemma: $\lg_2 C^P(f) \leq D(f) \leq 2 \lg_{3/2} C^P(f)$

Dk: 1. " \leq " triviálně

2. " \leq " ... s protokolem nalezní podstrom s $\frac{1}{3} \leq \leq \frac{2}{3}$ listů a přesuní na vrch



→ zvýšení protokolu




otázka: $D(f) = O(\lg C^D(f))$?

Viz: $D(f) = O(N^o(f) \cdot N'(f))$.

Dk: idea:

rekursivně, $\exists_0 f(x,y) = 1$





- každý 0-obsáhlivý může prohlédnout pouze buď v řádcích, nebo sloupcích

Problém: $A \times B$ najít maximální "živý" 0-obs.

- 1) Pokud všechny 0-obs. metru, A vyhledat $f(x,y)=1$
- 2) A se podívá, zda \exists 1-obs., který obsahuje sloupec y a ve sloupcích problému vyjítí problem živý 0-obs. Pokud ano, pokračuje 1-obs. Během. Jinak ukončí B
- 3) B se podívá, zda \exists 1-obs. obsahující řádek x , který v řádcích problému $\leq k$ živý 0-obs. Pokud ano, pokračuje jako číslo A ence. Jinak skončí s tím, že $f(x,y)=0$.

\rightarrow maximum $\lg C'(f)$ kd a kázané
kde $o(f) = O(\lg C'(f))$ $\leq k$


Ověřte: $\forall f: D(f) = O(\lg \text{hodnota}(M_f))^{O(1)}$?
... "log-rank conjecture"

Pravidlo dobroty' protokoly

$\forall A \in \{0,1\}^*$ A klen
 $n \leq 10 \dots$

B s
 $n \leq 10 \dots$ $r_B \in \{0,1\}^*$

$\forall A \in \{0,1\}^*$ Alice
 $x \in \{0,1\}^n$



Bob
 $y \in \{0,1\}^n$ $r_B \in \{0,1\}^*$

- zprávy Alice můžeme zvládnout tím, že na r_A
- -||- Boba -||- r_B

→ ve stranném protokolu v ústředí v partitice
 Alice máme f_i $M_v : \{0,1\}^n \times \{0,1\}^* \rightarrow \{0,1\}$
 $\times \quad r_A \quad M_v$
 Boba -||- $M_v : \{0,1\}^n \times \{0,1\}^* \rightarrow \{0,1\}$
 $y \quad r_B$

- listy opit obsahují: výstupní hodnotu

chceme: protokol P počítá f s chybou $\epsilon \geq 0$
 pokud

$$\forall x, y \quad \Pr [P(x, y) = f(x, y)] \geq 1 - \epsilon$$

- zajímá nás minimální délka komunikace na daném vstupě x, y . Cena protokolu je nejdelší (nejhorší) průměrná délka na nejhorším x, y .
- $R_\epsilon(f)$ = minimální cena protokolu P , který počítá f s chybou $\leq \epsilon$.

$$R(f) := R_{1/3}(f)$$

Winnikotův δ : kdyby byla cena definice pouze
 nejdelší komunikace na x, y , v žití

by se moc rozměřilo, neboť každý protokol lze zkrátit po $1/\epsilon$ -násobku průměrné délky a to zhorší chybu nejvýše o ϵ .

Rf: $R(\epsilon D) = O(\lg n)$


Michal Koucky at 16. 5. 2016 22:29

Lemma: $R(f) \geq \Omega(\lg D(f))$

Dk: ukážeme, že $D(f) \leq 2^{O(R(f))}$.

- vezmeme pevný protokol pro f s chybou $\leq 1/3$ a maximální hloubkou $d = O(R(f))$.
- Protokol má nejvýše 2^d listů.

Na větvích x a y je pravděpodobnost p_e dosažení listu l dána součinem pravděpodobností p_e^x a p_e^y , kde p_e^x je pravděpodobnost, že Alenka v jejích úkolech na větvích x jde směrem k l a podobně p_e^y pro Boba.



p_e^x je samo součinem pevných v jednotlivých Alenčiných

uzleku a sdějí p_e^y .


Det. protokol pro f : Alenka spočítá při p_e^x pro
všech listy l a pošle tuto informaci
Bobovi. Ten spočítá svoje p_e^y a zjistí
výslednou prot. jednotlivých výstupů. Výsledky
odpovídá s nejvyšší přesností.

Každou z hodnot p_e^x Alenka pošle s přesností
 $d+10$ bitů, tj. zanedbatelnou chybu

$2^{-(d+10)}$ velikost chyby při výpočtu p_e^y .
Jednotlivou odpovídá je tak $\leq 2^d \cdot 2^{-(d+10)}$
 $\leq \frac{1}{1000}$

Komunikace vyžaduje $\leq 2^d \cdot (d+10) + 1$ bit

• protokol s veřejnými náhodnými bity:




- Alenka i Bob dostanou zadanou společně náhodně
řetězec r .

Věta: protokol s veřejnými náhodnými bity lze simulovat
se soukromými posíláním $O(\log k)$ bitů navíc.
(Dojde k minimálnímu nárůstu chyby.)

Důk: idea: lze zvolit množinu R $n^{O(1)}$ řetězců r t.č.

dyba protokolů na každém vstupu (x, y) se
 při práci zula náhodně r a náhodně r
 vybraných z naší množiny R (síl práce
 $0 \leq \frac{1}{nO(1)}$). [Toto práce z číselný už
 při zvolení si množiny R zula náhodně.]

Simulace protokolů s úměrnými náhodnými bity
 pak probíhá tak, že Alice pomocí svého R_a
 vybere náhodně řetězec r z R a komunikuje ho Bobovi.
 Index tohoto řetězce lze kódovat $\log |R| = O(\log n)$ bity 

P2: EQ s úměrnými bity vs soukromými.
 $O(1)$ vs. $\Theta(\log n)$
 \uparrow
 $R(f) \geq \Omega(\log D(f))$
 $\Omega(\log n)$

Vida: $R(DIFS) \geq \Omega(n)$.

Použití komunikační složitosti:

Data streams

Výpočetní model



Alg.

Algoritmus má pouze omezenou paměť, nedobře si zapamatovat celý vstup.

Pr: data jsou celé čísla \rightarrow intervalu $[0, n]$

chci znát:

- 1) celkový součet - snadný
- 2) průměr - snadný
- 3) počet různých prvků - lze s malou pamětí pravděpodobně algoritmem (aprox.)
- 4) kolikrát se vyskytl nejčastější prvek - vyžaduje paměť $O(n)$.

Dk: vlna $D(DIST) \geq n$.

ukážeme, že obvyklý algoritmus pro 4) s malou pamětí implicitně přilivá efektivní protokol pro DIST.

mějme alg. A pro 4). Protokol pro A & B funguje následujícím způsobem:


Aleba
 $x \in \{0, 1\}^n$

Bob
 $y \in \{0, 1\}^n$

Aleba vytvoří posloupnost prvků i t.j. $x_i = 1$
tuto posloupnost zpracuje alg. A.

Aleba
 $i; x_i = 1$

Bob
 $\underline{j; y_j = 1} \rightarrow$



poté star panů algoritmu A poté Bobem.
 Ten vytrhne' jednoduchost $j; y_j = 1$ a
 zpracuje j algoritmem.


Poznámka! $DIST(x, y) = 1 \Leftrightarrow$ nejčastěji s'
 pane se u dotaz vytrhne' a
 Alenka a Bobem vyskytje
 právo držet.

→ objem komunikace mezi Alenka a Bobem
 je ovlivněn panů' použitím algoritmu.
 (+1 bit na sdělení výsledku A leže)

→ A musí' používat panů' $\Omega(n)$ bitů. 13

Stjně' trvá' s identickým' disketem plech' pro
 postul algoritmy


Datová' struktura



datová struktúra uchováva nějaké data a odpovídá
o ní data

Pr: d.s. pro množinu $S \subseteq U$ $U = \{1, \dots, |U|\}$
data typu $[x \in S]$ pro každé $x \in U$

máme implementace



data — čas $O(1)$

prostor $|U|$ špatně, pokud $|S| \ll |U|$

2) hashovací tabulka



čas na data — $O(1)$

prostor $O(|S|)$

Pozn: není $O(1)$ jako $O(1)$
 \uparrow \uparrow
 1-bit $O(\lg n)$ -bit
 1) 2)

• Chci datovou strukturu pro lineární prostor

d.s. uchováva $V \subseteq GF_2^n$, V lineární prostor

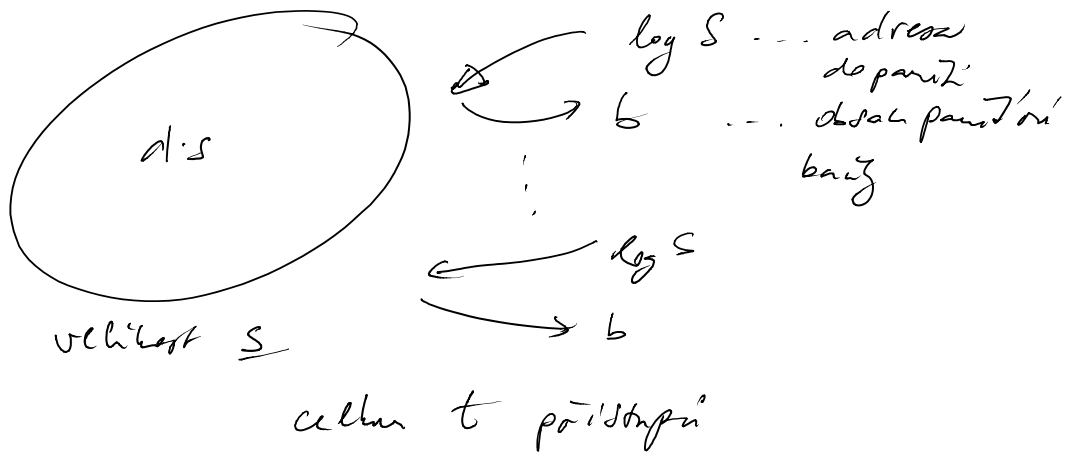
data: $[y \in V]$; $y \in GF_2^n$

řešení: triviální — pokud odpovídá na všechny možné
data \rightarrow prostor 2^n bitů
čas na data $O(1)$

• V se dá popsat n vektory, každý potřebuje
 n bitů \rightarrow stačí n^2 bitů
 báze V na papíře V


otázka: \exists d.s., která by měla $n^{O(1)}$ bitů
a "rychlou" zodpověď dotazu $[y \in V]$?

návrh: # přístupů do paměti d.s.
při každém přístupu přičteno b bitů



Řekneme, že $b = n$. Kolik přístupů potřebujeme,
když $S = n^{O(1)}$?

odpověď:



A množina kommitů a bitů • kolik musí být
B množina kommitů b bitů a & b ?

Trivial: $a \geq n/6$ nebo $b \geq n^2/12 - n/6$
díkům ničím.

způsob datové struktury:


datová struktura pro $[y \in V]$, kde na každé
dotaz potřebujeme nejvýše t přístupů $[y \in V]$

data: u, v - u - v
 data potřebujeme nejrychleji přístup
 do paměti data komunikací protokolu pro $[y \in V]$
 kde Alenka potřebuje $\log s$ bitů a Bob $t \cdot b$.

\Rightarrow (Tvzení) d.s. pro $[y \in V]$ s $b = n$ vyžaduje
 alespoň $\Omega(n / \log s)$ přístupů do
 paměti na dotaz, tj. $\Omega(n / \log n)$ pro $s = n^{O(1)}$.

Dk:

matrika M je (u, v) -křížka, pokud obsahuje
 alespoň v sloupců s alespoň u jednotkami.



Tvzení: Pokud f je funkce s (u, v) -křížkou matriky M_f
 a protokol pro f , kde Alenka pošle a bitů
 a Bob b , pak M_f obsahuje jednobarevné
 1-obdélníky o rozměrech $\geq \frac{u}{2a} \times \frac{v}{2at}$.

Dk: indukce podle $a+b$

1) $a+b = 0$




zjevně $M_f \equiv 1$ protože A a B nepřijíždí
 komunikovat

$\Rightarrow M_f \geq u \times v$ ✓

2) $a+b-1 \quad \checkmark \quad \Rightarrow \quad a+b$

dvě případy

a) Alenka pošle první bit




bud' podmatice $A_0 \times B$ nebo $A_1 \times B$

je $\left(\frac{u}{2}, \frac{v}{2}\right)$ -křídla

$$\Rightarrow \text{inverze } M_f \text{ obsahuje } \frac{\frac{u}{2}}{2^{a-1}} \times \frac{\frac{v}{2}}{2^{(b-1)u}} \quad | \text{-obd.}$$

$$= \frac{v}{2^a} \times \frac{v}{2^{a+b}} \quad \checkmark$$

b) Bob posílá první bit



bud' $A \times B_0$
nebo $A \times B_1$,
je $\left(u, \frac{v}{2}\right)$ -křídla

$$\Rightarrow \text{inverze } \frac{u}{2^a} \times \frac{\frac{v}{2}}{2^{a+(b-1)}} = \frac{v}{2^a} \times \frac{v}{2^{a+b}} \quad | \text{-obd.}$$

• Matice $[y \in V]$

je 1) $\left(2^{n/2}, 2^{n^2/4}\right)$ -křídla

2) neobsahuje jednorázovou 1-obdélníkovou velikost $2^{n/3} \times 2^{n/6}$.

1) & 2) \Rightarrow pokud by existoval protok, kde Alice posílá

$n/6$ bitů a Bob $\frac{n^2}{12} - \frac{n}{6}$, pak


by matice $[y \in V]$ obsahovala 1-obd.

$$\text{velikosti: } \frac{2^{n/2}}{2^{n/6}} \times \frac{2^{n^2/4}}{2^{n/6 + n^2/12 - n/6}} =$$

$$= 2^{n/3} \times 2^{n^2/6} \text{ což by bylo spor s 2).}$$

$$\text{Teď } a \geq n/6 \text{ nebo } b \geq \frac{n^2}{12} - \frac{n}{6}$$

zbylé obdrží 1) a 2)




$\left(\begin{array}{c} \diagup \diagdown \\ \diagdown \diagup \end{array} \right)$
 $V + \bar{2}$. $\dim V = \frac{n}{2}$ obšahují $2^{n/2}$
 rýněd vektorů z \mathbb{GF}_2^n
 teg jsou $2^{n/2}$ - tóřku'

$\#V$; $\dim V = \frac{n}{2} \geq 2^{n^2/4}$:

$\#$ bází v el. $\frac{n}{2}$ (lin. nezávisl. $\frac{n}{2}$ -k' vektorů) $\rightarrow \frac{\prod_{i=0}^{n/2-1} (2^n - 2^i)}{\prod_{i=0}^{n/2-1} (2^{n/2} - 2^i)} = \prod_{i=0}^{n/2-1} \frac{2^n - 2^i}{2^{n/2} - 2^i} \geq \prod_{i=0}^{n/2-1} 2^{n/2} \geq 2^{n^2/4}$

$\#$ bází prostoru V $\dim \frac{n}{2}$

$\Rightarrow \#V \dim \frac{n}{2} \geq 2^{n^2/2} / 2^{n^2/4} = 2^{n^2/4}$



A obšahje alespí $n/3$ lineárně nezávislých vektorů.

$\forall V \in B; \langle A \rangle \subseteq V$

\Rightarrow stáčí vřadit do bázise $n/6$ vektorů na ziskání báze V . $\Rightarrow |B| \leq (2^n - 1)^{n/6} \leq 2^{n^2/6}$