

# Teorie kódování - Kapitola 1 - Entropie

Jan Paseka

Ústav matematiky a statistiky  
Masarykova univerzita

14. února 2023

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Motivace

- FI** Uvažme následující tvrzení.
- A** Výsledek běhu mezi dvěma rovnocennými závodníky je méně nejistý než výsledek běhu mezi šesti rovnocennými závodníky.

# Motivace

- FI** Uvažme následující tvrzení.
  - A** Výsledek běhu mezi dvěma rovnocennými závodníky je méně nejistý než výsledek běhu mezi šesti rovnocennými závodníky.
  - B** Výsledek rulety je více nejistý než vrh kostkou.

# Motivace

- FI** Uvažme následující tvrzení.
- A** Výsledek běhu mezi dvěma rovnocennými závodníky je méně nejistý než výsledek běhu mezi šesti rovnocennými závodníky.
  - B** Výsledek rulety je více nejistý než vrh kostkou.
  - C** Výsledek vrhu ideální kostkou je více nejistý než výsledek vrhu falešnou kostkou.

# Motivace

- FI** Uvažme následující tvrzení.
- A** Výsledek běhu mezi dvěma rovnocennými závodníky je méně nejistý než výsledek běhu mezi šesti rovnocennými závodníky.
  - B** Výsledek rulety je více nejistý než vrh kostkou.
  - C** Výsledek vrhu ideální kostkou je více nejistý než výsledek vrhu falešnou kostkou.

# Motivace

- FI** Uvažme následující tvrzení.
- A** Výsledek běhu mezi dvěma rovnocennými závodníky je méně nejistý než výsledek běhu mezi šesti rovnocennými závodníky.
  - B** Výsledek rulety je více nejistý než vrh kostkou.
  - C** Výsledek vrhu ideální kostkou je více nejistý než výsledek vrhu falešnou kostkou.

Zřejmě s výše uvedenými tvrzeními lze okamžitě souhlasit. Obtížné však bude definovat, co je to vlastně nejistota.



# Motivace

- FI** Uvažme následující tvrzení.
- A** Výsledek běhu mezi dvěma rovnocennými závodníky je méně nejistý než výsledek běhu mezi šesti rovnocennými závodníky.
  - B** Výsledek rulety je více nejistý než vrh kostkou.
  - C** Výsledek vrhu ideální kostkou je více nejistý než výsledek vrhu falešnou kostkou.

Zřejmě s výše uvedenými tvrzeními lze okamžitě souhlasit. Obtížné však bude definovat, co je to vlastně nejistota. Podívejme se na dvě různé náhodné veličiny  $X$  a  $Y$ . Necht'

$$P(X = 0) = p, \quad P(X = 1) = 1 - p,$$

a

$$P(Y = 100) = p, \quad P(Y = 200) = 1 - p,$$

přičmž  $0 < p < 1$ .

# Motivace

Zřejmě by nám definice nejistoty měla zajistit, že  $X$  a  $Y$  jsou stejně nejisté. Tedy nejistota  $X$  a tedy i  $Y$  by měla být funkcí *pouze* pravděpodobnosti  $p$ . Tato vlastnost nejistoty musí být rozšiřitelná i na náhodné proměnné, které nabývají více než dvou hodnot. Tedy:

Nejistota náhodné proměnné  $Z$ , která nabývá hodnoty  $a_i$  s pravděpodobnostmi  $p_i$ , ( $1 \leq i \leq n$ ), je funkcí *pouze* pravděpodobností  $p_1, \dots, p_n$ .

# Obsah

- 1 **Nejistota**
  - Motivace
  - **Definice nejistoty**
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Definice nejistoty

Proto značíme takovouto funkci jako  $H(p_1, \dots, p_n)$ , přičemž předpokládáme splnění následujících přirozených podmínek:

- (A1)  $H(p_1, \dots, p_n)$  je maximální, když  $p_1 = p_2 = \dots = p_n = 1/n$ .  
(A2) Pro každou permutaci  $\pi$  na  $\{1, \dots, n\}$  platí

$$H(p_1, \dots, p_n) = H(p_{\pi(1)}, \dots, p_{\pi(n)}).$$

Tedy  $H$  je symetrická funkce svých argumentů, tj. její výsledek nezávisí na pořadí.

- (A3)  $H(p_1, \dots, p_n) \geq 0$  a rovnost nastává právě tehdy, když  $p_i = 1$  pro nějaké  $i$ .

Nejistota má tedy vždy nezápornou hodnotu a je nulová právě tehdy, když je jakákoliv náhoda vyloučena.

# Definice nejistoty

(A4)

$$H(p_1, \dots, p_n, 0) = H(p_1, \dots, p_n).$$

Nejistota vrhu šestibokou ideální kostkou je tatáž jako nejistota vrhu sedmibokou kostkou, u které je nemožné, aby padla 7, ale ostatní případy jsou si rovnocenné.

(A5)

$$H\left(\frac{1}{n}, \dots, \frac{1}{n}\right) \leq H\left(\frac{1}{n+1}, \dots, \frac{1}{n+1}\right).$$

Výsledek běhu mezi dvěma závodníky je méně nejistý než výsledek běhu mezi více závodníky.

(A6)  $H(p_1, \dots, p_n)$  je spojitá funkce svých parametrů. Malé změny na vstupu dají malé změny na výstupu.

# Definice nejistoty

(A7) Jsou-li  $m, n \in \mathbf{N}$ , pak

$$H\left(\frac{1}{m \cdot n}, \dots, \frac{1}{m \cdot n}\right) = H\left(\frac{1}{m}, \dots, \frac{1}{m}\right) + H\left(\frac{1}{n}, \dots, \frac{1}{n}\right).$$

Tato podmínka říká, že nejistota vrhu  $m \cdot n$ -stranné kostky je obsažena ve vrhu  $m$ -stranné kostky následovaná vrhem  $n$ -stranné kostky, a je rovna součtu individuálních nejistot.

(A8) Necht'  $p = p_1 + \dots + p_m$  a  $q = q_1 + \dots + q_n$ ,  $p_i, q_j$  jsou nezáporné. Jsou-li  $p$  a  $q$  kladná čísla,  $p + q = 1$ , pak platí

$$H(p_1, \dots, p_m, q_1, \dots, q_n) = H(p, q) + p \cdot H(p_1/p, \dots, p_m/p) + q \cdot H(q_1/q, \dots, q_n/q).$$

Představme si, že máme  $n + m$  uchazečů na místo v konkurzu - z toho je  $m$  mužů a  $n$  žen, s pravděpodobnostmi  $p_i, q_j$  vítězství v konkurzu. Pak nejistota výsledku konkurzu je nejistota, že vyhraje muž nebo žena plus vážený součet, nejistot výhry mezi muži a ženami.

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - **Charakterizace nejistoty a její důsledky**
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Charakterizace nejistoty

## Věta 1.1

*Bud'  $H(p_1, \dots, p_n)$  funkce definovaná pro každé přirozené číslo  $n$  a pro všechny hodnoty  $p_1, \dots, p_n$  tak, že  $p_i \geq 0$  a*

$$\sum_{i=1}^n p_i = 1.$$

*Pokud  $H$  splňuje axiomy (A1)-(A8), pak platí*

$$H(p_1, p_2, \dots, p_n) = -\lambda \sum_k p_k \cdot \log p_k, \quad (1.1)$$

*kde  $\lambda$  je libovolná kladná konstanta a sumuje se přes všechna  $k$  taková, že  $p_k > 0$ .*



# Důkaz Věty 1.1

**MA** Necht'  $H$  splňuje axiomy (A1)-(A8). Definujme

(1)  $g(n) = H(1/n, \dots, 1/n)$  pro  $n \in \mathbf{N}$ . Z (A7) pak

$$g(n^k) = g(n) + g(n^{k-1})$$

# Důkaz Věty 1.1

**MA** Necht'  $H$  splňuje axiomy (A1)-(A8). Definujme

(1)  $g(n) = H(1/n, \dots, 1/n)$  pro  $n \in \mathbf{N}$ . Z (A7) pak

$$g(n^k) = g(n) + g(n^{k-1})$$

a tedy

(2)  $g(n^k) = k \cdot g(n)$ .

Bud' dále  $r, s \in \mathbf{N} - \{1\}$ ,  $n \in \mathbf{N}$  a  $m = m(n, r, s) \in \mathbf{N}$  tak, že

# Důkaz Věty 1.1

**MA** Necht'  $H$  splňuje axiomy (A1)-(A8). Definujme

(1)  $g(n) = H(1/n, \dots, 1/n)$  pro  $n \in \mathbf{N}$ . Z (A7) pak

$$g(n^k) = g(n) + g(n^{k-1})$$

a tedy

(2)  $g(n^k) = k \cdot g(n)$ .

Bud' dále  $r, s \in \mathbf{N} - \{1\}$ ,  $n \in \mathbf{N}$  a  $m = m(n, r, s) \in \mathbf{N}$  tak, že

(3)  $r^m \leq s^n \leq r^{m+1}$ ;

# Důkaz Věty 1.1

**MA** Necht'  $H$  splňuje axiomy (A1)-(A8). Definujme

(1)  $g(n) = H(1/n, \dots, 1/n)$  pro  $n \in \mathbf{N}$ . Z (A7) pak

$$g(n^k) = g(n) + g(n^{k-1})$$

a tedy

(2)  $g(n^k) = k \cdot g(n)$ .

Bud' dále  $r, s \in \mathbf{N} - \{1\}$ ,  $n \in \mathbf{N}$  a  $m = m(n, r, s) \in \mathbf{N}$  tak, že

(3)  $r^m \leq s^n \leq r^{m+1}$ ; pak dle (2) a monotonie  $g$  (dle (A5)) máme

$$g(r^m) \leq g(s^n) \leq g(r^{m+1}),$$

tedy

$$m \cdot g(r) \leq n \cdot g(s) \leq (m+1) \cdot g(r).$$

# Důkaz Věty 1.1

Z (3) pak máme

$$m \cdot \ln(r) \leq n \cdot \ln(s) \leq (m + 1) \cdot \ln(r)$$

a tedy

$$\left| \frac{g(s)}{g(r)} - \frac{\ln(s)}{\ln(r)} \right| \leq \frac{1}{n}.$$

# Důkaz Věty 1.1

Z (3) pak máme

$$m \cdot \ln(r) \leq n \cdot \ln(s) \leq (m + 1) \cdot \ln(r)$$

a tedy

$$\left| \frac{g(s)}{g(r)} - \frac{\ln(s)}{\ln(r)} \right| \leq \frac{1}{n}.$$



# Důkaz Věty 1.1

Z (3) pak máme

$$m \cdot \ln(r) \leq n \cdot \ln(s) \leq (m+1) \cdot \ln(r)$$

a tedy

$$\left| \frac{g(s)}{g(r)} - \frac{\ln(s)}{\ln(r)} \right| \leq \frac{1}{n}.$$



Protože  $n$  bylo libovolné přirozené číslo, je

(4)

$$\frac{g(s)}{\ln(s)} = \frac{g(r)}{\ln(r)} = \lambda,$$

kde  $\lambda$  je nějaká (kladná) konstanta.

# Důkaz Věty 1.1

Tedy

(5)

$$g(s) = \lambda \cdot \ln(s), \text{ tj. } H\left(\frac{1}{s}, \dots, \frac{1}{s}\right) = -\lambda \cdot \ln\left(\frac{1}{s}\right).$$



# Důkaz Věty 1.1

Tedy

(5)

$$g(s) = \lambda \cdot \ln(s), \text{ tj. } H\left(\frac{1}{s}, \dots, \frac{1}{s}\right) = -\lambda \cdot \ln\left(\frac{1}{s}\right).$$

Bud'  $0 < p < 1$  racionální,  $p = t/n$ ,  $t, n \in \mathbf{N}$ .

# Důkaz Věty 1.1

Tedy

(5)

$$g(s) = \lambda \cdot \ln(s), \text{ tj. } H\left(\frac{1}{s}, \dots, \frac{1}{s}\right) = -\lambda \cdot \ln\left(\frac{1}{s}\right).$$

Bud'  $0 < p < 1$  racionální,  $p = t/n$ ,  $t, n \in \mathbf{N}$ .

Položme  $q = (n - t)/n$ . Z (A8) pak

$$g(n) = H\left(\frac{1}{n}, \dots, \frac{1}{n}\right) = H\left(\frac{t}{n}, \frac{n-t}{n}\right) + \frac{t}{n} \cdot g(t) + \frac{n-t}{n} \cdot g(n-t).$$

# Důkaz Věty 1.1

Tedy

(5)

$$g(s) = \lambda \cdot \ln(s), \text{ tj. } H\left(\frac{1}{s}, \dots, \frac{1}{s}\right) = -\lambda \cdot \ln\left(\frac{1}{s}\right).$$

Bud'  $0 < p < 1$  racionální,  $p = t/n$ ,  $t, n \in \mathbf{N}$ .

Položme  $q = (n - t)/n$ . Z (A8) pak

$$g(n) = H\left(\frac{1}{n}, \dots, \frac{1}{n}\right) = H\left(\frac{t}{n}, \frac{n-t}{n}\right) + \frac{t}{n} \cdot g(t) + \frac{n-t}{n} \cdot g(n-t).$$

Z (5) pak jednoduchou úpravou

$$H\left(\frac{t}{n}, \frac{n-t}{n}\right) = -\lambda \cdot \left(\frac{t}{n}\right) \cdot \ln \frac{t}{n} - \lambda \cdot \left(\frac{n-t}{n}\right) \cdot \ln \frac{n-t}{n}.$$

# Důkaz Věty 1.1

Zejména pak

(6)

$$H(p, 1 - p) = -\lambda \cdot (p \cdot \ln p + (1 - p) \cdot \ln(1 - p)),$$

a to pro každé racionální číslo  $p$  mezi 0 a 1. Ze spojitosti  $H$  platí (6) pro všechna  $0 < p < 1$ .

# Důkaz Věty 1.1

Zejména pak

(6)

$$H(p, 1 - p) = -\lambda \cdot (p \cdot \ln p + (1 - p) \cdot \ln(1 - p)),$$

a to pro každé racionální číslo  $p$  mezi 0 a 1. Ze spojitosti  $H$  platí (6) pro všechna  $0 < p < 1$ .

Dokažme, že pro každé  $N \in \mathbf{N}$  platí

(7)

$$H(p_1, \dots, p_N) = -\lambda \cdot \sum_{i=1}^N p_i \cdot \ln p_i,$$

přičemž  $p_i > 0$  a  $p_1 + \dots + p_N = 1$ , a to indukcí podle  $N$ .

# Důkaz Věty 1.1

Z (6) víme, že (7) platí pro  $N = 2$  a triviálně platí pro  $N = 1$  z (A3).

# Důkaz Věty 1.1

Z (6) víme, že (7) platí pro  $N = 2$  a triviálně platí pro  $N = 1$  z (A3). Předpokládejme, že (7) platí pro  $N$  a uvažujme  $H(p_1, \dots, p_{N+1})$ . Položme  $p = p_1 + \dots + p_N$ ,  $q = p_{N+1}$ . Příklad  $p = 0$  je jasný, předpokládejme tedy, že  $p > 0$  a použijme (A8).

# Důkaz Věty 1.1

Z (6) víme, že (7) platí pro  $N = 2$  a triviálně platí pro  $N = 1$  z (A3). Předpokládejme, že (7) platí pro  $N$  a uvažujme  $H(p_1, \dots, p_{N+1})$ . Položme  $p = p_1 + \dots + p_N$ ,  $q = p_{N+1}$ . Příklad  $p = 0$  je jasný, předpokládejme tedy, že  $p > 0$  a použijme (A8). Máme pak

$$\begin{aligned}
 H(p_1, \dots, p_{N+1}) &= H(p, q) + p \cdot H\left(\frac{p_1}{p}, \dots, \frac{p_N}{p}\right) + \overbrace{q \cdot H(1)}^{=0} \\
 &= -\lambda \cdot p \cdot \ln p - \lambda \cdot q \cdot \ln q + p \cdot (-\lambda) \cdot \sum_{i=1}^N \frac{p_i}{p} \ln \frac{p_i}{p},
 \end{aligned}$$

z indukčního předpokladu.



# Důkaz Věty 1.

Upravíme-li poslední rovnost na tvar

$$H(p_1, \dots, p_{N+1}) = -\lambda \cdot (p \cdot \ln p + p_{N+1} \cdot \ln p_{N+1} + \sum_{i=1}^N p_i \cdot (\ln p_i - \ln p)),$$

a vzpomeneme-li si, že  $\sum_{i=1}^N p_i = p$ , obdržíme hledanou rovnost

$$H(p_1, \dots, p_{N+1}) = -\lambda \cdot \sum_{i=1}^{N+1} p_i \cdot \ln p_i.$$

# Ekvivalentní definice nejistoty

**FI** Na základě výše uvedené věty pak definujeme

## Definice 1

*Bud'  $X$  náhodná proměnná s konečným oborem hodnot s odpovídajícími pravděpodobnostmi  $p_1, p_2, \dots, p_n$ . Pak definujeme **nejistotu** neboli **entropii** náhodné veličiny  $X$  jako*

$$H(X) = - \sum_k p_k \cdot \log_2 p_k, \quad (1.2)$$

*kde suma se bere pouze přes ta  $k$ , pro která je  $p_k > 0$ .*

# Ekvivalentní definice nejistoty

## Poznámka 1.2

*Nadále budeme vždy (bez újmy na obecnosti) předpokládat, že pro všechny členy pravé strany (1.2) jsou pravděpodobnosti  $p_k$  nenulové.*

## Poznámka 1.3

*Podmínky (A1)-(A8) odpovídají axiomům pro entropii navrženým Shannonem.*

## Poznámka 1.4

*Entropii náhodné veličiny  $X$  můžeme rovněž interpretovat jakožto střední hodnotu náhodné proměnné  $\log_2 \frac{1}{p(X)}$ . Tedy*

$$H(X) = E\left(\log_2 \frac{1}{p(X)}\right) = - \sum_k p_k \cdot \log_2 p_k. \quad (1.3)$$

# Ekvivalentní definice nejistoty



## Příklad 1.5

*Necht'*

$$X = \begin{cases} 1 & \text{s pravděpodobností } p \\ 0 & \text{s pravděpodobností } 1 - p. \end{cases} \quad (1.4)$$

*Pak*

$$H(X) = -p \log_2 p - (1 - p) \log_2(1 - p). \quad (1.5)$$



# Příklady

## Cvičení 1.6

- 1 *Který dostih má větší entropii: ten, ve kterém je sedm žokejů, tři z nich vyhrají s pravděpodobností  $\frac{1}{6}$  a čtyři z nich s pravděpodobností  $\frac{1}{8}$  nebo dostih, ve kterém je 8 žokejů s dvěma koni s pravděpodobností výhry  $\frac{1}{4}$  a šest koní s pravděpodobností výhry  $\frac{1}{12}$  ?*

# Příklady

## Cvičení 1.6

- 1 *Který dostih má větší entropii: ten, ve kterém je sedm žokejů, tři z nich vyhrají s pravděpodobností  $\frac{1}{6}$  a čtyři z nich s pravděpodobností  $\frac{1}{8}$  nebo dostih, ve kterém je 8 žokejů s dvěma koni s pravděpodobností výhry  $\frac{1}{4}$  a šest koní s pravděpodobností výhry  $\frac{1}{12}$  ?*
- 2 *Ověřte, že výše definovaná funkce entropie splňuje podmínky (A1)-(A8).*

# Příklady

## Příklad 1.7



$$H = -1.0 \cdot \log_2 1.0 = 0.0$$



$$H = -0.75 \cdot \log_2 0.75 \\ - 0.25 \cdot \log_2 0.25 = 0.81$$



$$H = -0.5 \cdot \log_2 0.5 \\ - 0.5 \cdot \log_2 0.5 = 1.0$$

$$p_r = 0.5$$

$$p_g = 0.25$$

$$p_y = 0.125$$

$$p_b = 0.125$$

$$H = 1.75$$



# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí



# Entropie náhodného vektoru

**FI** Řekli jsme, že pro náhodnou proměnnou  $X$  s konečným oborem hodnot a s pravděpodobnostmi  $p_1, \dots, p_n$  tak, že

$$\sum p_i = 1 \text{ a } p_i > 0 \text{ (} 1 \leq i \leq n \text{),}$$

definujeme entropii  $X$  jako

$$H(X) = - \sum_{k=1}^n p_k \cdot \log_2 p_k.$$

# Entropie náhodného vektoru

Analogicky pak pro náhodný vektor  $\mathbf{X}$ , který nabývá pouze konečně mnoha hodnot  $\mathbf{u}_1, \dots, \mathbf{u}_m$ , defimujeme jeho *entropii* náhodného vektoru jako

$$H(\mathbf{X}) = - \sum_{k=1}^m p(\mathbf{u}_k) \cdot \log_2 p(\mathbf{u}_k). \quad (2.1)$$

# Entropie náhodného vektoru

Analogicky pak pro náhodný vektor  $\mathbf{X}$ , který nabývá pouze konečně mnoha hodnot  $\mathbf{u}_1, \dots, \mathbf{u}_m$ , defimujeme jeho *entropii* náhodného vektoru jako

$$H(\mathbf{X}) = - \sum_{k=1}^m p(\mathbf{u}_k) \cdot \log_2 p(\mathbf{u}_k). \quad (2.1)$$

Je-li například  $\mathbf{X}$  2-dimenzionální náhodný vektor,  $\mathbf{X} = (U, V)$  s

$$p_{ij} = P(U = a_i, V = b_j),$$

budeme často psát

$$H(\mathbf{X}) = H(U, V) = - \sum p_{ij} \cdot \log_2 p_{ij}.$$

# Entropie náhodného vektoru

Zcela obecně, jsou-li  $X_1, \dots, X_m$  náhodné proměnné tak, že každá z nich nabývá pouze konečně mnoha hodnot, lze pak považovat  $\mathbf{X} = (X_1, \dots, X_m)$  za náhodný vektor a definovat souhrnou entropii  $X_1, \dots, X_m$  jako

$$H(X_1, \dots, X_m) = H(\mathbf{X}) = - \sum_{(x_1, \dots, x_m)} p(x_1, \dots, x_m) \cdot \log_2 p(x_1, \dots, x_m), \quad (2.2)$$

kde  $p(x_1, \dots, x_m) = P(X_1 = x_1, X_2 = x_2, \dots, X_m = x_m)$ .

# Entropie náhodného vektoru

Zcela obecně, jsou-li  $X_1, \dots, X_m$  náhodné proměnné tak, že každá z nich nabývá pouze konečně mnoha hodnot, lze pak považovat  $\mathbf{X} = (X_1, \dots, X_m)$  za náhodný vektor a definovat souhrnou entropii  $X_1, \dots, X_m$  jako

$$H(X_1, \dots, X_m) = H(\mathbf{X}) = - \sum_{(x_1, \dots, x_m)} p(x_1, \dots, x_m) \cdot \log_2 p(x_1, \dots, x_m), \quad (2.2)$$

kde  $p(x_1, \dots, x_m) = P(X_1 = x_1, X_2 = x_2, \dots, X_m = x_m)$ .

Snadno se ověří, že:

$$H(\mathbf{X}) = 0 \text{ právě tehdy, když } \mathbf{X} \text{ je konstantní.} \quad (2.3)$$

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - **Horní hranice entropie**
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Horní hranice entropie

Horní hranice pro  $H$  je určena následující větou:

## Věta 2.1

*Pro každé přirozené číslo  $n$  máme*

$$H(p_1, \dots, p_n) \leq \log_2 n,$$


*přičemž rovnost nastává právě tehdy, když*  
 $p_1 = p_2 = \dots = p_n = n^{-1}$ .

# Důkaz Věty 2.1

Zřejmě

$$\log_2 x = \log_2 e \log_e x.$$

Protože logaritmus je konkávní funkce, tj. leží celá pod tečnou, máme (bereme-li derivaci v bodě 1)



$$\log_e x \leq x - 1,$$

přičemž rovnost nastává právě tehdy, když  $x = 1$ .




# Důkaz Věty 2.1

Zřejmě

$$\log_2 x = \log_2 e \log_e x.$$

Protože logaritmus je konkávní funkce, tj. leží celá pod tečnou, máme (bereme-li derivaci v bodě 1)



$$\log_e x \leq x - 1,$$

přičemž rovnost nastává právě tehdy, když  $x = 1$ . Tedy, je-li  $(q_1, \dots, q_n)$  libovolné pravděpodobnostní rozdělení, pak máme

$$\log_e(q_k/p_k) \leq (q_k/p_k) - 1,$$

s rovností právě tehdy, když  $q_k = p_k$ .

# Důkaz Věty 2.1

Tudíž,

$$\sum p_i \cdot \log_e(q_i/p_i) \leq \sum q_k - \sum p_k = 0,$$

a z toho pak

$$\sum p_i \cdot \log_2 q_i \leq \sum p_i \cdot \log_2 p_i.$$

# Důkaz Věty 2.1

Tudíž,

$$\sum p_i \cdot \log_e(q_i/p_i) \leq \sum q_k - \sum p_k = 0,$$

a z toho pak

$$\sum p_i \cdot \log_2 q_i \leq \sum p_i \cdot \log_2 p_i.$$

Položíme-li  $q_i = 1/n$ , obdržíme dosazením

$$H(p_1, \dots, p_n) = - \sum p_i \cdot \log_2 p_i \leq \log_2 n,$$

což se mělo dokázat. Zbytek tvrzení o rovnosti plyne bezprostředně z důkazu.

# Klíčové lemma

Poznamenejme, že jsme dokázali velmi užitečnou nerovnost:

## Lemma 2.2

*Je-li  $\mathbf{p} = (p_i : 1 \leq i \leq n)$  dané pravděpodobnostní rozdělení, pak minimum funkce*

$$G(q_1, \dots, q_n) = - \sum p_i \cdot \log_2 q_i$$

*přes všechna pravděpodobnostní rozdělení  $\mathbf{q} = (q_1, \dots, q_n)$  nastává, pokud  $q_k = p_k$  ( $1 \leq k \leq n$ ).*

Někdy též mluvíme o **relativní entropii**

$$D(\mathbf{p} \parallel \mathbf{q}) = \sum p_i \cdot \log_2 \frac{p_i}{q_i}.$$

Tedy  $D(\mathbf{p} \parallel \mathbf{q}) \geq 0$  a  $D(\mathbf{p} \parallel \mathbf{q}) = 0$ , pokud  $\mathbf{p} = \mathbf{q}$ .

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - **Sčítání entropií**
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Sčítání entropií

## Věta 2.3

*Jsou-li  $X$  a  $Y$  náhodné proměnné s konečným oborem hodnot, platí pak*

$$H(X, Y) \leq H(X) + H(Y),$$

*přičemž rovnost nastává tehdy a jen tehdy, když  $X$  a  $Y$  jsou nezávislé.*

## Důkaz Věty 2.3

Předpokládejme, že

$$r_i = P(X = a_i) \quad (1 \leq i \leq m), \quad s_j = P(Y = b_j) \quad (1 \leq j \leq n),$$

$$t_{ij} = P(X = a_i, Y = b_j) \quad (1 \leq i \leq m, 1 \leq j \leq n).$$

## Důkaz Věty 2.3

Předpokládejme, že

$$r_i = P(X = a_i) \quad (1 \leq i \leq m), \quad s_j = P(Y = b_j) \quad (1 \leq j \leq n),$$

$$t_{ij} = P(X = a_i, Y = b_j) \quad (1 \leq i \leq m, 1 \leq j \leq n).$$

Pak

$$\begin{aligned} H(X) + H(Y) &= - \left( \sum_i r_i \cdot \log_2 r_i + \sum_j s_j \cdot \log_2 s_j \right) \\ &= - \left( \sum_{i,j} t_{ij} \cdot \log_2 r_i + \sum_{j,i} t_{ij} \cdot \log_2 s_j \right), \end{aligned}$$

protože

$$\sum_j t_{ij} = r_i, \quad \sum_i t_{ij} = s_j.$$



# Důkaz Věty 2.3

Odtud pak

$$\begin{aligned} H(X) + H(Y) &= - \sum_{i,j} t_{ij} \cdot \log_2(r_i \cdot s_j) \\ &\geq - \sum_{i,j} t_{ij} \cdot \log_2(t_{ij}) = H(X, Y) \end{aligned}$$

dle předchozího lemmatu.

# Důkaz Věty 2.3

Odtud pak

$$\begin{aligned} H(X) + H(Y) &= - \sum_{i,j} t_{ij} \cdot \log_2(r_i \cdot s_j) \\ &\geq - \sum_{i,j} t_{ij} \cdot \log_2(t_{ij}) = H(X, Y) \end{aligned}$$

dle předchozího lemmatu. Rovnost nastane právě tehdy, když

$$r_i \cdot s_j = t_{ij}.$$

Ale to je právě podmínka nezávislosti  $X$  a  $Y$ .

# Sčítání entropií

Jednoduchým rozšířením této metody lze dokázat:

$$H(X_1, \dots, X_n) \leq H(X_1) + \dots + H(X_n), \quad (2.4)$$

přičemž rovnost nastává právě tehdy, když  $X_1, \dots, X_n$  jsou navzájem nezávislé;

# Sčítání entropií

Jednoduchým rozšířením této metody lze dokázat:

$$H(X_1, \dots, X_n) \leq H(X_1) + \dots + H(X_n), \quad (2.4)$$

přičemž rovnost nastává právě tehdy, když  $X_1, \dots, X_n$  jsou navzájem nezávislé; případně

$$H(\mathbf{U}, \mathbf{V}) \leq H(\mathbf{U}) + H(\mathbf{V}) \quad (2.5)$$

pro každou dvojici náhodných vektorů  $\mathbf{U}, \mathbf{V}$ , přičemž rovnost nastává právě tehdy, když  $\mathbf{U}$  a  $\mathbf{V}$  jsou nezávislé náhodné vektory.

# Sčítání entropií

Jednoduchým rozšířením této metody lze dokázat:

$$H(X_1, \dots, X_n) \leq H(X_1) + \dots + H(X_n), \quad (2.4)$$

přičemž rovnost nastává právě tehdy, když  $X_1, \dots, X_n$  jsou navzájem nezávislé; případně

$$H(\mathbf{U}, \mathbf{V}) \leq H(\mathbf{U}) + H(\mathbf{V}) \quad (2.5)$$

pro každou dvojici náhodných vektorů  $\mathbf{U}, \mathbf{V}$ , přičemž rovnost nastává právě tehdy, když  $\mathbf{U}$  a  $\mathbf{V}$  jsou nezávislé náhodné vektory.

Důkazy (jež lze dokázat přesně stejným způsobem jako větu 2.3 z předchozího lemmatu 2.2) jsou ponechány čtenáři.

# Sčítání entropií

## Cvičení 2.4

- 1 Dvě ideální kostky jsou vrženy;  $X$  označuje hodnotu získanou první kostkou,  $Y$  hodnotu získanou druhou kostkou. Dokažte, že  $H(X, Y) = H(X) + H(Y)$ . Dokažte, že je-li  $Z = X + Y$ , pak

$$H(Z) < H(X, Y).$$

- 2 Dokažte, že pro každou náhodnou proměnnou  $X$ ,

$$H(X, X^2) = H(X).$$

- 3 Dokažte, že pro každou posloupnost náhodných proměnných  $(X_i : 1 \leq i < \infty)$ ,

$$H(X_1, \dots, X_n) \leq H(X_1, \dots, X_{n+1}).$$

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - **Definice podmíněné entropie**
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Podmíněná entropie

**FI** Předpokládejme, že  $X$  je náhodná proměnná na pravděpodobnostním prostoru  $\Omega$  a  $A$  je událost z  $\Omega$ . Nabývá-li  $X$  konečné množiny hodnot  $\{a_i : 1 \leq i \leq m\}$ , je přirozené definovat **podmíněnou entropii** náhodné proměnné  $X$  určenou událostí  $A$  jako

$$H(X|A) = - \sum_{k=1}^m P(X = a_k|A) \log P(X = a_k|A).$$



# Podmíněná entropie

Úplně stejně, je-li  $Y$  jiná náhodná proměnná nabývající hodnot  $b_k$  ( $1 \leq k \leq m$ ), definujeme **podmíněnou entropii** náhodné proměnné  $X$  určenou náhodnou proměnnou  $Y$  jako

$$H(X|Y) = \sum_j H(X|Y = b_j)P(Y = b_j).$$

# Podmíněná entropie

Úplně stejně, je-li  $Y$  jiná náhodná proměnná nabývající hodnot  $b_k$  ( $1 \leq k \leq m$ ), definujeme **podmíněnou entropii** náhodné proměnné  $X$  určenou náhodnou proměnnou  $Y$  jako

$$H(X|Y) = \sum_j H(X|Y = b_j)P(Y = b_j).$$

Považujeme  $H(X|Y)$  za entropii náhodné proměnné  $X$  určenou jistou hodnotou  $Y$  zprůměrovanou přes všechny hodnoty, jichž může  $Y$  nabývat.

Zcela triviální důsledky definic jsou:

$$H(X|X) = 0, \tag{3.1}$$

$$H(X|Y) = H(X) \text{ jsou-li } X \text{ a } Y \text{ nezávislé.} \tag{3.2}$$

# Podmíněná entropie

## Příklad 3.1

*Bud'  $X$  náhodná proměnná získaná vrháním ideální kostky. Bud' dále  $Y$  jiná náhodná proměnná určená tímtož experimentem, přičemž  $Y$  se rovná 1, je-li vržená hodnota lichá a 0 v ostatních případech. Protože kostka je ideální, platí*

$$H(X) = \log 6, H(Y) = \log 2 \text{ a } H(X|Y) = \log 3.$$

# Podmíněná entropie

## Příklad 3.1

*Bud'  $X$  náhodná proměnná získaná vrháním ideální kostky. Bud' dále  $Y$  jiná náhodná proměnná určená tímtéž experimentem, přičemž  $Y$  se rovná 1, je-li vržená hodnota lichá a 0 v ostatních případech. Protože kostka je ideální, platí*

$$H(X) = \log 6, H(Y) = \log 2 \text{ a } H(X|Y) = \log 3.$$

Jsou-li  $\mathbf{U}$  a  $\mathbf{V}$  náhodné vektory, přirozeně rozšíříme definici podmíněné entropie následovně

$$H(\mathbf{U}|\mathbf{V}) = \sum_j H(\mathbf{U}|\mathbf{V} = \mathbf{v}_j)P(\mathbf{V} = \mathbf{v}_j), \quad (3.3)$$

přičemž se sčítá, jako obvykle, přes (konečný) obor hodnot  $\mathbf{v}_j$  tak, že odpovídající pravděpodobnost je kladná.

# Obsah

- 1 Nejistota
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 Entropie a její vlastnosti
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - **Vlastnosti podmíněné entropie**
- 4 Informace
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 Závěr
  - Shrnutí

# Vlastnosti podmíněné entropie

Jako první příklad, jakým způsobem entropie  $H(\mathbf{U}|\mathbf{V})$  měří nejistotu o  $\mathbf{U}$  obsaženou ve  $\mathbf{V}$ , dokážeme:

$$H(\mathbf{U}|\mathbf{V}) = 0 \text{ právě tehdy, když } \mathbf{U} = g(\mathbf{V}) \text{ pro nějakou funkci } g. \quad (3.4)$$

# Vlastnosti podmíněné entropie

Jako první příklad, jakým způsobem entropie  $H(\mathbf{U}|\mathbf{V})$  měří nejistotu o  $\mathbf{U}$  obsaženou ve  $\mathbf{V}$ , dokážeme:

$$H(\mathbf{U}|\mathbf{V}) = 0 \text{ právě tehdy, když } \mathbf{U} = g(\mathbf{V}) \text{ pro nějakou funkci } g. \quad (3.4)$$

Důkaz. Pravá strana z definice podmíněné entropie je součet konečného počtu nezáporných veličin.

# Vlastnosti podmíněné entropie

Jako první příklad, jakým způsobem entropie  $H(\mathbf{U}|\mathbf{V})$  měří nejistotu o  $\mathbf{U}$  obsaženou ve  $\mathbf{V}$ , dokážeme:

$$H(\mathbf{U}|\mathbf{V}) = 0 \text{ právě tehdy, když } \mathbf{U} = g(\mathbf{V}) \text{ pro nějakou funkci } g. \quad (3.4)$$

Důkaz. Pravá strana z definice podmíněné entropie je součet konečného počtu nezáporných veličin.

Tudíž, aby byla nulová, potřebujeme  $H(\mathbf{U}|\mathbf{V} = \mathbf{v}_j) = 0$  pro všechna  $j$ .



# Vlastnosti podmíněné entropie

Jako první příklad, jakým způsobem entropie  $H(\mathbf{U}|\mathbf{V})$  měří nejistotu o  $\mathbf{U}$  obsaženou ve  $\mathbf{V}$ , dokážeme:

$$H(\mathbf{U}|\mathbf{V}) = 0 \text{ právě tehdy, když } \mathbf{U} = g(\mathbf{V}) \text{ pro nějakou funkci } g. \quad (3.4)$$

Důkaz. Pravá strana z definice podmíněné entropie je součet konečného počtu nezáporných veličin.

Tudíž, aby byla nulová, potřebujeme  $H(\mathbf{U}|\mathbf{V} = \mathbf{v}_j) = 0$  pro všechna  $j$ .

Ale opět každá z těchto nezáporných veličin je nulová právě tehdy, když  $\mathbf{U}$  je jednoznačně určená  $\mathbf{V}$ .

# Vlastnosti podmíněné entropie - řetězcové pravidlo

Poněkud více nám dává následující výsledek, který matematicky vyjadřuje ideu, že naše definice podmíněné entropie  $X$  při daném  $Y$  korektně měří zbývající nejistotu.

# Vlastnosti podmíněné entropie - řetězcové pravidlo

Poněkud více nám dává následující výsledek, který matematicky vyjadřuje ideu, že naše definice podmíněné entropie  $X$  při daném  $Y$  korektně měří zbývající nejistotu.

## Věta 3.2

*Pro každou dvojici náhodných proměnných  $X$  a  $Y$ , které nabývají pouze konečné množiny hodnot, platí*

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


# Vlastnosti podmíněné entropie - řetězcové pravidlo

Poněkud více nám dává následující výsledek, který matematicky vyjadřuje ideu, že naše definice podmíněné entropie  $X$  při daném  $Y$  korektně měří zbývající nejistotu.

## Věta 3.2

*Pro každou dvojici náhodných proměnných  $X$  a  $Y$ , které nabývají pouze konečné množiny hodnot, platí*

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



## Důkaz Věty 3.2

Bez ztráty na obecnosti lze předpokládat, že  $X$  a  $Y$  nabývají pouze celočíselných hodnot a, kde to bude nutné, že  $p_{ij} = P(X = i, Y = j)$ .

# Důkaz Věty 3.2

Bez ztráty na obecnosti lze předpokládat, že  $X$  a  $Y$  nabývají pouze celočíselných hodnot a, kde to bude nutné, že  $p_{ij} = P(X = i, Y = j)$ .

Nyní

$$\begin{aligned} H(X, Y) &= - \sum_i \sum_j P(X = i, Y = j) \log P(X = i, Y = j) \\ &= - \sum_i \sum_j P(X = i, Y = j) \log P(X = i | Y = j) P(Y = j) \\ &= - \sum_i \sum_j p_{ij} \log P(X = i | Y = j) - \sum_i \sum_j p_{ij} \log P(Y = j). \end{aligned}$$

# Důkaz Věty 3.2

Tedy

$$\begin{aligned}H(X, Y) &= -\sum_i \sum_j p_{ij} \log P(X = i | Y = j) - \sum_i \sum_j p_{ij} \log P(Y = j) \\&= -\sum_i \sum_j P(X = i | Y = j) P(Y = j) \log P(X = i | Y = j) + H(Y) \\&= -\sum_j P(Y = j) \sum_i P(X = i | Y = j) \log P(X = i | Y = j) + H(Y) \\&= \sum_j P(Y = j) H(X | Y = j) + H(Y) \\&= H(X | Y) + H(Y), \text{ což bylo třeba dokázat.}\end{aligned}$$

# Vlastnosti podmíněné entropie - řetězové pravidlo

## Věta 3.3

*Jsou-li  $\mathbf{U}$  a  $\mathbf{V}$  náhodné vektory, které nabývají pouze konečné množiny hodnot, platí*

$$H(\mathbf{U}, \mathbf{V}) = H(\mathbf{V}) + H(\mathbf{U}|\mathbf{V}).$$



# Vlastnosti podmíněné entropie - řetězcové pravidlo

## Věta 3.3

*Jsou-li  $\mathbf{U}$  a  $\mathbf{V}$  náhodné vektory, které nabývají pouze konečné množiny hodnot, platí*

$$H(\mathbf{U}, \mathbf{V}) = H(\mathbf{V}) + H(\mathbf{U}|\mathbf{V}).$$

Důkaz Věty 3.3: Procházíme důkazem předchozí věty, ale namísto  $X$  a  $Y$  nabývajících pouze celočíselných hodnot  $i$  a  $j$  máme  $\mathbf{U}$  a  $\mathbf{V}$  nabývajících hodnot  $\mathbf{u}_i$  a  $\mathbf{v}_j$ , kde  $\mathbf{u}_i$  a  $\mathbf{v}_j$  jsou zadané vektory.

# Vlastnosti podmíněné entropie

## Důsledek 3.4

*Pro každou dvojici  $\mathbf{X}$  a  $\mathbf{Y}$  náhodných vektorů je  $H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X})$  a rovnost nastává právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.*

# Vlastnosti podmíněné entropie

## Důsledek 3.4

*Pro každou dvojici  $\mathbf{X}$  a  $\mathbf{Y}$  náhodných vektorů je  $H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X})$  a rovnost nastává právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.*

Důkaz Důsledku 3.4: Z Věty 3.3 máme

$$H(\mathbf{X}|\mathbf{Y}) = H(\mathbf{X}, \mathbf{Y}) - H(\mathbf{Y}).$$

# Vlastnosti podmíněné entropie

## Důsledek 3.4

*Pro každou dvojici  $\mathbf{X}$  a  $\mathbf{Y}$  náhodných vektorů je  $H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X})$  a rovnost nastává právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.*

Důkaz Důsledku 3.4: Z Věty 3.3 máme

$$H(\mathbf{X}|\mathbf{Y}) = H(\mathbf{X}, \mathbf{Y}) - H(\mathbf{Y}).$$

Ale  $H(\mathbf{X}|\mathbf{Y}) + H(\mathbf{Y}) = H(\mathbf{X}, \mathbf{Y}) \leq H(\mathbf{X}) + H(\mathbf{Y})$ , s rovností právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.

# Vlastnosti podmíněné entropie

## Důsledek 3.4

*Pro každou dvojici  $\mathbf{X}$  a  $\mathbf{Y}$  náhodných vektorů je  $H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X})$  a rovnost nastává právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.*

Důkaz Důsledku 3.4: Z Věty 3.3 máme

$$H(\mathbf{X}|\mathbf{Y}) = H(\mathbf{X}, \mathbf{Y}) - H(\mathbf{Y}).$$

Ale  $H(\mathbf{X}|\mathbf{Y}) + H(\mathbf{Y}) = H(\mathbf{X}, \mathbf{Y}) \leq H(\mathbf{X}) + H(\mathbf{Y})$ , s rovností právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.

Tedy  $H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X})$  a rovnost nastává právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.

# Vlastnosti podmíněné entropie

## Cvičení 3.5

- 1 Ukažte, že pro každou náhodnou proměnnou  $X$  platí

$$H(X^2|X) = 0,$$

ale uveďte příklad, že  $H(X|X^2)$  není vždy nulová.

# Vlastnosti podmíněné entropie

## Cvičení 3.5

- 1 Ukažte, že pro každou náhodnou proměnnou  $X$  platí

$$H(X^2|X) = 0,$$

ale uveďte příklad, že  $H(X|X^2)$  není vždy nulová.

- 2 Náhodná proměnná  $X$  nabývá celočíselných hodnot  $1, \dots, 2N$  se stejnou pravděpodobností. Náhodná proměnná  $Y$  je definovaná  $Y = 0$ , je-li  $X$  sudá, ale  $Y = 1$ , je-li  $X$  lichá. Ukažte, že

$$H(X|Y) = H(X) - 1,$$

ale že  $H(Y|X) = 0$ .

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - **Motivace**
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí



# Informace

**FI** Zdá se, že R.V.L. Hartley byl v r. 1928 první, kdo se pokusil přiřadit kvantitativní míru k pojmu informace.

# Informace

**FI** Zdá se, že R.V.L. Hartley byl v r. 1928 první, kdo se pokusil přiřadit kvantitativní míru k pojmu informace.

Jeho myšlenky byly pak pomocí matematické statistiky a teorie pravděpodobnosti zevšeobecněny Shannonem, Wienerem a Fischerem koncem 40. let téhož století a daly základ kvantitativní teorii informace, která se zaměřovala na problémy související s množstvím informace, ale ne na problém, co to vlastně informace je.

# Informace

**FI** Zdá se, že R.V.L. Hartley byl v r. 1928 první, kdo se pokusil přiřadit kvantitativní míru k pojmu informace.

Jeho myšlenky byly pak pomocí matematické statistiky a teorie pravděpodobnosti zevšeobecněny Shannonem, Wienerem a Fischerem koncem 40. let téhož století a daly základ kvantitativní teorii informace, která se zaměřovala na problémy související s množstvím informace, ale ne na problém, co to vlastně informace je.

Naznačily však, že je třeba hledat odpověď v obsahových a kvalitativních projevech informace.

# Informace

Racionální příčinu tohoto pokusu můžeme částečně popsat následovně.

# Informace

Racionální příčinu tohoto pokusu můžeme částečně popsat následovně.

Předpokládejme, že  $E_1$  a  $E_2$  jsou dvě události v pravděpodobnostním prostoru  $\Omega$  spojené jistým experimentem a předpokládejme, že funkce  $I$  je naše míra informace.

# Informace

Racionální příčinu tohoto pokusu můžeme částečně popsat následovně.

Předpokládejme, že  $E_1$  a  $E_2$  jsou dvě události v pravděpodobnostním prostoru  $\Omega$  spojené jistým experimentem a předpokládejme, že funkce  $I$  je naše míra informace. Mají-li  $E_1$  a  $E_2$  pravděpodobnosti  $p_1$  a  $p_2$ , pak můžeme argumentovat tím, že každá přirozená míra obsahu informace by měla splňovat

$$I(p_1 p_2) = I(p_1) + I(p_2)$$

# Informace

Racionální příčinu tohoto pokusu můžeme částečně popsat následovně.

Předpokládejme, že  $E_1$  a  $E_2$  jsou dvě události v pravděpodobnostním prostoru  $\Omega$  spojené jistým experimentem a předpokládejme, že funkce  $I$  je naše míra informace. Mají-li  $E_1$  a  $E_2$  pravděpodobnosti  $p_1$  a  $p_2$ , pak můžeme argumentovat tím, že každá přirozená míra obsahu informace by měla splňovat

$$I(p_1 p_2) = I(p_1) + I(p_2)$$

na základě toho, že, pro **dvě nezávislé realizace experimentu**, informace, pro kterou výsledky těchto experimentů dopadnou jako  $E_1$  následováno  $E_2$ , by měla být **součtem informací** získaných provedením těchto experimentů zvlášť.

# Informace

Připustíme-li, že výše uvedená rovnost má jistou platnost, a přejeme-li si mít naši míru nezápornou a spojitou v  $p$ , což jsou oba přirozené předpoklady, zbývá nám s malou alternativou *definovat informaci*  $I$  události  $E$  kladné pravděpodobnosti jako

$$I(E) = -\log_2 P(E),$$

přičemž jsme vybrali 2 jako základ našich logaritmů, abychom zachovali soulad s moderní konvencí.



# Informace

Připustíme-li, že výše uvedená rovnost má jistou platnost, a přejeme-li si mít naši míru nezápornou a spojitou v  $p$ , což jsou oba přirozené předpoklady, zbývá nám s malou alternativou *definovat informaci*  $I$  události  $E$  kladné pravděpodobnosti jako

$$I(E) = -\log_2 P(E),$$

přičemž jsme vybrali 2 jako základ našich logaritmů, abychom zachovali soulad s moderní konvencí.

Hartley původně použil logaritmy o základu 10. Někdy též mluvíme o **Hartleyově míře informace**.

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - **Charakterizace**
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Informace

Platí totiž následující tvrzení

## Věta 4.1

*Funkce  $I(p)$ , definovaná pro všechna  $0 < p \leq 1$ , splňuje podmínky*

- *$I(p) \geq 0$ , pro všechna  $0 < p \leq 1$ ,*
- *$I(p \cdot q) = I(p) + I(q)$  pro všechny  $0 < p, q \leq 1$  takové, že  $p$  a  $q$  jsou pravděpodobnosti navzájem nezávislých jevů, a*
- *podmínku spojitosti vzhledem k  $p$*

*právě tehdy, když je tvaru*

$$I(p) = -\lambda \log_2 p,$$

*kde  $\lambda$  je kladná konstanta.*

# Důkaz Věty 4.1

Ponecháme za cvičení ukázat, že každá funkce výše uvedeného tvaru splňuje všechny tři podmínky.

# Důkaz Věty 4.1

Ponecháme za cvičení ukázat, že každá funkce výše uvedeného tvaru splňuje všechny tři podmínky.

Abychom dokázali obrácené tvrzení, připomeňme, že z vlastnosti  $I(p \cdot q) = I(p) + I(q)$  máme  $I(p^n) = nI(p)$  pro všechna kladná přirozená čísla  $n$ . Speciálně tedy platí

$$I(p^{\frac{1}{n}}) = \frac{1}{n}I(p).$$

# Důkaz Věty 4.1

Ponecháme za cvičení ukázat, že každá funkce výše uvedeného tvaru splňuje všechny tři podmínky.

Abychom dokázali obrácené tvrzení, připomeňme, že z vlastnosti  $I(p \cdot q) = I(p) + I(q)$  máme  $I(p^n) = nI(p)$  pro všechna kladná přirozená čísla  $n$ . Speciálně tedy platí

$$I(p^{\frac{1}{n}}) = \frac{1}{n}I(p).$$

Odtud pak máme

$$I(p^{\frac{n}{m}}) = nI(p^{\frac{1}{m}}) = \frac{n}{m}I(p),$$

tj. platí  $I(p^q) = qI(p)$  pro všechna kladná racionální čísla  $q$ .

# Důkaz Věty 4.1

Ze spojitosti umocňování a funkce  $I$  máme, že pro všechna kladná reálná čísla  $r$  musí platit

$$I(p^r) = rI(p).$$

# Důkaz Věty 4.1

Ze spojitosti umocňování a funkce  $I$  máme, že pro všechna kladná reálná čísla  $r$  musí platit

$$I(p^r) = rI(p).$$

Bud' nyní  $p$  libovolné, pevně zvolené číslo,  $0 < p < 1$ . Protože každé číslo  $q$ ,  $0 < q < 1$  lze psát ve tvaru  $q = p^{\log_p q}$ , máme pak

$$I(q) = I(p^{\log_p q}) = I(p)\log_p q = I(p)\frac{\log_2 q}{\log_2 p} = -\lambda \log_2 q,$$

pro vhodnou kladnou konstantu  $\lambda = -\frac{I(p)}{\log_2 p}$ .



# Důkaz Věty 4.1

Ze spojitosti umocňování a funkce  $I$  máme, že pro všechna kladná reálná čísla  $r$  musí platit

$$I(p^r) = rI(p).$$

Bud' nyní  $p$  libovolné, pevně zvolené číslo,  $0 < p < 1$ . Protože každé číslo  $q$ ,  $0 < q < 1$  lze psát ve tvaru  $q = p^{\log_p q}$ , máme pak

$$I(q) = I(p^{\log_p q}) = I(p)\log_p q = I(p)\frac{\log_2 q}{\log_2 p} = -\lambda \log_2 q,$$

pro vhodnou kladnou konstantu  $\lambda = -\frac{I(p)}{\log_2 p}$ .

Ze spojitosti funkce  $I$  plyne  $I(1) = 0$ .

# Příklad

## Příklad 4.2

*Předpokládejme, že máme zdroj, který emituje řetězec binárních číslic 0 a 1, každou se stejnou pravděpodobností a nezávisle pro po sobě jdoucích číslicích. Bud'  $E$  událost, že prvních  $n$  číslic jsou střídavě nuly a jedničky. Pak evidentně*

$$I(E) = -\log_2 \frac{1}{2^n} = n$$

*a totéž platí pro každou předepsanou posloupnost číslic délky  $n$ .*

# Příklad

## Příklad 4.2

*Předpokládejme, že máme zdroj, který emituje řetězec binárních číslic 0 a 1, každou se stejnou pravděpodobností a nezávisle pro po sobě jdoucích číslicích. Bud'  $E$  událost, že prvních  $n$  číslic jsou střídavě nuly a jedničky. Pak evidentně*

$$I(E) = -\log_2 \frac{1}{2^n} = n$$

*a totéž platí pro každou předepsanou posloupnost číslic délky  $n$ .*

Tedy "informačně-teoretická" jednotka informace, totiž *bit*, odpovídá přirozeně využití slova "bit", které znamená binární číslo v současné počítačové terminologii.

# Informace pro náhodné vektory

Rozšíříme pojem informace na to, abychom pokryli náhodné proměnné a vektory následovně.

# Informace pro náhodné vektory

Rozšíříme pojem informace na to, abychom pokryli náhodné proměnné a vektory následovně.

Předpokládejme, že  $\mathbf{X}$  je náhodný vektor, který nabývá hodnoty  $\mathbf{x}_1, \dots, \mathbf{x}_m$ , s pravděpodobnostmi  $p_1, \dots, p_m$ .

# Informace pro náhodné vektory

Rozšíříme pojem informace na to, abychom pokryli náhodné proměnné a vektory následovně.

Předpokládejme, že  $\mathbf{X}$  je náhodný vektor, který nabývá hodnoty  $\mathbf{x}_1, \dots, \mathbf{x}_m$ , s pravděpodobnostmi  $p_1, \dots, p_m$ .

Pak každá z elementárních událostí  $\mathbf{X} = \mathbf{x}_k$  ( $1 \leq k \leq m$ ) obsahuje sdruženou informaci rovnou  $-\log_2 p_k$  a poznamenejme, že entropie vektoru  $\mathbf{X}$  je určena vztahem

$$H(\mathbf{X}) = - \sum p_k \log_2 p_k = \sum p_k I(\mathbf{X} = \mathbf{x}_k),$$

# Informace pro náhodné vektory

Rozšíříme pojem informace na to, abychom pokryli náhodné proměnné a vektory následovně.

Předpokládejme, že  $\mathbf{X}$  je náhodný vektor, který nabývá hodnoty  $\mathbf{x}_1, \dots, \mathbf{x}_m$ , s pravděpodobnostmi  $p_1, \dots, p_m$ .

Pak každá z elementárních událostí  $\mathbf{X} = \mathbf{x}_k$  ( $1 \leq k \leq m$ ) obsahuje sdruženou informaci rovnou  $-\log_2 p_k$  a poznamenejme, že entropie vektoru  $\mathbf{X}$  je určena vztahem

$$H(\mathbf{X}) = - \sum p_k \log_2 p_k = \sum p_k I(\mathbf{X} = \mathbf{x}_k),$$

tedy  $H(\mathbf{X})$  má přirozenou interpretaci jako střední hodnota informace sdružené s elementárními událostmi určenými  $\mathbf{X}$ .

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - **Vzájemná informace**
- 5 **Závěr**
  - Shrnutí



# Vzájemná informace pro náhodné vektory

Obecněji, jsou-li  $\mathbf{X}$  a  $\mathbf{Y}$  dva náhodné vektory, definujeme *vzájemnou informaci o  $\mathbf{X}$  poskytnutou  $\mathbf{Y}$*  jako číslo

$$I(\mathbf{X}|\mathbf{Y}) = H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}).$$

# Vzájemná informace pro náhodné vektory

Obecněji, jsou-li  $\mathbf{X}$  a  $\mathbf{Y}$  dva náhodné vektory, definujeme *vzájemnou informaci o  $\mathbf{X}$  poskytnutou  $\mathbf{Y}$*  jako číslo

$$I(\mathbf{X}|\mathbf{Y}) = H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}).$$

Jinak řečeno,  $I(\mathbf{X}|\mathbf{Y})$  vyjadřuje množství nejistoty o  $\mathbf{X}$  odstraněné  $\mathbf{Y}$ .

# Vzájemná informace pro náhodné vektory

Obecněji, jsou-li  $\mathbf{X}$  a  $\mathbf{Y}$  dva náhodné vektory, definujeme *vzájemnou informaci o  $\mathbf{X}$  poskytnutou  $\mathbf{Y}$*  jako číslo

$$I(\mathbf{X}|\mathbf{Y}) = H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}).$$

Jinak řečeno,  $I(\mathbf{X}|\mathbf{Y})$  vyjadřuje množství nejistoty o  $\mathbf{X}$  odstraněné  $\mathbf{Y}$ . Zřejmě platí, že

$$I(\mathbf{X}|\mathbf{X}) = H(\mathbf{X}),$$

$I(\mathbf{X}|\mathbf{Y}) = 0$  právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.

# Vzájemná informace pro náhodné vektory

Obecněji, jsou-li  $\mathbf{X}$  a  $\mathbf{Y}$  dva náhodné vektory, definujeme *vzájemnou informaci o  $\mathbf{X}$  poskytnutou  $\mathbf{Y}$*  jako číslo

$$I(\mathbf{X}|\mathbf{Y}) = H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}).$$

Jinak řečeno,  $I(\mathbf{X}|\mathbf{Y})$  vyjadřuje množství nejistoty o  $\mathbf{X}$  odstraněné  $\mathbf{Y}$ . Zřejmě platí, že

$$I(\mathbf{X}|\mathbf{X}) = H(\mathbf{X}),$$


$I(\mathbf{X}|\mathbf{Y}) = 0$  právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.

Důkaz. Výsledek plyne bezprostředně z dřívější poznámky, že  $H(\mathbf{X}) = H(\mathbf{X}|\mathbf{Y})$  právě tehdy, když  $\mathbf{X}$  a  $\mathbf{Y}$  jsou nezávislé.

# Vzájemná informace pro náhodné vektory

Poněkud udivující symetrie v  $I$  je následující výsledek, který zřejmě nemá intuitivní vysvětlení.

$$\begin{aligned} I(\mathbf{X}|\mathbf{Y}) &= H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}) \\ &= H(\mathbf{X}) - [H(\mathbf{X}, \mathbf{Y}) - H(\mathbf{Y})] \\ &= H(\mathbf{X}) + H(\mathbf{Y}) - H(\mathbf{X}, \mathbf{Y}) \\ &= I(\mathbf{Y}|\mathbf{X}). \end{aligned}$$



# Vzájemná informace pro náhodné vektory

## Cvičení 4.3

- 1 *Co má větší informační obsah: posloupnost deseti písmen nad abecedou o 26 písmenech nebo posloupnost 26 číslic z množiny  $\{0, 1, \dots, 9\}$ ? [ Předpokládejte, že všechny posloupnosti mají stejnou pravděpodobnost.]*
- 2 *Ideální kostka je vržena. Ukažte, že informace o hodnotě kostky daná znalostí, že se jedná o nesložené číslo, má velikost  $\log_2 \frac{3}{2}$ .*

# Vztah vzájemné informace a relativní entropie

## Věta 4.4

*Jsou-li  $\mathbf{X}$  a  $\mathbf{Y}$  dva náhodné vektory s pravděpodobnostními rozděleními  $\mathbf{p} = (p_i : 1 \leq i \leq m)$  a  $\mathbf{q} = (q_j : 1 \leq j \leq n)$  a náhodný vektor  $(\mathbf{X}, \mathbf{Y})$  má pravděpodobnostní rozdělení  $\mathbf{p}_{(\mathbf{X}, \mathbf{Y})} = (r_{i,j} : 1 \leq i \leq m, 1 \leq j \leq n)$ , pak*

$$I(\mathbf{X}|\mathbf{Y}) = \sum_{i,j} r_{i,j} \log_2 \frac{r_{i,j}}{p_i \cdot q_j} = D(\mathbf{p}_{(\mathbf{X}, \mathbf{Y})} || \mathbf{p}\mathbf{q}),$$

*kde  $\mathbf{p}\mathbf{q}$  je součinnové rozdělení marginálů náhodného vektoru  $(\mathbf{X}, \mathbf{Y})$ .*

# Vztah vzájemné informace a relativní entropie

## Věta 4.4

*Jsou-li  $\mathbf{X}$  a  $\mathbf{Y}$  dva náhodné vektory s pravděpodobnostními rozděleními  $\mathbf{p} = (p_i : 1 \leq i \leq m)$  a  $\mathbf{q} = (q_j : 1 \leq j \leq n)$  a náhodný vektor  $(\mathbf{X}, \mathbf{Y})$  má pravděpodobnostní rozdělení  $\mathbf{p}_{(\mathbf{X}, \mathbf{Y})} = (r_{i,j} : 1 \leq i \leq m, 1 \leq j \leq n)$ , pak*

$$I(\mathbf{X}|\mathbf{Y}) = \sum_{i,j} r_{i,j} \log_2 \frac{r_{i,j}}{p_i \cdot q_j} = D(\mathbf{p}_{(\mathbf{X}, \mathbf{Y})} || \mathbf{pq}),$$

*kde  $\mathbf{pq}$  je součinnové rozdělení marginálů náhodného vektoru  $(\mathbf{X}, \mathbf{Y})$ .*

$I(\mathbf{X}|\mathbf{Y})$  měří odlišnost sdruženého rozdělení náhodného vektoru  $(\mathbf{X}, \mathbf{Y})$  od součinnového rozdělení, kterým by se vektor  $(\mathbf{X}, \mathbf{Y})$  řídil, pokud by  $\mathbf{X}$  a  $\mathbf{Y}$  byly nezávislé.



# Důkaz Věty 4.4

Uvědomme si nejprve, že

$$\mathbf{p}(x, y) = \mathbf{p}_{X|Y} \mathbf{q},$$

kde  $\mathbf{p}_{X|Y}$  je pravděpodobnostní rozdělení náhodného vektoru  $\mathbf{X}|Y$ .

# Důkaz Věty 4.4

Uvědomme si nejprve, že

$$\mathbf{p}_{(\mathbf{X}, \mathbf{Y})} = \mathbf{p}_{\mathbf{X}|\mathbf{Y}}\mathbf{q},$$

kde  $\mathbf{p}_{\mathbf{X}|\mathbf{Y}}$  je pravděpodobnostní rozdělení náhodného vektoru  $\mathbf{X}|\mathbf{Y}$ . Platí pak

$$\begin{aligned} I(\mathbf{X}|\mathbf{Y}) &= H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}) \\ &= -\sum_i p_i \log_2 p_i - \sum_j q_j H(\mathbf{X}|\mathbf{Y} = \mathbf{y}_j) \\ &= -\sum_{i,j} (r_{i,j} \log_2 p_i - q_j \mathbf{P}(\mathbf{X} = \mathbf{x}_i | \mathbf{Y} = \mathbf{y}_j) \log_2 \mathbf{P}(\mathbf{X} = \mathbf{x}_i | \mathbf{Y} = \mathbf{y}_j)) \\ &= \sum_{i,j} \left( r_{i,j} \log_2 \frac{r_{i,j}}{q_j} - r_{i,j} \log_2 p_i \right) \\ &= \sum_{i,j} r_{i,j} \log_2 \frac{r_{i,j}}{p_i \cdot q_j} = D(\mathbf{p}_{(\mathbf{X}, \mathbf{Y})} \| \mathbf{p}\mathbf{q}) \end{aligned}$$

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Shrnutí

Shrneme-li předchozí odstavce, ukázali jsme, že nejistota a informace jsou tytéž veličiny a odstranění nejistoty je rovno podání informace. Obě veličiny jsou měřitelné matematickým pojmem entropie, který je jednoznačně definován (až na multiplikativní konstantu) veličinou

$$H = -\lambda \sum p_i \cdot \log p_i.$$

Konvence si žádá, aby logaritmy byly brány o základu 2, v kterémžto případě je jednotka entropie *bit*.

# Obsah

- 1 **Nejistota**
  - Motivace
  - Definice nejistoty
  - Charakterizace nejistoty a její důsledky
- 2 **Entropie a její vlastnosti**
  - Entropie náhodného vektoru
  - Horní hranice entropie
  - Sčítání entropií
- 3 **Podmíněná entropie**
  - Definice podmíněné entropie
  - Vlastnosti podmíněné entropie
- 4 **Informace**
  - Motivace
  - Charakterizace
  - Vzájemná informace
- 5 **Závěr**
  - Shrnutí

# Problémy k řešení

## Problémy 1

- 1 *Diskžokej má slovník o kapacitě 10 000 slov a pronáší 1000 slov náhodně (opakování je dovoleno). Ukažte, že informační obsah jeho 1000 slov je mnohonásobně menší než obrazovky televizního přijímače o 500 řádcích a 600 sloupcích, přičemž každý pixel nabývá jednu z 16 úrovní jasů.*

# Problémy k řešení

## Problémy 1

- 1 *Diskžokej má slovník o kapacitě 10 000 slov a pronáší 1000 slov náhodně (opakování je dovoleno). Ukažte, že informační obsah jeho 1000 slov je mnohonásobně menší než obrazovky televizního přijímače o 500 řádcích a 600 sloupcích, přičemž každý pixel nabývá jednu z 16 úrovní jasu.*
- 2 *Jsou-li  $X$  a  $Y$  diskrétní náhodné proměnné, které nabývají pouze konečného počtu hodnot, ukažte, že*

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

*Ukažte, že*

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

*neplatí obecně pro  $g : \mathbf{R}^2 \rightarrow \mathbf{R}$ .*

# Problémy k řešení

## Problémy 1

- 3 *Je-li  $(X_i : 1 \leq i < \infty)$  posloupnost náhodných proměnných a  $Y$  je nějaká jiná náhodná proměnná, dokažte, že*

$$H(X_1, \dots, X_n | Y) \leq H(X_1, \dots, X_{n+1} | Y)$$

*pro každé přirozené číslo  $n$ .*

- 4 *Statistický přehled ženatých dvojic ukazuje, že 70% mužů mělo tmavé vlasy, 25% žen bylo blondýnek a že 80% blondýnek si bere tmavovlasé muže. Kolik informace o barvě mužových vlasů je sděleno barvou vlasů jeho ženy?*
- 5 *Jsou-li  $\mathbf{X}$ ,  $\mathbf{Y}$ ,  $\mathbf{Z}$  náhodné vektory, přičemž každý z nich nabývá pouze konečně mnoha hodnot, dokažte, že*

$$H(\mathbf{Y} | \mathbf{X}) + H(\mathbf{Z} | \mathbf{X}) \geq H(\mathbf{Y}, \mathbf{Z} | \mathbf{X}).$$



# Problémy k řešení

## Problémy 1

- 6 Dokažte, že pro každý náhodný vektor  $\mathbf{Y}$  a pro každou množinu náhodných proměnných  $X_1, \dots, X_{n+1}$  platí

$$H(\mathbf{Y}|X_1, \dots, X_n) \geq H(\mathbf{Y}|X_1, \dots, X_{n+1}).$$

- 7 Jsou-li  $X$  a  $Y$  dvě náhodné proměnné a  $f$  a  $g$  jsou libovolné dvě funkce, dokažte, že

$$H(f(X), g(Y)) \leq H(X, Y).$$

- 8 Náhodná proměnná  $X$  má binomiální rozdělení s parametry  $n$  a  $p$  a platí, pro  $0 \leq k \leq n$ ,

$$P(X = k) = \binom{n}{k} p^k q^{n-k},$$

kde  $0 < p < 1$  a  $q = 1 - p$ .

Dokažte, že  $H(X) \leq -n(p \log p + q \log q)$ .

# Problémy k řešení

## Problémy 1

- 9 *Náhodná veličina  $X$  má geometrické rozložení a nabývá celočíselných hodnot  $k = 0, 1, 2, \dots$  s pravděpodobnostmi*

$$p_k = P(X = k) = pq^k,$$

*kde  $0 < p$  a  $p + q = 1$ . Ukažte, že rozšíříme-li pojem entropie a definujeme-li*

$$H(X) = - \sum_{k=0}^{\infty} p_k \cdot \log p_k,$$

*kdykoliv pravá strana konverguje, pak zejména*

$$H(X) = -(p \log p + q \log q) / p.$$

# Problémy k řešení

## Problémy 1

- 10 *Nazvěme dvě náhodné proměnné  $X$  a  $Y$  ekvivalentní, jestliže  $H(X|Y) = 0$  a  $H(Y|X) = 0$ . Dokažte, že jsou-li  $X$  a  $Y$  ekvivalentní a  $Z$  a  $Y$  jsou ekvivalentní, jsou i  $Z$  a  $X$  jsou ekvivalentní.*
- 11 *Definujme vzdálenost mezi dvěma náhodnými proměnnými  $X$  a  $Y$  jako*

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

*Dokažte, že pro všechny tři náhodné proměnné  $X, Y, Z$  platí*

$$d(X, Y) + d(Y, Z) \geq d(X, Z).$$

# Problémy k řešení

## Problémy 1

- 12 Předpokládejte, že  $X$  je náhodná proměnná nabývající hodnot  $v_1, \dots, v_n$ . Ukažte, že je-li  $E(X) = \mu$  a  $X$  je náhodná proměnná s maximální entropií vzhledem k těmto omezením, pak

$$p_j = P(X = v_j) = Ae^{-\alpha v_j},$$

kde  $A$  a  $\alpha$  jsou konstanty určené vztahy  $E(X) = \mu$  a  $\sum p_j = 1$ .

*Poznámka:* hořejší příklad je ilustrací principu maximální entropie: jedná se o rozšíření Laplaceova principu nedostatečné příčiny; tento je často užíván ve statistické mechanice, vytváření obrazů a podobně jako je princip pro vybrání a priori distribuce vzhledem k různým omezením. Viz např. Guiasu a Shenitzer (1985).