

(1)

- M. Koucký, IUVK, MS, 3. patro
- kdo jste? - pravděpodobnost?, distribuční metrika?, složitost?
- Doněw úlohy - 4 50% bodů, 3/4 sad
↳ pokud přijete sporn → Ache
- Informace: 1) "V poledne přijdu na oběd"
2) "Prezident des stát odstoupil s tím, že ho již nebudí být prezidentem."
3) "Hrubá mast uletěla ve dřevě"

• překvapení & význam

- 1) málo překvapení
- 2) hodně překvapení, má význam
- 3) hodně překvapení, nemá žádný význam

→ někdo zajíma překvapení, význam neumíme analyzovat
↓
pravděpodobnost

Informace:

1) $I(A)$ ukazují s roztomelí prk. A

Pr: zavedem balíček 32 karet, jedna karta je

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

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

$$I(A \& B) \geq I(A), I(B) \quad I(B) \geq I(A)$$

2) aditivita $I(A \& B) = I(A) + I(B)$
A, B nezávislé

3) $I(A) \geq 0 \quad \forall A$

$$s) I(A) \geq 0 \quad \forall A$$

$$\rightarrow I(A) = -\log_a P(A) \quad \left\{ \begin{array}{l} \text{pro výsledek} \\ \text{z systému } a \end{array} \right.$$

\rightarrow alternativní přístup: Kolmogorovské složitost

Operativní přík:

- jev, prostor přík, náhodná proměnná
- nezávislé jevy
- očekávané hodnoty
- Markovova věrovnost

\rightarrow (neurčitost)

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

konvence: $0 \cdot \log 0 = 0$

• $H(X) \geq 0$ uk: $H(X) = -\sum p(x) \log p(x)$

$\log p(x) < 0$ pro $0 < p(x) < 1$

• $H(X) \leq \log |X|$
 $\underbrace{\quad}_{\rightarrow \text{supp}(X)}$

Př: X na $\{0, 1\}^n$

1) $\forall x \in X; \quad p(x) = 2^{-n}$

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


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

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

(2)

2

Pr: $H(p) = -p \log p - (1-p) \log (1-p)$



společná entropie : X, Y n.p.

$$H(X, Y) = - \sum_{\substack{x \in X \\ y \in Y}} P(x, y) \log P(x, y)$$

$$= - E_{xy} \log P(X, Y)$$

podmíněná entropie

$$H(Y|X) = \sum_{\substack{x \in X \\ P(x) > 0}} P(x) H(Y|X=x)$$

$$= - \sum_{x \in X} P(x) \sum_{y \in Y} P(y|x) \log P(y|x)$$

$$= - \sum_{x \in X} \sum_{y \in Y} P(x, y) \log P(y|x)$$

$$= E_{xy} \log P(Y|X)$$

Pr: 1) $H(X|X) = 0$

2) $H(X|Y) = H(X)$ pokud X & Y jsou nezávislé

1.27 ("chain rule")

Def: ("chain rule")

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

Dk:

$$\begin{aligned} H(X, Y) &= - \sum_{x \in X} \sum_{y \in Y} p(x, y) \cdot \log p(x, y) \\ &= - \sum_{x \in X} \sum_{y \in Y} p(x, y) \cdot \log p(x) p(y|x) \\ &= - \sum_{x \in X} \sum_{y \in Y} p(x, y) (\log p(x) + \log p(y|x)) \\ &= - \underbrace{\sum_{x \in X} p(x) \log p(x)}_{H(X)} - \underbrace{\sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y|x)}_{H(Y|X)} \end{aligned}$$

Distributiv:

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

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

Vzájemná informace:

$$\begin{aligned} I(X; Y) &= H(X) - H(X|Y) \\ &= H(Y) - H(Y|X) \end{aligned}$$

... o kolik se snížila neuvěřitelnost X, když znám Y.

Př: a) $I(X; X) = H(X) - H(X|X) = H(X)$

b) X, Y nezávislé, $I(X; Y) = H(X) - H(X|Y) = 0$

c) $X = \text{fair die}$ $I(X; Y) = 0$ $I(Y; Z) = 0$
 $Y = \text{fair die}$ $I(X; Z) = 0$
 $Z = X + Y \text{ mod } 6$ $I(X, Y; Z) = H(X, Y) - H(X, Y|Z) = H(Y) = H(X)$

d) $X = \mathbb{R}^{0^n}$ s $\text{pdf}' \frac{1}{2}$

$$d) X = \begin{cases} 0^n & \text{s prob' } \frac{1}{2} \\ x \in \{0,1\}^n \setminus \{0^n\} & \text{s prob' } \frac{1}{2} \cdot \frac{1}{2^n-1} \end{cases}$$

$$Y = \begin{cases} 0 & \text{if } X = 0^n \\ 1 & \text{else} \end{cases}$$

$$H(X) = \frac{n}{2} + O(1)$$

$$H(X|Y=1) \approx n-1$$

$$H(X|Y=0) = 0$$

$$H(X|Y) \leq \frac{n}{2}$$

Př: "Secret sharing scheme".

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

Kullback-Leiblerova vzdálenost: (Kullback-Leibler divergence)

$$D(p \parallel q) = \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)}$$

Uvaha: $0 \cdot \log \frac{0}{0} = 0$

$$D(p \parallel q) = - \sum_{x \in X} p(x) \log q(x) + \sum_{x \in X} p(x) \log p(x)$$

Uvaha: $0 \cdot \log \frac{0}{0} = 0$, $0 \log \frac{0}{2} = 0$, $p \log \frac{p}{0} = \infty$

• uváďme $D(p \parallel q) \geq 0$

• měří, o kolik se prodlouží kód, když použijí nesprávnou distribuci

$$\bullet I(X; Y) = D(p(x, y) \parallel p(x) \cdot p(y))$$


$$= - \sum_{x \in X} p(x) \log p(x) + \sum_{x, y} p(x, y) \log p(x, y)$$

$$= - \sum_{x, y} p(x, y) \log p(x) + \sum_{x, y} p(x, y) \log p(x, y)$$

$$\begin{aligned}
 &= \sum_{x,y} p(x,y) \ln p(x) - \sum_{x,y} p(x,y) \ln p(x,y) \\
 &= \sum_{x,y} p(x,y) \ln \frac{p(x)}{p(x,y)} = - \sum_{x,y} p(x,y) \ln \frac{p(x,y)}{p(x)p(y)}
 \end{aligned}$$

• fu f je konvexní na (a,b) , pokud $\forall x_1, x_2 \in (a,b)$ (3)
 $\forall 0 \leq \lambda \leq 1$

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



• Jensenova nerovnost: f je konvexní fu a X je n.p. s hodnotami z (a,b) , pak

$$E[f(X)] \geq f(E[X])$$

Důkaz: $p(x_1) = \lambda$ $p(x_2) = (1-\lambda)$

definice konvexnosti \Rightarrow tvrzení
 dále indukce

• $p(x_1) = p_1$ $p(x_2) = p_2$... $p(x_n) = p_n$

$$\sum_{i=1}^n p_i f(x_i) = p_n f(x_n) + (1-p_n) \sum_{i=1}^{n-1} p'_i f(x_i)$$

• kde $p'_i = \frac{p_i}{(1-p_n)}$

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

$$= \sum_{i=1}^n p_i x_i \quad \square$$

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

Pak $D(p \parallel q) \geq 0$

Důk: označ $A = \{x; p(x) > 0\}$. Pak

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

• Remark $D(p \parallel q) = 0$ právě pro $p = q$

Důsledek: $I(x; y) \geq 0$

Důk: $I(x; y) = D(p(x, y) \parallel p(x) \cdot p(y)) \quad \square$

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

Důk: def. $u(x) = \frac{1}{|X|}$, p je dist. pro X

$$D(p \parallel u) = \sum p(x) \log \frac{p(x)}{u(x)} = \log |X| - H(x)$$

$$0 \leq D(p \parallel u) \Rightarrow H(x) \leq \log |X| \quad \square$$

Důsledek: $H(x|y) \leq H(x)$, rovnost iff x, y nezávislé

Důk: $0 \leq I(x; y) = H(x) - H(x|y) \quad \square$

Důl: $0 \leq I(X:Y) = H(X) - H(X|Y)$ \square

- X, Y, Z náhodný proměnné, podmíněná informace X o Y , když je dáno Z :

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

$$= \sum \Pr[Z=z] \cdot H(X|Z=z)$$

$$H(X_1, \dots, X_n) = \sum_z \Pr[Z=z] \cdot H(X|Y, Z=z)$$

$$= H(X|Z) - \sum_z \Pr[Z=z] \sum_y \Pr[Y=y|Z=z] \cdot H(X|Y=y, Z=z)$$

$$= H(X|Z) - \sum_{y,z} \Pr[Z=z \& Y=y] H(X|Y=y, Z=z)$$

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

- $H(X_1, X_2, X_3, \dots, X_n) = H(X_1) + H(X_2|X_1) + \dots + H(X_n|X_1, \dots, X_{n-1})$

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

- $I(X_1, X_2, \dots, X_n : Y) = \sum_{i=1}^n I(X_i : Y | X_1, X_2, \dots, X_{i-1})$

Důl: $I(X_1, \dots, X_n : Y) =$


$$H(X_1, \dots, X_n) - H(X_1, \dots, X_n | Y)$$

$$= \sum_{i=1}^n H(X_i | X_1, \dots, X_{i-1}) - H(X_i | X_1, \dots, X_{i-1}, Y)$$

$$= \sum_{i=1}^n I(X_i : Y | X_1, \dots, X_{i-1})$$



Př:



$$I(X:Y) \rightsquigarrow I(X:Z) ?$$

X u Z ... 'bratřím'

$$I(X:Y) \geq I(X:Z)$$

X, Y, Z nek. proměnné

Def: X, Y, Z splňují: markovskou vlastnost, pokud
 $X \rightarrow Y \rightarrow Z$
 $\forall x, y, z$

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

- $P(z|y) = P(z|y, x)$
 - $P(x, z|y) = P(x|y) P(z|y, x) = \underbrace{P(x|y) P(z|y)}_{P(x, z|y) = P(x|y) P(z|y)}$
 $= P(z|y) P(x|y, z)$
- $\Rightarrow P(x|y) \cdot P(z|y) = P(z|y) \cdot P(x|y, z) \Rightarrow P(x|y, z) = P(x|y)$
 $\Rightarrow (X \rightarrow Y \rightarrow Z \iff Z \rightarrow Y \rightarrow X)$
 symetrie \updownarrow

Věta (Data processing inequality): X, Y, Z n.p. splňující markovskou vlastnost Pak

$$I(X:Y) \geq I(X:Z)$$

Důk:

$$I(X:Y, Z) = I(X:Y) + I(X:Z|Y)$$

$$= I(X:Z) + I(X:Y|Z)$$

$I(X:Z|Y) = 0$ protože X & Z jsou
 vzájemně podmíněné na Y

$I(X:Y|Z) \geq 0$ navíc

$\Rightarrow I(X:Y) \geq I(X:Z)$ \square

Fanoova nerovnost

$$X \rightarrow Y \rightarrow \hat{X}$$

$P_e = Pr[X \neq \hat{X}] \dots$ pr. chyby

• $H(X) \geq H(X|Y) \geq H(X|\hat{X}) \geq H(X|Y)$

Pr. ... $L \wedge T \wedge \dots$

$$H(p_e) + p_e \log |X| \geq H(X|\hat{X}) \geq H(X|Y)$$

Důsledek: $1 + p_e \log |X| \geq H(X|Y)$

neboli $p_e \geq \frac{H(X|Y) - 1}{\log |X|}$

$p_e = 0 \Rightarrow H(X|Y) = 0$... odpořídání instrukcí

Důk:

def. n.p. $E = \begin{cases} 1 & \hat{X} \neq X \\ 0 & \hat{X} = X \end{cases}$

$$H(X, E | \hat{X}) = H(X | \hat{X}) + \underbrace{H(E | X, \hat{X})}_{=0}$$

$$= H(E | \hat{X}) + H(X | E, \hat{X})$$

$$\leq H(p_e) + \underbrace{Pr\{E=0\} H(X | \hat{X}, E=0) + Pr\{E=1\} H(X | \hat{X}, E=1)}_{\leq 0 + p_e \log |X|}$$

$$\Rightarrow H(X | \hat{X}) \leq H(p_e) + p_e \log |X|$$

podle data-processing inequality $I(X; \hat{X}) \leq I(X; Y)$

$$\Rightarrow H(X | \hat{X}) \geq H(X | Y) \quad \square$$

Důsledek: $\forall X, Y$ n.p., $p = Pr\{X \neq Y\}$

$$H(p) + p \log |X| \geq H(X|Y)$$

Důk: $\hat{X} = Y$ & use Fano. \square

Čeť vylepšit pokud $\hat{X} \subseteq X$ w

$$1/(n-1) \dots 0 \dots (|X|-1) > 1/(|X|-1)$$

Učte vglepiti poševni $X \subseteq X$ in

$$H(p_c) + p_c \lg(|X|-1) \geq H(X/Y)$$

- Členi pro 4 konst., $X = \{1, \dots, m\}$, $(1-p_c, \frac{p_c}{m-1}, \dots, \frac{p_c}{m-1})$
- $$H(p_c) + p_c \lg(m-1) \geq H(X) \quad 1-p_c \geq \frac{p_c}{m-1}$$

• X, X' n.p. n.i.i.d. $\Pr[X=X'] = \sum_x p^2(x)$

$$\Pr[X=X'] \geq 2^{-H(X)}$$

(izost $\Leftrightarrow X$ je uniformni)

Dk: $X \sim P(x)$.

$$2^{\mathbb{E} \lg P(x)} \leq \mathbb{E} 2^{\lg P(x)}$$

↓ Jensenova neenakost

$$2^{-H(X)} = 2^{\mathbb{E} \lg P(x)} \leq \sum_x p(x) 2^{\lg P(x)} = \sum_x p^2(x)$$

"Asymptotic Equipartition property"

x_1, x_2, \dots nezavisli neodvisni razdeljeni jako X

Trazen, $\forall \epsilon, \delta > 0 \exists n_0 \forall n \geq n_0$

$$\Pr \left[2^{-n(H(X)+\epsilon)} \leq p(x_1, x_2, \dots, x_n) \leq 2^{-n(H(X)-\epsilon)} \right] \geq 1-\delta$$

Primerjava: • $\text{Var}[X] = \mathbb{E}[(X - \mathbb{E}(X))^2]$

• poševni x_1, x_2, \dots, x_n vzajemno nezavisni p.k.

$$\text{Var}[x_1 + x_2 + \dots + x_n] = \text{Var}[x_1] + \dots + \text{Var}[x_n]$$

• Čebyševova nek: $\Pr[|X - \mathbb{E}(X)| \geq a] \leq \frac{\text{Var}[X]}{a^2}$

• čelýjstovaz vzok : $\Pr[|X - \mathbb{E}[X]| \geq a] \leq \frac{\text{Var}[X]}{a^2}$

Dle : uvazijme $-\log p(x_1), -\log p(x_2), \dots, -\log p(x_n)$
n.p.

$$\mathbb{E}[-\log p(x_i)] = H(x_i) = H(x)$$

$$\begin{aligned} & \Pr\left[\left|\sum_{i=1}^n -\log p(x_i) - \mathbb{E}\left[\sum_{i=1}^n -\log p(x_i)\right]\right| \geq \varepsilon n H(x)\right] = \\ & = \Pr\left[\left|\sum_{i=1}^n -\log p(x_i) - n H(x)\right| \geq \varepsilon n H(x)\right] \\ & \leq \frac{n \cdot \text{Var}[-\log p(x)]}{\varepsilon^2 n^2 [H(x)]^2} = \text{cond. } \frac{1}{n} \xrightarrow{n \rightarrow \infty} 0 \end{aligned}$$

→ s velkou pští, vzorek x_1, \dots, x_n má pšt. $\approx n H(x)$

$$\bullet A_\varepsilon^n = \left\{ (x_1, \dots, x_n) \in X_1 \times X_2 \times \dots \times X_n, \text{ t. } \mathbb{E} \cdot \right. \\ \left. 2^{-n(H(x)+\varepsilon)} \leq p(x_1, \dots, x_n) \leq 2^{-n(H(x)-\varepsilon)} \right\}$$

$$(1-\varepsilon)2^{n(H(x)+\varepsilon)} \leq |A_\varepsilon^n| \leq 2^{n(H(x)+\varepsilon)} \quad \text{pro dostatek velkých } n.$$

⇒ ukážeme n-tic

$$(y_1, y_2, \dots, y_n) \in A_\varepsilon^n \rightarrow \text{index } i \text{ v řánci } A_\varepsilon^n$$

kod → 0 i

$$(y_1, \dots, y_n) \notin A_\varepsilon^n \rightarrow \text{index } i \text{ v řánci } X^n$$

kod → 1 i

$(y_1, \dots, y_n) \in \Sigma^n \rightarrow$ index a řada n

kód \rightarrow 1v

očekávaná délka kódu:

$$\leq n(H(X) + \epsilon) + \delta n \log |X| + 2$$

$$\text{pro } \delta = \frac{\epsilon}{\log |X|}$$

$$\rightarrow n(H(X) + 2\epsilon) + 2$$

pro libovolný $\epsilon' > 0$ lze zvolit vhodné n , t.j. kódujeme s očekávanou délkou kódu

$$n(H(X) + \epsilon')$$

Př: $P(X=0) = 1/10$ $P(X=1) = 9/10$

$$P(X = |1111 \dots 1|) = \left(\frac{9}{10}\right)^n$$

↑ maximální $p(x)$.

ale tato kóduje neuvěřitelně.

kód: $C: X \rightarrow \Sigma^*$ $\forall x \neq y \quad C(x) \neq C(y)$

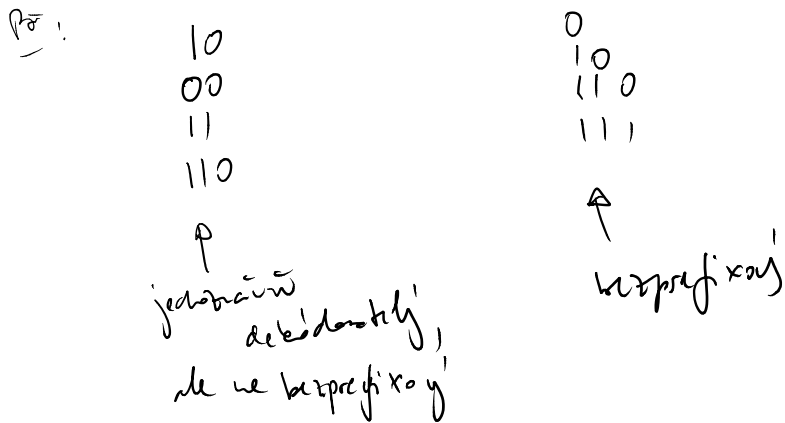
očekávaná délka: $L(C) = \sum_{x \in X} p(x) |C(x)|$

uztvar kód: $C^*(x_1, \dots, x_n) = C(x_1)C(x_2)\dots C(x_n)$

• kód je jednoznačně dekodovatelný pokud uztvar kód nemá kolizi.

• bezprefixový kód $C: \forall x \neq y \quad C(x)$ není prefix $C(y)$

Př: $\begin{matrix} 10 \\ 00 \end{matrix}$ $\begin{matrix} 0 \\ 10 \\ 110 \end{matrix}$



• Kraftova nerovnost: kód s délkami l_1, l_2, l_3, \dots

je bezprefixový \Rightarrow

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

Dk:



$$\sum 2^{l_{\max} - l_i} \leq 2^{l_{\max}}$$

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

□

• opětně implikace $\sum 2^{-l_i} \leq 1 \Rightarrow \exists$ bezprefixový kód.

• optimální kód: $l(x) \quad x \in X$
pro danou
distribuci X

optimální délka $L = \sum_{x \in X} p(x) l(x)$

$$L - H(x) = \sum p(x) l(x) - \sum p(x) \log \frac{1}{p(x)} =$$

$$= - \sum p(x) \cdot \log 2^{-l(x)} + \sum p(x) \log p(x)$$

$$l(x) = \frac{2^{-l(x)}}{2^{-l(y)}} \quad c = \sum_Y 2^{-l(y)}$$

$$= - \sum p(x) \log g(x) + \sum p(x) \log p(x)$$

$$= \underbrace{\sum p(x) \log \frac{p(x)}{q(x)}}_{D(p||q) \geq 0} - \underbrace{H_2 C}_{\geq 0} \in (0,1] \Rightarrow \geq 0$$

• Shannon-Fano kod : $l(x) = \lceil \log \frac{1}{p(x)} \rceil$.

• $H(x) \leq L(L) \leq H(x) + 1$

• optimalni - bezna koda a to kodiranje

$l(x) = H(x_1, x_2, \dots, x_k) \leq L(L) \leq H(x_1, \dots, x_k) + 1$

$\Rightarrow L(L) \leq H(x) + \frac{1}{k}$.

• Mc Millan : jednodimenzionalni dekadovski kod s $l(x)$

$\sum 2^{-l(x)} \leq 1$

\Rightarrow izračunati kraćky verovornost.

Dh : unika c_k

$$\left(\sum_x 2^{-l(x)} \right)^k = \sum_{x_1} \sum_{x_2} \dots \sum_{x_k} 2^{-l(x_1) - l(x_2) - \dots - l(x_k)}$$

$$= \sum_{\bar{x} \in X^k} 2^{-l(\bar{x})}$$

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

$c(m) = \# \text{ slov s de'elom } m$

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

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

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

• Huffmanov kod

$p_1 \geq p_2 \geq \dots \geq p_{n-1} \geq p_n$

$$\rightarrow p' = (p_1, p_2, \dots, p_{n-1} + p_n) \quad \text{v s\u00e9fekt}$$

bezpreferen\u010d\u00ed

• optim\u00e1ln\u00ed k\u00f3d m\u00e1 bez\u00edjny v\u00e1\u017eebnost:

1) s p\u00e1n\u00ed k\u00f3d d\u00edl\u00e1 slov

2) d\u00edl\u00e1 v\u00e1\u017eebn\u00ed slov j\u00e9n st\u00e1n\u00ed d\u00edl\u00e1

3) d\u00edl\u00e1 v\u00e1\u017eebn\u00ed slov, kter\u00e1 se l\u00ed\u010d\u00ed j\u00e9n s p\u00e1n\u00ed k\u00f3d

D\u00e1: trino. \Rightarrow

optim\u00e1ln\u00ed Huffman

$$p = (p_1, p_2, \dots, p_n)$$

$$p' = (p_1, p_2, \dots, p_{n-1} + p_n)$$

opt. k\u00f3d pro p & p' , jejich d\u00e9lka $l^*(p)$ & $l^*(p')$

\times $C^*(p')$ v\u00e1\u017eebn\u00ed k\u00f3d pro p roz\u00e1p\u00edn\u00e1 slov pro $p_{n-1} + p_n \rightarrow l(p)$

\times $C^*(p)$ v\u00e1\u017eebn\u00ed k\u00f3d pro p' ur\u00e1dn\u00e9 p\u00e1n\u00ed slov b\u00eddn\u00e1 d\u00edl\u00e1 v\u00e1\u017eebn\u00ed slov l\u00ed\u010d\u00ed se v p\u00e1n\u00ed slov b\u00eddn\u00e1. $\rightarrow l(p')$

$$l(p') = l^*(p) - p_{n-1} - p_n$$

$$l(p) = l^*(p') + p_{n-1} + p_n$$

$$\Rightarrow (l(p') - l^*(p')) + (l(p) - l^*(p)) = 0$$

$$\geq 0 \text{ opt.}$$


$$\geq 0 \text{ opt.}$$

$$\Rightarrow = 0 \text{ A}$$

$$= 0 \text{ A}$$

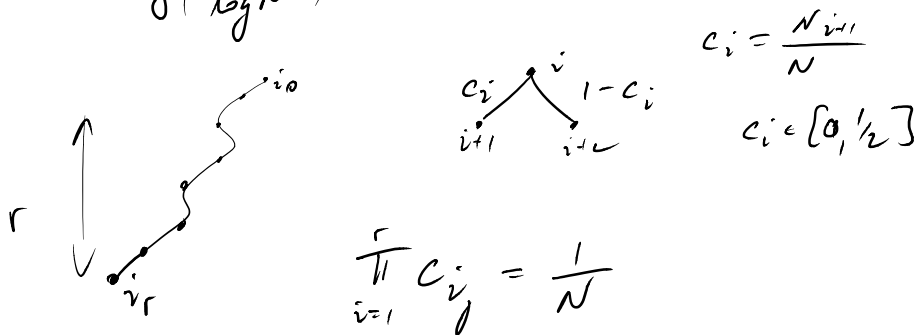
\Rightarrow " $C^*(p')$ optim\u00e1ln\u00ed $\Rightarrow C^*(p)$ optim\u00e1ln\u00ed"

• D\u00e9lka slov v t k\u00f3d



Jaká je celková cena všech seznamů délky N v r kódu
 $B(N, r)$

$$B(N, r) \geq \frac{N \log N}{4 \log \left(\frac{4r}{\log N} \right)}$$



$$\Rightarrow \left(\frac{1}{N} \right)^N = \prod c_i^{c_i N_i} (1-c_i)^{(1-c_i) N_i}$$

$$N \log N = \sum_i N_i H(c_i)$$

$$\bullet \sum_i N_i = rN$$

je \sum_i
všechny
uzly

$$\bullet c \stackrel{\text{def}}{=} \sum_{\text{všechny}} \frac{c_i N_i}{rN}$$

průměrná cena za
prvek při dělení

$$\bullet B(N, r) = c \cdot rN$$

H je konkávní \Rightarrow

$$\sum_i \frac{N_i}{rN} H(c_i) \leq H\left(\sum_i \frac{c_i N_i}{rN}\right) = H(c)$$

$$\Rightarrow N \log N = rN \sum \frac{N_i}{rN} H(c_i) \leq rN H(c)$$

Pohled $B(N, r) = crN < \frac{N \log N}{4 \log(\frac{4r}{\log N})}$

$$\rightarrow c < \frac{\log N}{4r \log(\frac{4r}{\log N})} \quad c = \frac{x}{-yx} \quad \text{pro } x = \frac{\log N}{4r}$$

$$\frac{\log N}{r} \leq H(c) = H\left(\frac{x}{-yx}\right) < 4x = 4 \frac{\log N}{4r} = \frac{\log N}{r}$$

Ukaž: $\forall x \in (0, \frac{1}{2}]$, $H\left(\frac{x}{1-x}\right) < 4x$

Důk: $y = \frac{x}{1-x}$ $x \in (0, \frac{1}{2}] \Rightarrow y \in (0, \frac{1}{2}]$

$$H(y) = y \log \frac{1}{y} + (1-y) \log \frac{1}{1-y}$$

$$\forall x y \leq \frac{1}{2} \quad y \log \frac{1}{1-y} \leq 2y \quad 1-y < 1$$

$$H(y) \leq y \log \frac{1}{y} + (1-y) 2y \leq y \log \frac{1}{y} + 2y$$

$$\rightarrow H\left(\frac{x}{1-x}\right) \leq x \left(\frac{\log \frac{1}{y}}{y}\right) + x \left(\frac{\log \frac{1}{1-y}}{1-y}\right) + 2x \left(\frac{1}{1-x}\right)$$

$$\leq 1 \leq 1 \leq 1$$

$$\leq 4x$$

• viz Brief introduction to Kolmogorov Complexity na moji webové stránce

synotič informace

$$C(x, y) = C(x) + C(y|x) + O(\log n)$$

- f ... částečně rekurzivní funkce $f: \{0,1\}^* \rightarrow \{0,1\}^*$

$$C_f(x) = \min\{|p|; p \in \{0,1\}^*, f(p) = x\} \dots \text{Kolmogorovská složitost } x \text{ vzhledem k } f.$$

- Věta: Existuje univerzální částeč. rek. fun $U + \Sigma$.

$$\forall \text{ č.r.f. } g \exists c_g \forall x \in \{0,1\}^*$$

$$C_U(x) \leq C_g(x) + c_g \quad \text{Dk: } \dots \square$$

$\Rightarrow U$ dávká nejmenší složitost ke všem č.r.f.

\rightarrow zafixujeme U

- $\forall x \quad C(x) \leq |x| + O(1)$
 $\forall n \quad C(0^n) \leq |n| + O(1)$
 $\hookrightarrow \sim \log n$

podmíněná Kolmogorovská složitost:

$$C_g(x|y) = \min\{|p|, p \in \{0,1\}^*, f(\langle p, y \rangle) = x\}$$

- Věta: \exists č.r.f. $U + \Sigma \quad \forall$ č.r.f. $g \exists c_g \quad \forall x, y$

$$C_U(x|y) \leq C_g(x|y) + c_g$$

\rightarrow zafixujeme U .

$$C(x) \stackrel{\text{def}}{=} C(x|\varepsilon)$$

- $\forall n \quad C(0^n|n) = O(1)$
 $\forall n \exists x \in \{0,1\}^n \quad C(x|n) \geq n \dots$ Kolmogorovský náhodný
 \uparrow
Dk: počet programů délky $\leq n-1$ je $2^n - 1$. \square

- A rekurzivně spřítelná množina

$$\forall x \in A \quad C(x|n) \leq \log |A^n| + O(1) .$$

$|x|=n$

$$c(x, y) \leq c(x) + c(y|x) + O(\log c(x, y))$$

Důk: program p pro x
 program g pro y když znám x

$O(\log c(x, y))$ extra info na separaci
 p a g

$$c(x, y) \geq c(x) + c(y|x) - O(\log c(x, y))$$

Důk: sporum. Předpokládejme, že pro každou konstantu k
 $\exists x, y$ t.č.

$$(H) \quad c(y|x) \geq c(x, y) - c(x) + k \log c(x, y)$$

def. $A = \{ \langle u, z \rangle; c(u, z) \leq c(x, y) \}$
 $A_x = \{ z; c(x, z) \leq c(x, y) \}$... rel. spočítat!

$$(Hx) \quad c(y|x) \leq \log |A_x| + 2 \log c(x, y) + O(1)$$

$\Rightarrow \forall k \exists x, y$

(*) (*)

$$|A_x| \geq 2^k$$

$$k = c(x, y) - c(x) + k \log c(x, y)$$

\rightarrow nalezneme příliš krátký pgm pro x :

uvážijme množinu u t.č. $\forall u \in U$

$$A_u = \{ z; c(z, u) \leq c(x, y) \}$$

$$|A_u| \geq 2^k$$

1) $x \in U$, u je rel. spočítat!

$$2) \{ \langle u, z \rangle; u \in U, z \in A_u \} \subseteq A$$

$$3) |A| \leq 2^{c(x, y) + 1}$$

$$\rightarrow |U| \leq \frac{|A|}{2^k} \leq \frac{2^{c(x, y) + 1}}{2^k}$$

x has redundancy $\geq C(x,y)$, l a index
 \vee rdnici / mostly / u

$$C(x) \leq 2 \log C(x,y) + 2 \log l + \overbrace{C(x,y) - l} + O(1)$$

$\rightarrow C(x) < C(x)$ pro dostatek velik \underline{k} . \square

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

Symmetric information: $I_c(x:y) = I_c(y:x) + O(\log C(x,y))$

PF: $\forall n \exists x \quad |x|=n \quad C(x|n) \geq n$

for $C(n) \geq \log n$ pak

$$I_c(x:n) = C(x) - C(x|n) \leq n - n = 0$$

$$I_c(n:x) = C(n) - \underbrace{C(n|x)}_{=0} \geq \log n$$

\rightarrow logarithmic rate limit

Von: $H(X_n) - O(\log n) \leq E[C(X_n)] \leq H(X_n) + O(\log n)$

$X_1, X_2, \dots, X_n, \dots$ sekvenční posloupnost

první distribuce na $\{0,1\}^k$

Dů: $E[C(X_n)] \leq H(X_n)$

Huffmanův kód / Shannon-Fano kód

$$E[C(X_n)] \leq H(X_n)$$

$$C(X_n) \leq l(x_n) + 2 \log n + O(1)$$

\uparrow
 kód je delší, tj. n

• fix \underline{n} . X_n

$$i=0, \dots, 2n \quad V_i = \{x \in \Sigma_i^n; 2^{i-1} \leq \Pr[x = X_n] \leq 2^i\}$$

$$q_i = \Pr[X_n \in V_i] \quad V_{2n} = \{x, \Pr[x = X_n] \in 2^{2n}\}$$

$$|V_i| \geq \frac{q_i}{2^i} \Rightarrow V'_i = \{x \in V_i, C(x) \geq \log \frac{q_i}{2^i} - \log n\}$$

$$\cdot \Pr[X_n \in V'_i] \geq q_i \left(1 - \frac{1}{n}\right)$$

$$\cdot |V'_i| \geq \frac{|V_i|}{2}$$

$$H(X_n) \leq \sum_{i=0}^{2n-1} q_i \cdot i + 1 \quad \leftarrow \text{(Exc)} \quad \text{pro } n \geq 10$$

$$E[C(X_n)] \geq \sum_{i=0}^{2n-1} q_i \left(1 - \frac{1}{n}\right) \cdot \left(\log \frac{q_i}{2^i} - \log n\right)$$

$$\geq \left(1 - \frac{1}{n}\right) \left[\sum_{i=0}^{2n-1} q_i \log q_i + \sum_{i=0}^{2n-1} q_i \cdot i - \log n \right]$$

$$\geq \left(1 - \frac{1}{n}\right) \left[-\log 2n + \sum_{i=0}^{2n-1} q_i \cdot i - \log n \right]$$

$$\geq \sum_{i=0}^{2n-1} q_i \cdot i - 2 \log n - O(1) \quad \square$$