

1. Kolik otázek je třeba v průměru položit, abychom se dozvěděli datum narození člověka (den v roce), pokud odpovědi jsou pouze ano/ne a tázaný odpovídá pravdivě? Uvažujte, že každý 4. rok je přestupný.

**Řešení:**

Průměrný počet otázek je při každé strategii jejich kladení zdola omezen entropií. V tomto případě hledáme entropii náhodné veličiny  $X$ , která nabývá 366 hodnot, z toho 365 hodnot je stejně pravděpodobných a zbývající hodnota je 4×-méně pravděpodobná (přestupný den jednou za čtyři roky):

$$p_X(x) = \begin{cases} \frac{4}{4 \cdot 365 + 1}, & x \in \{1, \dots, 365\}, \\ \frac{1}{4 \cdot 365 + 1}, & x = 366. \end{cases}$$

Z toho dostaneme entropii  $H(X) \doteq 8.51$  bitů. Horší odhad nutného počtu otázek je  $9 = \lceil \log 366 \rceil$ , neboť stačí určit prvek množiny o 366 možných prvcích.

2. Je Vám nabídnuta účast ve hře v kostky. Máte na výběr mezi dvěma kostkami, které nejsou symetrické a mají následující pravděpodobnosti padnutí jednotlivých stran:

$$p = (2^{-3}, 2^{-3}, 2^{-3}, 2^{-3}, 2^{-3}, 3 \cdot 2^{-3}),$$

$$q = (2^{-2}, 2^{-2}, 2^{-3}, 2^{-3}, 2^{-3}, 2^{-3}).$$

Preferujete-li symetrii kostky, kterou z nich si vyberete? Bude pro Vás výhodnější, když se před začátkem hry vylosuje kostka, se kterou se bude hrát?

**Řešení:**

Symetrii kostek budeme přirozeně hodnotit pomocí entropie. Tak dostaneme pro jednotlivé kostky

$$H(p) = 3 - \frac{3}{8} \log 3 \doteq 2.406,$$

$$H(q) = 2.5.$$

Volíme tedy druhou kostku.

Losujeme-li kostku před začátkem hry, dostaneme pravděpodobnosti popsané vektorem  $r$ , který odpovídá směsi (s koeficientem  $\frac{1}{2}$ ) dvou původních diskretních rozdělení popsaných pomocí  $p$  a  $q$ :

$$r = \frac{1}{2}p + \frac{1}{2}q = \left( \frac{3}{16}, \frac{3}{16}, \frac{2}{16}, \frac{2}{16}, \frac{2}{16}, \frac{4}{16} \right).$$

Potom platí

$$H(r) = \frac{25 - 3 \log 3}{8} \doteq 2.531.$$

Losování kostky na začátku tedy vede k nejvyšší entropii a tudíž k nejvyšší symetrii výsledků hry. Tento způsob již zaručuje entropii blízkou symetrické kostce, jejíž entropie je maximální a rovna

$$\log 6 = 1 + \log 3 \doteq 2.585.$$

3. Odpověď  $X$  na otázku je náhodná veličina nad množinou  $\Lambda = \{1, 2, 3\}$ , jejíž rozdělení je popsáno vektorem pravděpodobností  $(\frac{1}{4}, \frac{1}{2}, \frac{1}{4})$ . Odpověď může být náhodně změněna, výsledek je popsán náhodnou veličinou  $Y$ . Podmíněné pravděpodobnosti  $p_{Y|X}(y|x)$  jsou popsány touto tabulkou:

$p_{Y X}(y x)$	$y = 1$	$y = 2$	$y = 3$
$x = 1$	1	0	0
$x = 2$	$\frac{1}{2}$	0	$\frac{1}{2}$
$x = 3$	0	$\frac{1}{2}$	$\frac{1}{2}$

Určete:

- entropii veličin  $X$  a entropii veličiny  $Y$ ;
- podmíněnou entropii veličiny  $X$  pozorované prostřednictvím veličiny  $Y$  a obráceně.

### Řešení:

Zřejmě lze přímo určit  $H(X)$  a  $H(Y|X)$ . Platí

$$H(X) = \frac{1}{4} \cdot 2 + \frac{1}{2} \cdot 1 + \frac{1}{4} \cdot 2 = \frac{3}{2} \quad \text{a} \quad H(Y|X) = \frac{1}{4} \cdot 0 + \frac{1}{2} \cdot 1 + \frac{1}{4} \cdot 1 = \frac{3}{4}.$$

Ke stanovení  $H(Y)$  a  $H(X|Y)$  je třeba nejprve určit sdružené rozdělení náhodného vektoru  $(X, Y)$ . To získáme jako  $p_{XY} = p_{Y|X}p_X$ :

$p_{XY}(x, y)$	$y = 1$	$y = 2$	$y = 3$
$x = 1$	$\frac{1}{4}$	0	0
$x = 2$	$\frac{1}{4}$	0	$\frac{1}{4}$
$x = 3$	0	$\frac{1}{8}$	$\frac{1}{8}$

Z tabulky rovnou vidíme, že  $H(Y) = \frac{1}{2} \cdot 1 + \frac{1}{8} \cdot 3 + \frac{3}{8} \log \frac{8}{3} \doteq 1.41$ . Z řetězcového pravidla snadno určíme  $H(X|Y)$  jako

$$H(X|Y) = H(X, Y) - H(Y) = H(X) + H(Y|X) - H(Y) \doteq 0.84.$$

4. Uvažujme abecedu  $\Lambda = \Omega = \{0, 1\}$ . Náhodná veličina  $X$  má binomické rozdělení  $\text{Bi}(1, 3/4)$ , kde  $P[X = 1] = 3/4$ . Šum je vyjádřen veličinou  $Z$  mající rozdělení  $\text{Bi}(1, 1/10)$ , kde  $P[Z = 1] = 1/10$ . Položme  $Y = X \oplus Z$ , přičemž  $\oplus$  je součet modulo 2. Určete vzájemnou informaci veličin  $X$  a  $Y$ .

**Řešení:**

Platí  $I(X; Y) = H(Y) - H(Y|X)$ . Stanovme nejprve  $H(Y|X)$ . Z definice  $Y$  dostaneme následující tabulku podmíněných pravděpodobností:

$p_{Y X}(y x)$	$y = 0$	$y = 1$
$x = 0$	$9/10$	$1/10$
$x = 1$	$1/10$	$9/10$

Z té plyne  $H(Y|X) = \frac{1}{4}H(Y|X = 0) + \frac{3}{4}H(Y|X = 1) = H(Y|X = 0) \doteq 0.47$ . Dále spočítáme  $p_Y$  jako marginální rozdělení pomocí  $p_{XY}$ :

$p_{XY}(x, y)$	$y = 0$	$y = 1$
$x = 0$	$9/40$	$1/40$
$x = 1$	$3/40$	$27/40$

Dostaneme  $H(Y) \doteq 0.88$  a tudíž  $I(X; Y) \doteq 0.41$ . Jelikož  $H(X) = 0.81$ , lze usoudit, že při přenosu se ztratí část informace o  $X$  díky šumu  $Z$ .

5. Rozhodněte, zda kód je jednoznačně dekódovatelný (JD) nebo instantní.

- (a) 1,01,001,000  
 (b) 1,101,10,01  
 (c) 01,11,00,001

Pokud je kód JD a nikoli instantní, lze nalézt instatní kód stejné střední délky?

**Řešení:**

(a) je instantní. (b) není JD: řetězec 101 lze parsovat jako (101) nebo jako (10)(1). (c) není instantní, ale je JD. Při dekódování je totiž nutné pouze rozlišit 3. a 4. kódové slovo: pokud je počet jednotkových bitů mezi řetězcem 001... a nejbližším bitem 0 sudý, potom 001 parsujeme jako (00)(1...), jinak jako (001)...

Ke kódu (c) snadno nalezneme instantní kód, jehož slova mají stejnou délku. Stačí uvážit, že délky kódových slov 2,2,2,3 splňují Kraftovu nerovnost,

$$2^{-2} + 2^{-2} + 2^{-2} + 2^{-3} \leq 1,$$

a proto lze nalézt odpovídající instantní kód. Je to např. kód 01, 11, 00, 101.

6. Pro zadaný informační zdroj  $X$  nalezněte Shannonův kód a Huffmanův kód:

$$p_X(a) = 0.1, p_X(b) = 0.15, p_X(c) = 0.05, p_X(d) = 0.4, p_X(e) = 0.3.$$

**Řešení:**

Například:

	$a$	$b$	$c$	$d$	$e$
$C_S$	1010	100	10111	00	01
$C_H$	0110	010	0111	1	00

Srovnáním délek kódových slov ihned plyne, že Huffmanův kód má menší střední kódovou délku. Přesvědčte se o tom výpočtem!

7. Nalezněte (binární) Huffmanův kód pro informační zdroj  $X$  popsany pravděpodobnostmi

$$\left(\frac{1}{3}, \frac{1}{5}, \frac{1}{5}, \frac{2}{15}, \frac{2}{15}\right).$$

Určete, zda je nalezený Huffmanův kód optimální i pro zdroj  $Y$  s pravděpodobnostmi

$$\left(\frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}\right),$$

a zdůvodněte proč.

**Řešení:**

Huffmanův kód pro zdroj  $X$ :

$$\{00, 10, 11, 010, 011\}.$$

Ovšem jiný Huffmanův kód pro zdroj  $X$  dostaneme bitovou inverzí ve všech kódových slovech:

$$\{11, 01, 00, 101, 100\}.$$

Chceme ukázat, že Huffmanův kód s délkami kódových slov

$$2, 2, 2, 3, 3$$

je optimální i pro zdroj  $Y$  s rovnoměrnou pravděpodobnostní funkcí. Ten má entropii

$$H(Y) = \log 5 \doteq 2.32.$$

Střední délka uvažovaného Huffmanova kódu je pro tuto rovnoměrnou pravděpodobnostní funkci

$$3 \cdot 2 \cdot \frac{1}{5} + 2 \cdot 3 \cdot \frac{1}{5} = \frac{12}{5}.$$

Střední délka libovolného instantního kódu s délkami kódových slov  $\ell_1, \dots, \ell_5$  pro  $Y$  však musí splňovat nerovnost

$$\frac{1}{5} \sum_{i=1}^5 \ell_i \geq H(Y),$$

čemuž vyhovuje každý instantní kód, jehož délky kódových slov splňují

$$\sum_{i=1}^5 \ell_i \geq 12.$$

Jelikož je součet délek slov Huffmanova kódu pro  $X$  právě 12, je tento kód optimální i pro zdroj  $Y$ .

8. Mějme kód s těmito čtyřmi kódovými slovy:

$$0, 10, 110, 111.$$

a) Rozhodněte, zda je tento kód optimální pro nějaký informační zdroj, případně popište alespoň dva informační zdroje, pro něž je optimální. b) Odstraníme-li z posledního kódového slova první bit, bude takto upravený kód jednoznačně dekódovatelný? Odpověď zdůvodněte.

### Řešení:

a) Uvedený kód je optimální, neboť je instantní a délky  $\ell_i$  jeho kódových slov splňují

$$\ell_i = -\log 2^{-n_i}, \quad n_i \in \mathbb{N}$$

přičemž

$$\sum_{i=1}^4 2^{-n_i} = 1.$$

Volbou  $n_1 = 1, n_2 = 2, n_3 = n_4 = 3$  tak dostaneme optimální kód pro informační zdroj popsany pravděpodobnostmi

$$\left( \frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{8} \right).$$

Uvedený kód je ovšem Huffmanův (a tudíž optimální) i např. pro zdroj popsaný pravděpodobnostmi

$$\left(\frac{1}{2}, \frac{3}{8}, \frac{1}{16}, \frac{1}{16}\right).$$

b) Výsledný kód nemůže být jednoznačně dekódovatelný, neboť délky jeho kódových slov nespĺňují Kraftovu nerovnost:

$$2^{-1} + 2 \cdot 2^{-2} + 2^{-3} \not\leq 1.$$

9. Pro informační zdroj nad abecedou  $\mathcal{X} = \{a,b,c,d,e,f\}$  byl nalezen kód  $C$ :

a		001
b		1001
c		0010
d		1110
e		1010
f		01110

Je jednoznačně dekódovatelný?

**Řešení:**

Pro délky kódových slov

$$3, 4, 4, 4, 4, 5$$

ověříme Kraftovu nerovnost:

$$2^{-3} + 4 \cdot 2^{-4} + 2^{-5} = \frac{13}{32} < 1.$$

Tedy existuje jednoznačně dekódovatelný binární kód s takto zadanými délkami kódových slov:

a		000
b		0010
c		0011
d		0100
e		0101
f		01100

Ovšem původní kód  $C$  jednoznačně dekódovatelný není, neboť např. zprávy  $cd$  a  $af$  jsou zakódovány shodně.

10. Informační zdroje nad abecedou  $\mathcal{X} = \{1, \dots, 5\}$  jsou popsány dvěma pravděpodobnostními funkcemi  $p$  a  $q$ . Uvažujme binární kódy  $C_1$  a  $C_2$  pro tyto zdroje:

$x$	$p(x)$	$q(x)$	$C_1(x)$	$C_2(x)$
1	1/2	1/2	0	0
2	1/4	1/8	10	100
3	1/8	1/8	110	101
4	1/16	1/8	1110	110
5	1/16	1/8	1111	111

Ověřte, že kód  $C_1$  je optimální pro zdroj s pravděpodobnostní funkcí  $p$  a kód  $C_2$  je optimální pro zdroj s pravděpodobnostní funkcí  $q$ . Pokud užijeme kód  $C_1$  pro zdroj popsáný pomocí  $q$ , jaké chyby se dopustíme?

### Řešení:

Určíme entropie  $p$  a  $q$ :

$$H(p) = 1.875,$$

$$H(q) = 2.$$

Avšak střední délka kódu  $C_1$  je 1.875, střední délka kódu  $C_2$  je 2: oba kódy jsou optimální. Střední délka  $L_q(C_1)$  kódu  $C_1$  použitého na zdroj s pravděpodobnostní funkcí  $q$  je

$$\frac{1}{2} + (2 + 3) \cdot \frac{1}{8} + 2 \cdot 4 \cdot \frac{1}{8} = 2.125.$$

Kód  $C_1$  tedy není pro  $q$  optimální: za nevhodné kódování zaplatíme chybou o velikosti rozdílu

$$L_q(C_1) - H(q) = 0.125,$$

což je právě hodnota informační divergence  $D(q||p)$ .

11. Markovský řetězec nad abecedou  $\Lambda = \{a, b, c\}$  je popsán těmito pravděpodobnostmi přechodu: pravděpodobnosti přechodů ze stavu  $a$  i ze stavu  $b$  jsou rovnoměrné, přechod ze stavu  $c$  do  $c$  nikdy nemůže nastat, ostatní podmíněné pravděpodobnosti jsou shodné. Určete rychlost entropie odpovídajícího markovského zdroje informace.

### Řešení:

Ze zadání dostaneme matici přechodu:

$$\mathbf{P} = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{2} & \frac{1}{2} & 0 \end{pmatrix}$$

Rychlost entropie markovského zdroje splňuje  $H((X_n)_{n \in \mathbb{N}}) = H(X_2|X_1)$ . Stačí tedy určit

$$H(X_2|X_1) = \sum_{x_1 \in \{a,b,c\}} p(x_1) \cdot H(X_2|x_1),$$

kde  $p = (p(a), p(b), p(c))$  je stacionární rozdělení řetězce a  $H(X_2|x_1)$  jsou podmíněné entropie jednotlivých řádku matice  $\mathbf{P}$ . Platí

$$H(X_2|a) = H(X_2|b) = \log 3, \quad H(X_2|c) = \log 2 = 1.$$

Stacionární rozdělení nalezneme řešením soustavy

$$p \cdot \mathbf{P} = p, \quad p(a) + p(b) + p(c) = 1.$$

Dostaneme  $p = (0.375, 0.375, 0.25)$ . Proto

$$H(X_2|X_1) = 2 \cdot 0.375 \log 3 + 0.25 \cdot 1 = 0.75 \log 3 + 0.25 \doteq 1.435.$$

12. Určete rychlost entropie markovského zdroje informace s abecedou  $\mathcal{X} = \{a, b, c\}$ , jehož matice přechodu je

$$\mathbf{P} = \begin{pmatrix} 0 & \frac{1}{2} & \frac{1}{2} \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix}.$$

Jaká je maximální rychlost entropie libovolného markovského zdroje s abecedou  $\mathcal{X}$ ? Odpověď zdůvodněte.

### Řešení:

Nejprve nalezneme stacionární rozdělení  $\mathbf{p} = (p_1, p_2, p_3)$  Markovova řetězce zadaného maticí  $\mathbf{P}$ . Řešíme soustavu lineárních rovnic

$$\begin{aligned} \mathbf{p} &= \mathbf{pP}, \\ p_1 + p_2 + p_3 &= 1. \end{aligned}$$

Jejím řešením je vektor  $\mathbf{p} = (\frac{2}{5}, \frac{2}{5}, \frac{1}{5})$ . Informační zdroj  $X_1, X_2, \dots$  je markovský, pokud pro jeho počáteční rozdělení  $\mathbf{p}(0)$  platí  $\mathbf{p}(0) = \mathbf{p}$ . Potom je rychlost entropie tohoto zdroje rovna střední podmíněné entropii  $H(X_2|X_1)$ . Tedy

$$H(X_2|X_1) = \sum_{i=0}^2 p_i(0) \cdot H(X_2|X_1 = i) = \frac{2}{5} \cdot H\left(\frac{1}{2}, \frac{1}{2}\right) = \frac{2}{5}.$$

Maximální rychlost entropie markovského zdroje pro tento zdroj je maximum entropie na tříprvkové množině, neboť  $H(X_2|X_1)$  je konvexní kombinací podmíněných entropií na tříprvkových množinách. V našem případě tedy  $\log 3 \doteq 1.585$ .



13. Nalezněte střední délku Huffmanova kódu pro informační zdroj generující řetězec

*aaababbcbabc*

Určete, jaké úspory dosáhneme použitím blokového Huffmanova kódování s délkou bloku 2.

**Řešení:**

Při použití Huffmanova kódu o délce bloku 1 máme tuto tabulku:

	<i>a</i>	<i>b</i>	<i>c</i>
$p(x)$	$\frac{5}{11}$	$\frac{4}{11}$	$\frac{2}{11}$
$C_H$	0	11	10

Při použití bloku délky 2 dostaneme tento Huffmanův kód:

	<i>aa</i>	<i>ab</i>	<i>ba</i>	<i>ac</i>	<i>ca</i>	<i>bb</i>	<i>bc</i>	<i>cb</i>	<i>cc</i>
$p(x, y)$	$\frac{25}{121}$	$\frac{20}{121}$	$\frac{20}{121}$	$\frac{10}{121}$	$\frac{10}{121}$	$\frac{16}{121}$	$\frac{8}{121}$	$\frac{8}{121}$	$\frac{4}{121}$
$C_H^2$	01	110	111	000	1011	100	0011	1010	0010

Střední délky kódů vztahované na 1 znak zdrojové abecedy:

$$L(C_H) = \frac{17}{11} \doteq 1.545, \quad \frac{L(C_H^2)}{2} \doteq \frac{3.041}{2} = 1.521.$$

Tedy dosáhneme komprese lepší o

$$\left(1 - \frac{1.521}{1.545}\right) \times 100\% = 1.55\%.$$

14. Při vysílání dvouprvkové abecedy  $\{\cdot, -\}$  se zkreslí 8% teček a 2% čárek. Zpráva, ve které se tečky a čárky vyskytují rovnočetně, obsahuje 154 bitů informace. Kolik z nich uvedený informační kanál v průměru přenese správně?

**Řešení:**

Rozdělení informačního zdroje  $X$  s abecedou  $\{\cdot, -\}$  je na vstupu popsáno rovnoměrnou pravděpodobnostní funkcí  $p_X$ . Podmíněné pravděpodobnosti  $p_{Y|X}(y|x)$ ,  $x, y \in \{\cdot, -\}$ , vyjadřující možnou záměnu symbolu jsou dány maticí

$$\begin{pmatrix} 0.92 & 0.08 \\ 0.02 & 0.98 \end{pmatrix}.$$

Nejprve určíme zpětné podmíněné pravděpodobnosti  $p_{X|Y}(x|y)$  pomocí Bayesova vzorce:

$$p_{X|Y}(x|y) = \frac{p_{Y|X}(y|x)p_X(x)}{\sum_{x' \in \{.,-\}} p_{Y|X}(y|x')p_X(x')}.$$

Potom vzájemnou informaci:

$$I(X; Y) = H(X) - H(X|Y) = 0.725.$$

Ve zprávě o 154 bitech se tak za předpokladu nezávislosti vysílaných znaků zachová přibližně  $154 \cdot 0.725 = 112$  bitů.

15. Informační zdroj  $X$  vysílá znaky z abecedy  $\mathcal{X} = \{a_1, a_2, a_3, a_4\}$  s pravděpodobnostmi  $p_X(a_i)$ ,  $i = 1, \dots, 4$ . Na výstupu kanálu je pozorován informační zdroj  $Y$  nad stejnou abecedou  $\mathcal{X}$ . Chybovost přenosu je popsána podmíněnými pravděpodobnostmi  $p_{Y|X}(a_j|a_i)$ ,  $i, j = 1, \dots, 4$ . Pokud jsou podmíněné entropie  $H(Y|X = a_i)$ ,  $i = 1, \dots, 4$  maximální, jaká je vzájemná informace  $X$  a  $Y$ ?

### Řešení:

Maximum podmíněné entropie  $H(Y|X = a_i)$  se pro každé  $i = 1, \dots, 4$  nabývá pro rovnoměrnou podmíněnou pravděpodobnostní funkci:

$$p_{Y|X}(a_j|a_i) = \frac{1}{4}, \quad j = 1, \dots, 4.$$

Proto platí

$$H(Y|X) = \sum_{i=1}^4 p_X(a_i) \cdot H(Y|X = a_i) = \log 4 \cdot \sum_{i=1}^4 p_X(a_i) = 2.$$

Rozdělení zdroje  $Y$  je též rovnoměrné, neboť pro každé  $i = 1, \dots, 4$  platí

$$p_Y(a_i) = \sum_{j=1}^4 p_{Y|X}(a_i|a_j)p_X(a_j) = \frac{1}{4} \sum_{j=1}^4 p_X(a_j) = \frac{1}{4}.$$

Tudíž  $H(Y) = \log 4 = 2$  a proto  $I(X; Y) = 0$ .

## Reference

- [1] J. Adámek. *Stochastické procesy a teorie informace - úlohy*. Vydavatelství ČVUT, 1989.

- [2] T. M. Cover and J. A. Thomas. *Elements of information theory*. Wiley-Interscience [John Wiley & Sons], Hoboken, NJ, second edition, 2006.