

# Úvod do teorie informace

Matematické základy komprese a digitální komunikace

Tomáš Kroupa

<http://staff.utia.cas.cz/kroupa/>

Ústav teorie informace a automatizace  
AV ČR

2014

# Obsah

1. Úvod
2. Charakteristiky informace
3. Asymptotická rovnočetnost typických zpráv
4. Komprese zpráv a kódování
5. Informační kanály
6. Dodatek

# Část I

## Úvod

**Teorie informace** je matematická disciplína, která zkoumá

- ▶ možnosti komprese informace,
- ▶ metody rychlého a kvalitního přenosu informace.

**Teorie informace** je založena na **pravděpodobnostním modelu** zpráv a komunikace. Tato myšlenka umožnila **C. Shannonovi** v r. 1948 ukázat převratný fakt:

- ▶ zvyšování výkonu přenosového zařízení není jediná cesta k potlačení chyb při přenosu informace, neboť
- ▶ existuje určitá přenosová rychlost, od níž lze přenášet s libovolně malou pravděpodobností chyby.

## Počátky teorie informace

*Suppose we have a set of possible events whose probabilities of occurrence are  $p_1, p_2, \dots, p_n$ . These probabilities are known but that is all we know concerning which event will occur. Can we find a measure of how much “choice” is involved in the selection of the event or how uncertain we are of the outcome?*



C. E. Shannon.

A mathematical theory of communication.

*Bell System Tech. J.*, 27:379–423, 623–656,  
1948.



C.E. Shannon (1916–2001)

## Model komunikace podle Shannona

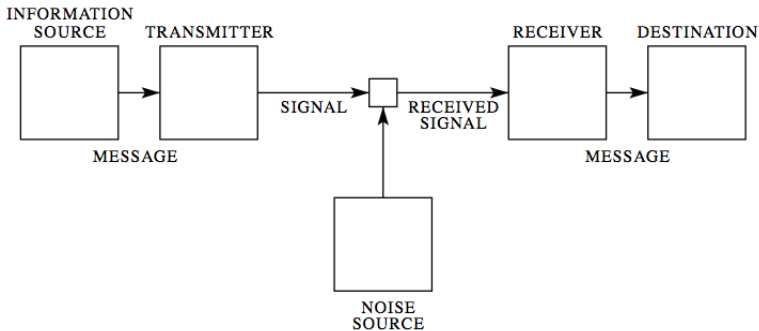


Fig. 1 — Schematic diagram of a general communication system.

# Hlavní úlohy teorie informace

- ▶ **komprese** - efektivní reprezentace dat
- ▶ **komunikace** - spolehlivý přenos dat
- ▶ **kryptografie** - zabezpečení dat před nežádoucím přístupem

Rozlišujeme 2 hlavní třídy **kódování**:

- 1 zdrojové - při kompresi informačního zdroje odstraňujeme redundantní informaci
- 2 kanálové - větší redundance informace naopak zaručuje menší chybovost při přenosu

## Co je informační zdroj?

**Informační zdroj** je pravděpodobnostní model zařízení, které produkuje zprávy složené ze znaků konečné abecedy  $\Lambda$ . Podle délky zpráv rozeznáváme 3 základní typy informačních zdrojů:

- 1 **náhodná veličina**  $X$  s výběrovým prostorem  $\Lambda$
- 2 **náhodný vektor**  $(X_1, \dots, X_n)$  s výběrovým prostorem  $\Lambda^n$
- 3 **náhodný proces**  $(X_n)_{n \in \mathbb{N}}$  s výběrovým prostorem  $\Lambda^{\mathbb{N}}$

Tyto informační zdroje generují zprávy dlouhé

- ▶ 1 znak
- ▶  $n$  znaků
- ▶ (teoreticky) nekonečný počet znaků

## Dva významy slova “bit”

- 1 symbol z množiny  $\{0, 1\}$
  - 2 jednotka informace při dvojkovém základu logaritmu
- ▶ podle Shannona zavedl termín “bit” známý statistik John W. Tukey již v roce 1947
  - ▶ díky zvolené jednotce informace používáme dvojkový logaritmus a značení

$$\log := \log_2$$



## Příklady informačních zdrojů

### Příklad

$\Lambda = \{A, \dots, Z, \_ \}$ .

Pravděpodobnosti  $p_X(x)$  **jednotlivých písmen**  $x \in \Lambda$  můžeme odhadnout např. pomocí dostatečně velkého souboru textů nad anglickou abecedou  $\Lambda$ . Viz tato **studie**.

Tento model však umožňuje popsat pouze informační zdroje, v němž jsou výskyty jednotlivých znaků  $x_1, \dots, x_n \in \Lambda$  ve slově  $x_1 \dots x_n$  **nezávislé**:

$$p_{X_1 \dots X_n}(x_1, \dots, x_n) = \prod_{i=1}^n p_X(x_i).$$

## Příklady informačních zdrojů (pokr.)

### Příklad

$$\Lambda = \{A, \dots, Z, \_ \}.$$

**Markovův řetězec**  $(X_n)_{n \in \mathbb{N}}$  popisuje slova nad abecedou  $\Lambda$ , kde pravděpodobnost **dvojic písmen** odpovídá typickému anglickému textu. Viz tato **studie**. Z toho lze odvodit pravděpodobnosti přechodu, např. platí

$$p_{TH} > p_{TO}, \quad p_{IN} > p_{IT}.$$

Shannon uvádí tento příklad realizace:

ON IE ANTSOUTINYS ARE T INCTORE ST BE S DEAMY ACHIN D  
ILONASIVE TUCOOWE AT TEASONARE FUSO TIZIN ANDY TOBE  
SEACE CTISBE

## O čem to bude: komprese

Do telefonu si chceme uložit zkratky v binární abecedě  $\{0, 1\}$  pro každé z 8 čísel přátel, kterým voláme s těmito pravděpodobnostmi:

$$(2^{-1}, 2^{-2}, 2^{-3}, 2^{-4}, 2^{-6}, 2^{-6}, 2^{-6}, 2^{-6})$$

### Řešení

- ▶ je možno použít kód mající **3 bity** pro každého
- ▶ lepší je však využít uvedené pravděpodobnosti ke konstrukci kódu kratší **střední délky**

## Kompresa: řešení

### Řešení


- ▶ střední délka kódu s 3-bitovými délkami kódových slov je **3**
- ▶ uvažujme následující kód s délkami slov  $\ell_i = -\log p_i$

1	2	3	4	5	6	7	8
$2^{-1}$	$2^{-2}$	$2^{-3}$	$2^{-4}$	$2^{-6}$	$2^{-6}$	$2^{-6}$	$2^{-6}$
0	10	110	1110	111100	111110	111101	111111

- ▶ střední délka tohoto kódu je **2**
- ▶ později uvidíme, že kód kratší střední délky nelze nalézt!

## O čem to bude: komunikace

Chceme přenést bitové slovo **informačním kanálem**, v němž dochází vlivem šumu k záměně 1 bitu s pravděpodobností  $p < 1/2$ . Lze vhodným kódováním docílit menší pravděpodobnosti chyby  $\lambda_x$  záměny bitu  $x$ ?



## Komunikace: možné řešení

- 1 **Kódování vstupu**: každý bit  $x$  zopakuj  $(2n + 1)$ -krát
- 2 **Dekódování výstupu**: podle většiny výstupních bitů  $y_1 \dots y_{2n+1}$

To umožňuje opravit nejvýše  $n$  chyb, ovšem značně neefektivně:

- ▶ počet chyb  $E$  má rozdělení  $\text{Bi}(2n + 1, p)$ , tedy

$$\lambda_x = P[E > n] = \sum_{i=n+1}^{2n+1} \binom{2n+1}{i} p^i (1-p)^{2n+1-i}$$

- ▶ při  $n = 1$  to dává chybu  $\lambda_x = 3p^2 - 2p^3 < p$
- ▶ když  $n \rightarrow \infty$ , potom  $\lambda_x \rightarrow 0$
- ▶ ale  $R \rightarrow 0$ , kde  $R := \frac{1}{2n+1}$  měří rychlost komunikace!

# Aplikace teorie informace

## Kompresní algoritmy

- ▶ Huffmanovo kódování, aritmetické kódování, LZW
- ▶ JPEG, MP3, TIFF

## Kódy pro detekci a opravu chyb

- ▶ Reed-Solomonovy kódy (CD, DVD, DVB)
- ▶ turbo kódy (3G)

## Z pohledu studenta FEL

Pochopím a naučím se používat

- 1 **informační míry**, které jsou důležité i mimo teorii informace (AI, strojové učení)
- 2 **Huffmanovo kódování**, které provádí optimální kompresi bezpaměťových zdrojů dat
- 3 **model diskrétního kom. kanálu**, který je základem pro moderní teorii kódování

Více v předmětu **Teorie informace a kódování** v LS 2014!



# Část II

## Charakteristiky informace

- Entropie
- Vzájemná informace
- Rychlost entropie

## Hartleyho míra informace

Kolika bity vyjádříme  $n$  znaků?

Definice (Hartley, 1928)

Hartleyho míra informace  $I$  je funkce

$$I(n) = \log n, \quad n \in \mathbb{N}.$$

- ▶ platí-li  $|\Lambda| = 2^k$  pro nějaké  $k \geq 1$ , potom  $I(2^k) = k$  udává počet bitů, kterými lze zakódovat znak z  $\Lambda$
- ▶ pokud neexistuje  $k \geq 1$  takové, že  $|\Lambda| = 2^k$ , potom musíme kódovat znaky z  $\Lambda$  pomocí  $\lceil I(|\Lambda|) \rceil$  bitů

## Axiomy Hartleyho míry

### Věta (Rényi)

Hartleyho míra informace je jediná funkce  $I: \mathbb{N} \rightarrow \mathbb{R}$  následujících vlastností:

- 1  $I(m \cdot n) = I(m) + I(n)$ , pro každé  $m, n \in \mathbb{N}$
- 2  $I$  je rostoucí
- 3  $I(2) = 1$

### Intepretace

- ▶ k vyjádření prvku z  $2^{k+\ell}$ -prvkové množiny stačí zřetězit původní bitová slova délek  $k$  a  $\ell$
- ▶ počet bitů roste s počtem kódovaných znaků
- ▶ informaci měříme v bitech

## Entropie: motivace

Pro popis každého z  $n$  výsledků potřebujeme informaci  $I(n)$ .

- ▶  $\Lambda = \{1, 2\}$ ,  $p_1 = p_2 = \frac{1}{2}$ . Pak  $I(2) = \log 2 = \log \frac{1}{p_i} = 1$

Ovšem výsledky  $i \in \Lambda$  mohou mít různou pravděpodobnost  $p_i$ !

- ▶ každý výsledek  $i \in \Lambda$  přinese informaci  $\log \frac{1}{p_i}$  bitů
- ▶ **průměrnou informaci**, kterou nám přinese znalost nějakého výsledku náhodného pokusu, tedy dostaneme jako

$$\sum_{i \in \Lambda} p_i \log \frac{1}{p_i} = - \sum_{i \in \Lambda} p_i \log p_i$$


# Entropie

## Definice (Shannon)


Nechť  $X$  je náhodná veličina s hodnotami v  $\Lambda$  a pravděpodobnostní funkcí  $p_X$ . **Entropie** náhodné veličiny  $X$  je

$$H(X) = - \sum_{x \in \Lambda} p_X(x) \log p_X(x),$$

kde užíváme konvenci  $0 \log 0 = 0$ .



Funkce  $-\log p$  pro  $p \in (0, 1)$



Funkce  $-p \log p$  pro  $p \in (0, 1)$

## Entropie jako funkce

Nechť  $|\Lambda| = n$ . Entropii lze chápat jako reálnou funkci


$$H: \Delta_n \rightarrow \mathbb{R},$$

kde  $\Delta_n$  je **pravděpodobnostní  $n$ -simplex**, což je množina všech pravděpodobnostních funkcí na  $\Lambda$ :


$$\Delta_n = \left\{ p \in \mathbb{R}^n \mid p_i \geq 0, \sum_{i=1}^n p_i = 1 \right\}.$$



## Entropie jako funkce (pokr.)



Entropie na  $\Delta_2$



Entropie na  $\Delta_3$

## Axiomy entropie

### Věta

Entropie  $H(p_1, \dots, p_n)$  je jediná funkce  $\Delta_n \rightarrow \langle 0, \infty \rangle$  následujících vlastností:

- 1  $H$  nezávisí na pořadí argumentů  $p_1, \dots, p_n$
- 2 Funkce  $(p, 1 - p) \in \Delta_2 \mapsto H(p, 1 - p)$  je spojitá
- 3  $H(1/2, 1/2) = 1$
- 4  $H(p_1, \dots, p_n) = H(p_1 + p_2, p_3, \dots, p_n) + (p_1 + p_2)H\left(\frac{p_1}{p_1 + p_2}, \frac{p_2}{p_1 + p_2}\right)$

První tři axiomy mají velmi přirozenou interpretaci. A co čtvrtý?



## Interpretace 4. axiomu

### Příklad

Úkolem je uhodnout soupeřem náhodně zvolené číslo z množiny  $\{1, \dots, 5\}$ . Lze použít např. jednu z těchto strategií:

- ▶ náhodně vybereme číslo z množiny  $\{1, \dots, 5\}$ , pokus je tak popsán rovnoměrným rozdělením  $p_i = \frac{1}{5}, i = 1, \dots, 5$
- ▶ nejprve volíme prvek množiny  $\{\{1, 2\}, 3, 4, 5\}$  podle rozdělení  $(\frac{2}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5})$ , potom případně náhodně volíme číslo z  $\{1, 2\}$

Dostaneme vždy to samé:

- ▶  $H(\frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}) = I(5) = \log 5$
- ▶  $H(\frac{2}{5}, \frac{1}{5}, \frac{1}{5}, \frac{1}{5}) + \frac{2}{5}H(\frac{1}{2}, \frac{1}{2}) = \log 5$

## Entropie o základu $d$

Informaci lze měřit i v jiných jednotkách než bitech ( $d = 2$ ).

### Věta

Nechť  $d > 0$  a  $H_d(X) = - \sum_{x \in \Lambda} p_X(x) \log_d p_X(x)$ . Pak

$$H_d(X) = \log_d 2 \cdot H(X).$$

### Důkaz.

Pro každé  $t > 0$  platí rovnost  $t = 2^{\log t}$ . Jejím zlogaritmováním získáme vztah

$$\log_d t = \log_d 2 \cdot \log t,$$

ze kterého tvrzení plyne.

## Minimální entropie

Výsledek pokusu v **Diracově rozdělení** nepřinese informaci.

### Věta

Platí  $H(X) \geq 0$ . Rovnost  $H(X) = 0$  nastane právě tehdy, když je rozdělení  $X$  Diracovo.

### Důkaz.

- ▶ nerovnost plyne přímo z definice entropie
- ▶ pokud má  $X$  Diracovo rozdělení, potom  $H(X) = \log 1 = 0$
- ▶ obráceně, z existence  $x \in \Lambda$  s vlastností  $1 > p_X(x) > 0$  plyne  $-p_X(x) \log p_X(x) > 0$ , a tudíž  $H(X) > 0$

## Maximální entropie

Výsledek popsany **rovnoměrným rozdělením** přináší maximální možnou informaci.

### Věta

Platí  $H(X) \leq \log |\Lambda|$ . Rovnost  $H(X) = \log |\Lambda|$  nastane právě tehdy, když má  $X$  rovnoměrné rozdělení.

### Důkaz.

Využijeme této nerovnosti platné pro každé  $t > 0$ :

$$\log t \leq (t - 1) \log e,$$

kde rovnost nastává právě tehdy, když  $t = 1$ .

## Sdružená a podmíněná entropie

### Definice

Nechť  $(X, Y)$  je náhodný vektor s hodnotami v  $\Lambda \times \Omega$ . **Sdružená entropie**  $(X, Y)$  je

$$H(X, Y) = - \sum_{(x,y) \in \Lambda \times \Omega} p_{XY}(x, y) \log p_{XY}(x, y).$$

Pro dané  $x \in \Lambda$ ,  $p_X(x) > 0$  je **podmíněná entropie** dána jako

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

a **střední podmíněná entropie** je  $H(Y | X) = \sum_{x \in \Lambda} p_X(x) H(Y | X = x)$ ,

kde  $H(Y | X = x)$  definujeme libovolně, pokud  $p_X(x) = 0$ .

## Řetězcové pravidlo

### Věta

Platí  $H(X, Y) = H(X) + H(Y | X)$ .

### Důkaz.

Jelikož  $p_{XY}(x, y) = p_X(x)p_{Y|X}(y|x)$ , dostaneme

$$\begin{aligned} H(X, Y) &= - \sum_{(x,y) \in \Lambda \times \Omega} p_{XY}(x, y) \log p_X(x)p_{Y|X}(y | x) \\ &= - \sum_{(x,y) \in \Lambda \times \Omega} (p_{XY}(x, y) \log p_X(x) + p_{XY}(x, y) \log p_{Y|X}(y | x)) \\ &= - \sum_{x \in \Lambda} p_X(x) \log p_X(x) + \sum_{x \in \Lambda} H(Y | X = x) p_X(x). \end{aligned}$$

## Interpretace řetězcového pravidla

Nechť  $X$  a  $Y$  popisují souřadnice pokladu na čtvercové síti.

- ▶  $H(X, Y)$  udává **průměrnou informaci** o pozici pokladu
  - ▶ taková informace se k nám ovšem může dostat ve **dvou kolech**:
- 1 dozvíme se  $X$ -ovou souřadnici,
  - 2 po odhalení  $X$  se dozvíme  $Y$ -ovou souřadnici.

Vztah je symetrický,

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

a lze ho snadno zobecnit pro více veličin:

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

## Entropie nezávislých veličin

### Věta

Jsou-li  $X, Y$  nezávislé, pak

$$H(Y|X) = H(Y) \quad \text{a} \quad H(X, Y) = H(X) + H(Y).$$

### Důkaz.

Důsledek řetězcového pravidla, vztahu

$$p_{Y|X}(y|x) = p_Y(y)$$

pro nezávislé veličiny  $X, Y$  a  $H(Y|X = x) = H(Y)$ .



- Entropie
- **Vzájemná informace**
- Rychlost entropie

## Vzájemná informace

Jak závisí obdržená zpráva  $Y$  na zasláné zprávě  $X$ ?

### Definice

Nechť  $(X, Y)$  je náhodný vektor s hodnotami v  $\Lambda \times \Omega$ . **Vzájemná informace**  $I(X; Y)$  je definována jako

$$I(X; Y) = \sum_{(x,y) \in \Lambda \times \Omega} p_{XY}(x, y) \log \frac{p_{XY}(x, y)}{p_X(x) \cdot p_Y(y)}.$$

### Interpretace

$I(X; Y)$  měří odlišnost sdruženého rozdělení náhodného vektoru  $(X, Y)$  od součinnového rozdělení jeho marginálů, kterým by se vektor  $(X, Y)$  řídil, pokud by  $X$  a  $Y$  byly nezávislé.

## $I(X; Y)$ je míra zachování informace

### Věta

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

### Důkaz.

Protože  $p_{XY} = p_{X|Y}p_Y$ , dostaneme

$$\begin{aligned} I(X; Y) &= \sum_{(x,y) \in \Lambda \times \Omega} p_{XY}(x, y) \log \frac{p_{X|Y}(x | y)}{p_X(x)} \\ &= \sum_{(x,y) \in \Lambda \times \Omega} (-p_{XY}(x, y) \log p_X(x) + p_{XY}(x, y) \log p_{X|Y}(x | y)) \\ &= - \sum_{x \in \Lambda} p_X(x) \log p_X(x) - \sum_{y \in \Omega} H(X | Y = y) p_Y(y). \end{aligned}$$

## Vlastnosti vzájemné informace

### Věta

- 1  $I(X; Y) = I(Y; X)$
- 2  $0 \leq I(X; Y) \leq H(X)$
- 3  $I(X; Y) = 0 \Leftrightarrow X$  a  $Y$  jsou nezávislé
- 4  $I(X; Y) = H(X) \Leftrightarrow$  existuje  $\delta : \Omega \rightarrow \Lambda$  splňující  $p_{X|Y}(\delta(y) | y) = 1$  pro každé  $y \in \Omega$ ,  $p_Y(y) > 0$

### Důkaz.

1. a 4. vlastnost plynou ihned z definic. Pro 2. a 3. využijeme opět nerovnosti platné pro každé  $t > 0$ :

$$\log t \leq (t - 1) \log e,$$

kde rovnost nastává právě tehdy, když  $t = 1$ .

## Příklad: bitová inverze

### Příklad (maximum vzájemné informace)

$$X \sim \text{Bi}(1, 1/2)$$

$$Y = X \oplus 1$$

Z toho plyne

$$p_{Y|X}(1|0) = p_{Y|X}(0|1) = 1$$

a tedy


$$p_{X|Y}(1|0) = p_{X|Y}(0|1) = 1.$$

Stačí definovat

$$\delta(y) := y \oplus 1$$

a vidíme, že  $I(X; Y) = H(X) = \log 2 = 1$ .

## Schéma



Význam informačních identit lze dobře ilustrovat na modelu informačního kanálu.

- Entropie
- Vzájemná informace
- Rychlost entropie

## Motivace

Jak popíšeme informaci obsaženou ve zdroji  $(X_n)_{n \in \mathbb{N}}$ ?

- ▶ zdroj  $(X_1, \dots, X_n)$  má sdruženou entropii  $H(X_1, \dots, X_n)$
- ▶ ovšem pro  $n \rightarrow \infty$  není entropie zdroje  $(X_1, \dots, X_n)$  shora omezena, neboť pro  $|\Lambda| \geq 2$  platí

$$H(X_1, \dots, X_n) \leq \log |\Lambda|^n \rightarrow \infty$$

### Řešení

Hledejme entropii na jeden znak zprávy!



## Bezpečný zdroj

### Definice

**Bezpečný zdroj** je informační zdroj  $(X_n)_{n \in \mathbb{N}}$  nad konečnou abecedou  $\Lambda$ , kde veličiny  $X_1, X_2, \dots$  jsou **nezávislé** a **stejně rozdělené**.

### Příklad: náhodné generování bitů

$X_n$  je náhodný bit a  $p_{X_n}(1) = p \in \langle 0, 1 \rangle$ , pro každé  $n \in \mathbb{N}$

### Příklad: náhodné generování textu


$X_n$  je písmeno z abecedy  $\Lambda = \{A, \dots, Z, \_ \}$ , pravděpodobnosti jednotlivých písmen jsou stejné pro každé  $n \in \mathbb{N}$

# Markovův řetězec

## Markovův řetězec $(X_n)_{n \in \mathbb{N}}$

stavový prostor  $\Lambda = \{1, 2\}$

$\alpha, \beta \in \langle 0, 1 \rangle$



Matice přechodu je  $\mathbf{P} = \begin{pmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{pmatrix}$  a počáteční rozdělení  $\mathbf{p}(0)$  udává pravděpodobnosti stavů 1 a 2 na začátku.

## Rychlost entropie

### Definice

Rychlost entropie zdroje  $(X_n)_{n \in \mathbb{N}}$  je

$$H((X_n)_{n \in \mathbb{N}}) = \lim_{n \rightarrow \infty} \frac{H(X_1, \dots, X_n)}{n},$$

pokud tato limita existuje.

### Příklad

Je-li zdroj zpráv  $X_1, X_2, \dots$  bezpaměťový, potom

$$H((X_n)_{n \in \mathbb{N}}) = H(X_1).$$

## Mezní podmíněná entropie

### Definice

Mezní podmíněná entropie  $\tilde{H}((X_n)_{n \in \mathbb{N}})$  zdroje  $(X_n)_{n \in \mathbb{N}}$  je limita posloupnosti

$$H(X_1), H(X_2|X_1), H(X_3|X_2, X_1), \dots$$

pokud tato limita existuje.

Dostáváme tak 2 pojmy:

- ▶  $H((X_n)_{n \in \mathbb{N}})$  je entropie na znak vyslané zprávy
- ▶  $\tilde{H}((X_n)_{n \in \mathbb{N}})$  je entropie znaku při znalosti předchozích znaků

Oba pojmy splývají pro **stacionární** informační zdroje.

## Stacionární informační zdroj

### Definice

Zdroj  $(X_n)_{n \in \mathbb{N}}$  je **stacionární**, pokud platí

$$P[X_1 = x_1, \dots, X_n = x_n] = P[X_{1+\ell} = x_1, \dots, X_{n+\ell} = x_n]$$

pro každé  $n \in \mathbb{N}$ , každý posun  $\ell$  a každé  $x_1, \dots, x_n \in \Lambda$ .

### Příklad

Bezpečný zdroj

### Zajímavější příklad

Markovův řetězec s maticí přechodu  $\mathbf{P}$  a počátečním rozdělením  $\mathbf{p}(0)$ , které je **stacionární**:  $\mathbf{p}(0) = \mathbf{p}(0)\mathbf{P}$ .

## Stacionarita a mezní podmíněná entropie

### Věta

Je-li zdroj  $(X_n)_{n \in \mathbb{N}}$  **stacionární**, potom je posloupnost  $H(X_2|X_1), H(X_3|X_2, X_1), \dots$  **nerostoucí** a její limita  $\tilde{H}((X_n)_{n \in \mathbb{N}})$  existuje.

### Důkaz.

Pro  $n \geq 2$  platí

$$\begin{aligned} H(X_{n+1}|X_1, X_2, \dots, X_n) &\leq H(X_{n+1}|X_2, \dots, X_n) \\ &= H(X_n|X_1, \dots, X_{n-1}) \end{aligned}$$

kde  $\leq$  plyne z faktu, že podmiňování snižuje entropii a  $=$  je důsledkem stacionarity. Dostaneme tak nerostoucí posloupnost nezáporných reálných čísel, jejíž limita  $\tilde{H}((X_n)_{n \in \mathbb{N}})$  existuje.

## Stacionarita a rychlost entropie

### Věta

Je-li zdroj  $(X_n)_{n \in \mathbb{N}}$  **stacionární**, potom rychlost entropie  $H((X_n)_{n \in \mathbb{N}})$  existuje a platí

$$H((X_n)_{n \in \mathbb{N}}) = \tilde{H}((X_n)_{n \in \mathbb{N}}).$$

### Důkaz.

Podle **řetězcového pravidla** pro sdruženou entropii platí

$$\frac{H(X_1, \dots, X_n)}{n} = \frac{\sum_{i=2}^n H(X_i | X_1, \dots, X_{i-1}) + H(X_1)}{n}.$$

Vpravo je průměr posloupnosti, která konverguje k  $\tilde{H}((X_n)_{n \in \mathbb{N}})$ .  
Tudíž musí konvergovat k  $\tilde{H}((X_n)_{n \in \mathbb{N}})$  i posloupnost průměrů.


## Markovský zdroj

### Definice

**Markovský zdroj** informace je stacionární Markovův řetězec.

### Příklad (pokr.)

Je-li  $\alpha + \beta = 0$ , pak je libovolné počáteční rozdělení  $\mathbf{p}(0)$  stacionární. Předpokládejme  $\alpha + \beta > 0$ .



Existuje jediné stacionární rozdělení  $\left( \frac{\beta}{\alpha + \beta}, \frac{\alpha}{\alpha + \beta} \right)$  a tak klademe  $\mathbf{p}(0) = \left( \frac{\beta}{\alpha + \beta}, \frac{\alpha}{\alpha + \beta} \right)$ .



## Rychlost entropie markovského zdroje

### Věta

Pokud je zdroj informace  $(X_n)_{n \in \mathbb{N}}$  markovský, potom

$$H((X_n)_{n \in \mathbb{N}}) = H(X_2|X_1).$$


### Důkaz.

$$\begin{aligned} H((X_n)_{n \in \mathbb{N}}) &= \tilde{H}((X_n)_{n \in \mathbb{N}}) = \lim_{n \rightarrow \infty} H(X_{n+1}|X_n, \dots, X_1) \\ &= \lim_{n \rightarrow \infty} H(X_{n+1}|X_n) = H(X_2|X_1). \end{aligned}$$

## Příklad markovského zdroje

### Příklad (pokr.)

Je-li  $\alpha + \beta = 0$ , pak  $H((X_n)_{n \in \mathbb{N}}) = 0$ . Nechť  $\alpha + \beta > 0$ .




Počáteční rozdělení  $\mathbf{p}(0) = \left( \frac{\beta}{\alpha + \beta}, \frac{\alpha}{\alpha + \beta} \right)$ . Rychlost entropie je

$$H((X_n)_{n \in \mathbb{N}}) = H(X_2|X_1) = \frac{\beta}{\alpha + \beta} H(\alpha, 1 - \alpha) + \frac{\alpha}{\alpha + \beta} H(\beta, 1 - \beta).$$

## Příklad markovského zdroje: $\alpha = \beta = \frac{1}{2}$

Příklad:  $H((X_n)_{n \in \mathbb{N}}) = 1$



Počáteční rozdělání  $\mathbf{p}(0) = \left(\frac{1}{2}, \frac{1}{2}\right)$


Jde o **bezpaměťový** zdroj informace a ve zprávě  $x_1 x_2 \dots$  má každý řetězec

$$x_k x_{k+1} \dots x_{k+\ell}$$

stejnou pravděpodobnost  $2^{-\ell-1}$ .

## Příklad markovského zdroje: $\alpha = 0, \beta > 0$

Příklad:  $H((X_n)_{n \in \mathbb{N}}) = 0$



Počáteční rozdělení  $\mathbf{p}(0) = (1, 0)$


Jde o **deterministický** zdroj informace: zpráva

111...

vznikne s pravděpodobností 1.

## Příklad markovského zdroje: $\beta = 0$ , $\alpha > 0$

Příklad:  $H((X_n)_{n \in \mathbb{N}}) = 0$



Počáteční rozdělení  $\mathbf{p}(0) = (0, 1)$


Jde o **deterministický** zdroj informace: zpráva

222...

vznikne s pravděpodobností 1.

## Příklad markovského zdroje: $\alpha = \beta = 1$

Příklad:  $H((X_n)_{n \in \mathbb{N}}) = 0$



Počáteční rozdělení  $\mathbf{p}(0) = (\frac{1}{2}, \frac{1}{2})$ , oba stavy mají periodu 2

Jde o **nedeterministický** zdroj informace, ale každá zpráva je jednoznačně určena prvním znakem: zprávy

1212...    a    2121...

mají obě pravděpodobnost  $1/2$ .

# Část III

## Asymptotická rovnočetnost typických zpráv

- Prolog k bezztrátové kompresi
- Typické zprávy

## Motivace

### Příklad

**Bez paměťový** zdroj generuje 100 bitů s pravděpodobnostmi  $p(0) = 0.995$ ,  $p(1) = 0.005$ . Máme zakódovat každou zprávu  $x_1 \dots x_{100}$ , která obsahuje nejvýše tři bity 1.

- ▶ počet **typických zpráv** (nejvýše tři bity 1) je

$$\binom{100}{0} + \binom{100}{1} + \binom{100}{2} + \binom{100}{3} = 166\,751$$

- ▶ tudíž stačí kódová slova délky  $\lceil \log 166\,751 \rceil = 18$
- ▶ tak zakódujeme zprávy z množiny, jejíž pravděpodobnost je

$$\sum_{i=0}^3 \binom{100}{i} 0.005^i 0.995^{100-i} = 0.99833$$



## Motivace (pokr.)

### Příklad (pokr.)

- ▶ tím ovšem dosáhneme jen **ztrátové komprese**
- ▶ **atypické zprávy** (více než tři 1) kódujeme pomocí původních

100 bitů

- ▶ přidáním počátečního **příznakového** bitu odlišíme kódová slova pro typické a atypické zprávy
- ▶ **střední délka** kódového slova je tak

$$0.99833 \cdot 19 + 0.00167 \cdot 101 = 19.13694$$

## Motivace (pokr.)

Jak poznáme **typické zprávy**?

- ▶ pravděpodobnost typické zprávy  $(\underbrace{0, \dots, 0}_{100 \times})$  je

$$p_{100} = 0.995^{100} = 0.60577$$

- ▶ povšimněme si, že existuje  $\varepsilon > 0$  takové, že

$$p_{100} \approx 2^{-100(H(0.005, 0.995) - \varepsilon)}$$

- ▶ pravděpodobnost každé typické zprávy je tedy přibližně

$$2^{-100H(0.005, 0.995)}$$

## Obecná úloha

Uvažujme tyto informační zdroje:

- ▶  $X$  s pravděpodobnostní funkcí  $p$  na množině  $\mathcal{X}$
- ▶  $(X_1, \dots, X_n)$ ,  $n \in \mathbb{N}$ , popsány pomocí sdružené pravděpodobnostní funkce

$$p_n(\mathbf{x}^n) = \prod_{i=1}^n p(x_i), \quad \mathbf{x}^n = (x_1, \dots, x_n) \in \mathcal{X}^n$$

na množině  $\mathcal{X}^n$

### Interpretace

- ▶ zdroj  $(X_1, \dots, X_n)$  je **bezpaměťový**
- ▶ pravděpodobnost výskytu znaku  $x \in \mathcal{X}$  je vždy  $p(x)$

## Obecná úloha (pokr.)

Pro dlouhé zprávy řešme tuto úlohu **bezztrátové komprese**:

- ▶ hledáme **binární blokový kód** pro  $(X_1, \dots, X_n)$ : kódujeme celé bloky zpráv  $x_1 \dots x_n$ , nikoli jednotlivé znaky  $x_i$ !
- ▶ tento kód musí umožňovat jednoznačnou rekonstrukci původních zpráv z  $\mathcal{X}^n$
- ▶ cílem je minimalizovat střední délku tohoto kódu

**AEP** (Asymptotic Equipartition Property)

- ▶ využití slabého zákona velkých čísel v teorii informace
- ▶ efektivní komprese zpráv z **typické množiny**

# Typičnost

## Definice

Nechť  $\varepsilon > 0$ . **Množina  $\varepsilon$ -typických zpráv** zdroje  $(X_1, \dots, X_n)$  je

$$A_\varepsilon^{(n)} = \left\{ \mathbf{x}^n \in \mathcal{X}^n \mid 2^{-n(H(X)+\varepsilon)} \leq p_n(\mathbf{x}^n) \leq 2^{-n(H(X)-\varepsilon)} \right\}.$$

**Ekvivalentně:** zpráva  $\mathbf{x}^n \in \mathcal{X}^n$  je  $\varepsilon$ -typická  $\Leftrightarrow$

$$H(X) - \varepsilon \leq -\frac{1}{n} \log p_n(\mathbf{x}^n) \leq H(X) + \varepsilon.$$

Typické zprávy umožňují “dobrý” odhad entropie  $H(X)$ .

## AEP

## Věta

Nechť  $\varepsilon > 0$ .

- ① Pro každé  $n \in \mathbb{N}$  platí

$$|A_\varepsilon^{(n)}| \leq 2^{n(H(X)+\varepsilon)}.$$

- ② Existuje  $n_\varepsilon$  takové, že

$$P(A_\varepsilon^{(n)}) > 1 - \varepsilon, \quad \text{pro } n > n_\varepsilon.$$

- ③  $|A_\varepsilon^{(n)}| \geq (1 - \varepsilon)2^{n(H(X)-\varepsilon)}$ , pro  $n > n_\varepsilon$ .

## Důkaz AEP

## Důkaz.

**První tvrzení:**

$$\begin{aligned}
 1 &= \sum_{\mathbf{x}^n \in \mathcal{X}^n} p_n(\mathbf{x}^n) \geq \sum_{\mathbf{x}^n \in A_\varepsilon^{(n)}} p_n(\mathbf{x}^n) \\
 &\geq \sum_{\mathbf{x}^n \in A_\varepsilon^{(n)}} 2^{-n(H(X)+\varepsilon)} = 2^{-n(H(X)+\varepsilon)} |A_\varepsilon^{(n)}|.
 \end{aligned}$$

**Druhé tvrzení:** položme  $Y_i = -\log p_{X_i}(x_i)$ . Pak  $E(Y_i) = H(X)$  a

$$P(A_\varepsilon^{(n)}) = P[|\bar{Y}_n - H(X)| \leq \varepsilon] = P[|\bar{Y}_n - E(Y_i)| \leq \varepsilon].$$

Nerovnost tak plyne přímo ze slabého ZVČ.

## Důkaz AEP (pokr.)

## Důkaz.

**Třetí tvrzení:** pro  $n > n_\varepsilon$  platí

$$\begin{aligned} 1 - \varepsilon < P(A_\varepsilon^{(n)}) &= \sum_{\mathbf{x}^n \in A_\varepsilon^{(n)}} p_n(\mathbf{x}^n) \\ &\leq \sum_{\mathbf{x}^n \in A_\varepsilon^{(n)}} 2^{-n(H(X) - \varepsilon)} = 2^{-n(H(X) - \varepsilon)} |A_\varepsilon^{(n)}|. \end{aligned}$$



## Využití AEP

- 1 Horní odhad velikosti  $A_\epsilon^{(n)}$
- 2 Množina typických zpráv má pravděpodobnost 1 pro  $n \rightarrow \infty$
- 3 Dolní odhad velikosti  $A_\epsilon^{(n)}$  (závislý na  $n > n_\epsilon$ )

### Kódování pomocí AEP

- ▶ přednostní pozornost budeme věnovat typickým zprávám
- ▶ takový přístup ale bude stačit k výhodné kompresi všech zpráv!

## Kódování pomocí AEP

- 1 každou zprávu z  $A_\varepsilon^{(n)}$  lze zakódovat pomocí nejvýše  $n(H(X) + \varepsilon) + 1$  bitů, přidáním počátečního **příznakového bitu 0** je horní mez  $n(H(X) + \varepsilon) + 2$  bitů
- 2 každou zprávu z  $\mathcal{X}^n \setminus A_\varepsilon^{(n)}$  zakódujeme pomocí nejvýše  $n \log |\mathcal{X}| + 2$  bitů

### Vlastnosti

- ▶ kód umožňuje dékodování **ihned** po obdržení kódového slova
- ▶ dosáhneme **efektivní komprese**: každé kódové slovo je v průměru vyjádřeno pomocí  $nH(X)$  bitů

## Efektivita kódování pomocí AEP

### Věta

Nechť  $\ell(X^n)$  značí délku kódového slova pro zprávu  $X^n$ . Pro každé  $\hat{\varepsilon} > 0$  platí

$$E\left(\frac{1}{n}\ell(X^n)\right) - H(X) < \hat{\varepsilon}, \quad \text{pro } n \rightarrow \infty.$$

- ▶ uvedená věta platí pro nezávislé a stejně rozdělené veličiny  $X_1, X_2, \dots$ , ale existuje zobecnění pro jisté stacionární zdroje
- ▶ střední délku kódového slova na jeden znak lze tak libovolně přiblížit k entropii původního zdroje

## Efektivita kódování pomocí AEP (pokr.)

### Důkaz.

Díky 2.tvrzení AEP platí pro  $n > n_0$  a  $\varepsilon > 0$ :

$$\begin{aligned}
 E\left(\frac{1}{n}\ell(X^n)\right) &= \frac{1}{n} \sum_{\mathbf{x}^n \in \mathcal{X}^n} p_n(\mathbf{x}^n)\ell(\mathbf{x}^n) \\
 &= \sum_{\mathbf{x}^n \in A_\varepsilon^{(n)}} p_n(\mathbf{x}^n) \left(H(X) + \varepsilon + \frac{2}{n}\right) + \sum_{\mathbf{x}^n \in \mathcal{X}^n \setminus A_\varepsilon^{(n)}} p_n(\mathbf{x}^n) \left(\log |\mathcal{X}| + \frac{2}{n}\right) \\
 &= \left(H(X) + \varepsilon + \frac{2}{n}\right) P(A_\varepsilon^{(n)}) + \left(\log |\mathcal{X}| + \frac{2}{n}\right) \left(1 - P(A_\varepsilon^{(n)})\right) \\
 &< H(X) + \underbrace{\varepsilon + \frac{2}{n} + \varepsilon \left(\log |\mathcal{X}| + \frac{2}{n}\right)}_{\hat{\varepsilon}}
 \end{aligned}$$

## Ilustrace AEP

### Příklad

**Bez paměťový** zdroj generuje  $n = 25$  bitů s pravděpodobnostmi  $p(0) = 0.4$ ,  $p(1) = 0.6$ . Zřejmě  $H(X) \doteq 0.97$ . Pro  $\varepsilon = 0.1$  určíme

1  $A_\varepsilon^{(n)} = \{ \mathbf{x}^n \in \mathcal{X}^n \mid 0.96 \leq -\frac{1}{n} \log p_n(\mathbf{x}^n) \leq 0.98 \}$


2  $P(A_\varepsilon^{(n)})$

3  $|A_\varepsilon^{(n)}|$

Stačí vyhodnotit počet jednotkových bitů ve zprávě délky 25 bitů.

**Varování:** nejpravděpodobnější zpráva (samé 1) zde není typická!

## Ilustrace AEP (pokr.)

Pravděpodobnostní funkce  $Bi(25,0.6)$

## Ilustrace AEP (pokr.)

### Příklad (pokr.)

$$\textcircled{1} A_\varepsilon^{(n)} = \left\{ (x_1, \dots, x_{25}) \in \{0, 1\}^{25} \mid 11 \leq \sum_{i=1}^{25} x_i \leq 19 \right\}$$

$$\textcircled{2} P(A_\varepsilon^{(n)}) = \sum_{i=11}^{19} \binom{25}{i} 0.6^i 0.4^{25-i} = 0.93625 > 1 - \varepsilon = 0.9$$

$$\textcircled{3} |A_\varepsilon^{(n)}| = \sum_{i=11}^{19} \binom{25}{i} = 26\,366\,510 < |\mathcal{X}^n| = 2^{25} = 33\,554\,432$$

Odhad velikosti  $A_\varepsilon^{(n)}$  pomocí AEP je

$$3 \times 10^6 \approx (1 - \varepsilon) 2^{n(H(0.6, 0.4) - \varepsilon)} \leq |A_\varepsilon^{(n)}| \leq 2^{n(H(0.6, 0.4) + \varepsilon)} \approx 1.15 \times 10^8$$

# Část IV

## Komprese zpráv a kódování

- Prolog k bezztrátové kompresi
- Typické zprávy



## Kódování

### Definice

Nechť  $X$  je náhodná veličina s hodnotami v  $\Lambda$ . Nechť  $\mathcal{D}$  je konečná abeceda a  $\mathcal{D}^* = \bigcup_{n=1}^{\infty} \mathcal{D}^n$ . **Kód** pro  $X$  je zobrazení

$$C: \Lambda \rightarrow \mathcal{D}^*.$$

**Poznámka.** Pro  $\mathcal{D} = \{0, \dots, d-1\}$ ,  $d \geq 2$  hovoříme o  **$d$ -znakovém kódu**. Fyzikální principy přenosu a uchování dat vedou k využití zejména binárních kódů ( $d = 2$ ).

### Definice

**Střední délka** kódu  $C$  je  $L(C) = \sum_{x \in \Lambda} p_X(x) \cdot \ell(C(x))$ , kde  $\ell(C(x))$  značí délku kódového slova  $C(x)$ .

## Příklady kódů

### Příklad 1

Nechť  $p_X(i) = 1/3$ ,  $i = 1, 2, 3$ . Mějme tento binární kód:

$$C(1) = 0, C(2) = 10, C(3) = 11.$$

Zřejmě  $L(C) = 5/3 = 1.\bar{6}$ , přičemž  $H(X) = \log 3 \doteq 1.58$ .

### Příklad 2

Nechť  $p_X(i) = 2^{-i}$ ,  $i = 1, 2, 3$  a  $p_X(4) = 2^{-3}$ . Mějme tento binární kód:

$$C(1) = 0, C(2) = 10, C(3) = 110, C(4) = 111.$$

Zřejmě  $L(C) = H(X) = 1.75$ .

## Třídy kódů

### Definice

Kód  $C$  je

- ▶ **nesingulární**, pokud je  $C : \Lambda \rightarrow \mathcal{D}^*$  prosté zobrazení.
- ▶ **jednoznačně dekódovatelný**, pokud je jeho rozšíření  $C^*$  nesingulární, kde  $C^* : \Lambda^* \rightarrow \mathcal{D}^*$  je definováno pomocí

$$C^*(x_1 \dots x_n) = C(x_1) \dots C(x_n), \quad x_1 \dots x_n \in \Lambda^*.$$

- ▶ **instantní**, pokud žádné kódové slovo  $C(x)$  není počátečním úsekem kódového slova  $C(x')$  pro  $x, x' \in \Lambda$ ,  $x \neq x'$ .

## Třídy kódů (pokr.)

### Věta (Vztahy mezi kódy)

- 1 Každý **instantní kód** je **jednoznačně dekódovatelný**.
- 2 Každý **jednoznačně dekódovatelný kód** je **nesingulární**.

### Důkaz.

Druhé tvrzení plyne přímo z definice rozšíření  $C^*$ .

Nechť  $C$  není jednoznačně dekódovatelný. Potom  $C^*$  je singulární, tedy  $C^*(x_1 \dots x_m) = C^*(y_1 \dots y_n)$  pro nějaké dvě zprávy  $x_1 \dots x_m$ ,  $y_1 \dots y_n \in \Lambda^*$ , kde  $x_1 \dots x_m \neq y_1 \dots y_n$ . Kratší ze slov  $C(x_1)$ ,  $C(y_1)$  musí být tudíž prefixem delšího z nich.

## Třídy kódů (pokr.)

x	singulární	nesingulární	jedn. dekódovatelný	instantní
1	0	0	10	0
2	0	010	00	10
3	0	01	11	110
4	0	10	110	111

- ▶ pro **nesingulární kód** může být kódové slovo 010 dekódováno jako 2, 14 nebo 31
- ▶ kód ve 4. sloupci je **jednoznačně dekódovatelný**:
  - 1 pokud jsou první dva bity 00 nebo 10, lze je dekódovat
  - 2 pokud jsou první dva bity 11, potom
    - 2-1 je-li další bit 1, pak je první znak zprávy 3
    - 2-2 je-li délka řetězce nulových bitů za 11 **lichá**, pak je první znak zprávy 4
    - 2-3 je-li délka řetězce nulových bitů za 11 **sudá**, pak je první znak zprávy 3
  - 3 na další znaky kódového slova použijeme stejný postup

## Instantní kódy

- ▶ **neinstantní jednoznačně dekódovatelný kód** obecně umožňuje dekódování až po přečtení **celého** rozšířeného kódového slova  $C^*(x_1 \dots x_n)$
- ▶ **instantní kód** umožňuje dekódování **ihned** po obdržení kódového slova

### Příklad

$\Lambda = \{1, 2, 3, 4\}$ ,  $C(1) = 0$ ,  $C(2) = 10$ ,  $C(3) = 110$ ,  $C(4) = 111$

Potom rozšířené kódové slovo

01011111010

kóduje zprávu 12432, tedy  $C(12432) = 01011111010$ .

## Jak konstruovat kódy?

**Úloha.** Pro náhodnou veličinu  $X$  hledáme kód  $C$ , jehož střední délka  $L(C)$  je **minimální**

- ▶ ukážeme, že při hledání minima se lze omezit na množinu **instantních kódů**
- ▶ při konstrukci instantního kódu nelze přiřazovat krátká kódová slova všem znakům zdrojové abecedy  $\Lambda$ , neboť to by vedlo k porušení instantnosti
- ▶ existuje **dolní mez** pro střední délku libovolného kódu, kterou nelze překročit
- ▶ **Kraftova nerovnost** nám umožní nalézt délky slov instantního kódu

- Kódy
- **Kraftova nerovnost**
- Konstrukce kódů
- Huffmanovo kódování
- Zdroje s pamětí



## Kraftova nerovnost

### Věta (Kraft, 1949)

Délky slov  $\ell_1, \dots, \ell_m$  libovolného **instantního**  $d$ -znakového kódu splňují nerovnost

$$\sum_{i=1}^m d^{-\ell_i} \leq 1.$$

Obráceně, splňují-li  $\ell_1, \dots, \ell_m \in \mathbb{N}$  tuto nerovnost, potom existuje **instantní**  $d$ -znakový kód s délkami slov  $\ell_1, \dots, \ell_m$ .

### Příklad


Kraftova nerovnost je splněna pro exponenty  $\ell_1, \dots, \ell_m$  každé **dyadické pravděpodobnostní funkce**  $p$ , tedy  $p$  splňující  $p(x_i) = 2^{-\ell_i}$ ,  $i = 1, \dots, m$ . Např. pro  $m = 3$  jsou takové koeficienty pouze 1, 2, 2.

## Důkaz Kraftovy nerovnosti

Větu dokážeme pro binární kódy ( $d = 2$ ).

Důkaz.

K instantnímu kódu zkonstruujeme **kódovací strom**:



V kódovacím stromě jsou kódová slova vyznačena žlutě. Jelikož je kód **instantní**, žádné kódové slovo není následníkem jiného kódového slova.

## Důkaz Kraftovy nerovnosti (pokr.)

### Pokračování důkazu.

Nechť  $\ell$  je délka nejdelšího kódového slova. Potom:

- ▶ každé kódové slovo v úrovni  $\ell_i$  má právě  $2^{\ell-\ell_i}$  následníků v úrovni  $\ell$
- ▶ tyto množiny následníků jsou vzájemně disjunktní pro všechna kódová slova díky **instantnosti** kódu
- ▶ počet uzlů v úrovni  $\ell$  je  $2^\ell$ , tedy dostáváme

$$\sum_{i=1}^m 2^{\ell-\ell_i} \leq 2^\ell, \quad \text{což dává} \quad \sum_{i=1}^m 2^{-\ell_i} \leq 1$$

## Důkaz Kraftovy nerovnosti (pokr.)

### Pokračování důkazu.

Obráceně, necht' platí Kraftova nerovnost a  $\ell_1 \leq \dots \leq \ell_m$ . Mějme **binární strom** hloubky  $\ell_m$ :

- ▶ v úrovni  $\ell_1$  vyznačme libovolný uzel a vyjměme jeho následníky
- ▶ necht' byl vyznačen uzel v úrovni  $\ell_i$  ( $1 \leq i \leq m-1$ ) a jeho následníci vyjmuti
- ▶ nalezneme uzel v úrovni  $\ell_{i+1}$ ? Je zde

$$2^{\ell_{i+1}} - 2^{\ell_{i+1}-\ell_1} - \dots - 2^{\ell_{i+1}-\ell_i} \quad \text{uzlů}$$


- ▶ tento počet je  $\geq 1$  díky Kraftově nerovnosti (násobme  $2^{\ell_{i+1}}$ ):

$$\sum_{j=1}^{i+1} 2^{-\ell_j} \leq 1$$

## Ilustrace Kraftovy nerovnosti

### Příklad


Nalezneme binární kód s délkami kódových slov 1,2,3,3.



## Ilustrace Kraftovy nerovnosti

### Příklad


Nalezneme binární kód s délkami kódových slov 1,2,3,3.



## Ilustrace Kraftovy nerovnosti

### Příklad


Nalezneme binární kód s délkami kódových slov 1,2,3,3.



## Ilustrace Kraftovy nerovnosti

### Příklad

Nalezneme binární kód s délkami kódových slov 1,2,3,3.






## Ilustrace Kraftovy nerovnosti

### Příklad


Nalezneme binární kód s délkami kódových slov 1,2,3,3.



## Ilustrace Kraftovy nerovnosti

### Příklad

Nalezneme binární kód s délkami kódových slov 1,2,3,3.



## Kraftova nerovnost pro jednoznačně dekódovatelné kódy

### Věta (McMillan, 1956)

Délky slov  $\ell_1, \dots, \ell_m$  libovolného **jednoznačně dekódovatelného**  $d$ -znakového kódu splňují nerovnost

$$\sum_{i=1}^m d^{-\ell_i} \leq 1.$$

Obráceně, splňují-li  $\ell_1, \dots, \ell_m \in \mathbb{N}$  tuto nerovnost, potom existuje **jednoznačně dekódovatelný**  $d$ -znakový kód s délkami slov  $\ell_1, \dots, \ell_m$ .

- Kódy
- Kraftova nerovnost
- **Konstrukce kódů**
- Huffmanovo kódování
- Zdroje s pamětí

## Hledáme optimální kód

- ▶ Kraftova nerovnost umožňuje konstrukci instantního kódu pomocí zadaných délek kódových slov  $l_1, \dots, l_m$
- ▶ hledání kódu minimální střední délky tak lze formulovat jako **optimalizační úlohu**
- ▶ pro pravděpodobnostní funkci  $p_X$  na  $m$ -prvkové množině  $\Lambda$  a  $d \in \mathbb{N}$  tak hledáme minimum funkce

$$\bar{L}(l_1, \dots, l_m) = \sum_{i=1}^m p_X(x_i) l_i$$

na množině

$$\left\{ (l_1, \dots, l_m) \in \mathbb{N}^m \mid \sum_{i=1}^m d^{-l_i} \leq 1 \right\}$$

## Hledáme optimální kód (pokr.)

- ▶ zanedbejme celočíselné omezení kladené na  $(\ell_1, \dots, \ell_m)$  a předpokládejme v Kraftově nerovnosti rovnost:

$$\sum_{i=1}^m d^{-\ell_i} = 1$$

- ▶ potom snadno nalezneme vázaný extrém funkce  $\bar{L}$  metodou Lagrangeových multiplikátorů:

$$\ell'_i = -\log_d p(x_i), \quad i = 1, \dots, m$$

- ▶ v bodě  $(\ell'_1, \dots, \ell'_m)$  je hodnota minima rovna Shannonově entropii:

$$\bar{L}(\ell'_1, \dots, \ell'_m) = \sum_{i=1}^m p_X(x_i) \ell'_i = H_d(X)$$

## Hledáme optimální kód (pokr.)

- ▶ nalezli jsme pouze vektor  $(l'_1, \dots, l'_m) \in \mathbb{R}^m$ !
- ▶ pro každou  $d$ -adickou  $p_X$  platí  $(l'_1, \dots, l'_m) \in \mathbb{N}^m$
- ▶ můžeme se pokusit najít instantní kód, jehož délky slov by se “příliš nelišily” od  $(l'_1, \dots, l'_m)$ , tato úloha je však obtížně řešitelná a proto se prosadily jiné metody

### Klasické kódovací algoritmy

- 1 Shannonovo kódování
- 2 Fanovo kódování
- 3 Huffmanovo kódování
- 4 LZ algoritmy

Žádný způsob kódování nepřekoná mez danou entropií!

## Dolní mez komprese

### Věta

- ▶ Střední délka  $L(C)$  libovolného jednoznačně dekódovatelného  $d$ -znakového kódu  $C$  pro náhodnou veličinu  $X$  splňuje nerovnost

$$L(C) \geq H_d(X).$$

- ▶ Rovnost

$$L(C) = H_d(X)$$

platí právě tehdy, když  $p_X(x) = d^{-\ell(C(x))}$ .



## Nutné podmínky optimality

Optimální kód zatím neumíme nalézt. Ovšem snadno odvodíme, jaké musí splňovat podmínky.

### Věta

Nechť  $C$  je optimální binární instantní kód pro veličinu  $X$ . Platí:

- 1 Pokud  $p_X(x) > p_X(y)$ , pak  $\ell(C(x)) \leq \ell(C(y))$ .
- 2 V kód. stromě pro  $C$  má každý list přiřazeno kódové slovo.
- 3 Dvě nejméně pravděpodobná kódová slova mají stejnou délku.

## Shannonovo kódování

**Vstup:** zdroj  $(\Lambda, p)$ , kde  $\Lambda = \{x_1, \dots, x_n\}$ ,  $p = (p_1, \dots, p_n)$

**Výstup:** kód  $C_S: \Lambda \rightarrow \{0, 1, \dots, d-1\}^*$

- ▶ bez újmy na obecnosti předpokládáme  $p_i > 0$
- ▶ položme

$$\ell_i = \lceil \log_d p_i^{-1} \rceil,$$

tato čísla splňují Kraftovu nerovnost:

$$\sum_{i=1}^n d^{-\lceil \log_d p_i^{-1} \rceil} \leq \sum_{i=1}^n d^{-\log_d p_i^{-1}} = \sum_{i=1}^n p_i = 1$$

- ▶ slova kódu  $C_S$  nalezneme pomocí konstrukce instantního kódu se zadanými délkami  $\ell_i$

## Meze Shannonova kódování

### Věta

Platí  $H_d(X) \leq L(C_S) < H_d(X) + 1$ .

### Důkaz.

Snadno plyne z nerovnosti

$$\log_d p_i^{-1} \leq \lceil \log_d p_i^{-1} \rceil < \log_d p_i^{-1} + 1.$$

**Poznámka.** Střední délka optimálního kódu  $C^*$  tedy splňuje

$$H_d(X) \leq L(C^*) < H_d(X) + 1.$$

- Kódy
- Kraftova nerovnost
- Konstrukce kódů
- **Huffmanovo kódování**
- Zdroje s pamětí

# Úvod

- ▶ Huffman našel v r.1951 **optimální kód**  $C_H$ , tedy instantní kód minimalizující střední délku na množině všech jednoznačně dekódovatelných kódů
- ▶ výsledný kód není určen jednoznačně (např. bitovou inverzí získáme jiný optimální kód)
- ▶ jednoznačně není určena ani délka kódových slov
- ▶ **aplikace**
  - ▶ závěrečné zpracování formátů JPEG, MP3, DEFLATE, PKZIP
  - ▶ předzpracování souboru pro aritmetické kódování

## Algoritmus


**Vstup:** inf. zdroj  $(\Lambda, p)$ , kde  $\Lambda = \{x_1, \dots, x_n\}$ ,  $p = (p_1, \dots, p_n)$

**Výstup:** kód  $C_H : \Lambda \rightarrow \{0, 1\}^*$

- 1 Z prvků množiny  $\Lambda$  vytvoř množiny  $S_1 = \{x_1\}, \dots, S_n = \{x_n\}$ ,  $\mathcal{S} = \{S_1, \dots, S_n\}$  a uvažuj informační zdroj  $(\mathcal{S}, p)$
- 2 Dokud  $\mathcal{S}$  není jednoprvková:
  - 2-1 najdi množiny  $S_i, S_j, i \neq j$  s nejnižšími pravděpodobnostmi  $p_i, p_j$
  - 2-2 prvkům z  $S_i$  přiřip bit 0, prvkům z  $S_j$  přiřip bit 1 (bity připisujeme na **začátek** kódového slova)
  - 2-3 polož  $\mathcal{S} := \mathcal{S} \setminus \{S_i, S_j\}$
  - 2-4 polož  $\mathcal{S} := \mathcal{S} \cup \{S_i \cup S_j\}$  a  $p(S_i \cup S_j) := p(S_i) + p(S_j)$
- 3 Každému  $x_i \in \Lambda$  přiřad slovo  $C_H(x_i)$ , které vzniklo postupným připisováním bitů

## Příklad

$x$	$p(x)$	$x$	$p(x)$	$x$	$p(x)$	$x$	$p(x)$	kód
1	0.25	(4, 5)	0.30	(2, 3)	0.45	(1, 4, 5)	0.55	01
2	0.25	1	0.25	(4,5)	0.30	(2,3)	0.45	10
3	0.20	2	0.25	1	0.25			11
4	0.15	3	0.20					000
5	0.15							001



## Huffmanův vs. Shannonův kód

Srovnání délek kód. slov:

### Příklad

Informační zdroj:  $\Lambda = \{x_1, x_2\}$ ,  $p(x_1) = 0.9999$ ,  $p(x_2) = 0.0001$ .

- ▶ Shannonův kód obsahuje slova délky 1 a 14
- ▶ Huffmanův kód obsahuje slova délky 1 a 1

### Příklad

Informační zdroj:  $\Lambda = \{x_1, x_2, x_3, x_4\}$ ,

$$p(x_1) = p(x_2) = 3^{-1}, p(x_3) = 4^{-1}, p(x_4) = 12^{-1}.$$

- ▶ Huffmanův kód má slova délek (2, 2, 2, 2) nebo (1, 2, 3, 3)
- ▶ Shannonův kód dává pro  $x_3$  slovo délky 2



# Optimalita Huffmanova kódování

## Věta

Nechť  $C_H$  je Huffmanův kód a  $C$  je libovolný jednoznačně dekódovatelný kód pro náhodnou veličinu  $X$ . Potom platí:

- ▶  $C_H$  je optimální, neboli  $L(C_H) \leq L(C)$
- ▶  $H(X) \leq L(C_H) < H(X) + 1$

## Vlastnosti Huffmanova kódování

### Výhody

- ▶ minimální střední délka
- ▶ snadná implementace
- ▶ není patentová ochrana

### Nevýhody

- ▶ vstupem je informační zdroj, což vyžaduje načtení celého souboru dat kvůli výpočtu četností jednotlivých symbolů (řešení: **adaptivní Huffmanovo kódování**)
- ▶ ke kódu je nutno připojit **kódovací tabulku**

## Připojení kódovací tabulky

### Příklad

Zpráva obsahuje  $10^4$  znaků ( $=10^4$  bajtů) z abecedy  $\Lambda = \{a, \dots, e\}$  s pravděpodobnostmi

$$p_X(a) = 0.35, p_X(b) = p_X(c) = 0.17, p_X(d) = 0.16, p_X(e) = 0.15.$$

Zkomprimovaná zpráva má

$$10^4 L(C_H) = 10^4 \cdot 2.3 = 23\,000 \text{ bitů} = 2\,875 \text{ bajtů}$$

Kompresní poměr 28.75 % je tak připojením kódovací tabulky navýšen jen minimálně.

Ovšem  $H(X) = 2.23284 < 2.3 = L(C_H)$ , rozdíl je asi 3%. Entropii se můžeme dále přiblížit **blokovým kódováním**.

## Blokové kódování

### Věta (Shannonova věta o zdrojovém kódování)

Nechť  $(X_n)_{n \in \mathbb{N}}$  je **bezpaměťový** zdroj s rychlostí entropie  $H((X_n)_{n \in \mathbb{N}}) = H(X_1)$ . Potom Huffmanův nebo Shannonův kód  $C^n$  pro  $n$ -tice znaků z abecedy  $\Lambda$  splňuje

$$\lim_{n \rightarrow \infty} \frac{L(C^n)}{n} = H(X_1).$$

### Příklad

$\Lambda = \{a, b, c\}$ ,  $p_X(a) = 0.1$ ,  $p_X(b) = 0.2$ ,  $p_X(c) = 0.7$

$L(C_H) = 0.1 \cdot 2 + 0.2 \cdot 2 + 0.7 \cdot 1 = 1.3 > H(X) = 1.15678$

Lze dosáhnout maximálně **11%** úspory **blokovým kódováním**.

## Blokové kódování-příklad

### Příklad(pokr.)

Uvažujme Huffmanův blokový kód pro **dvojice** znaků z  $\Lambda$ . Zdrojová abeceda je nyní  $\Lambda^2$  a pravděpodobnosti stanovíme díky nezávislosti jako

$$p_{XY}(x, y) = p_X(x) \cdot p_Y(y), \quad (x, y) \in \Lambda^2$$

Potom pro kód  $C_H^2$  platí

$$\frac{L(C_H^2)}{2} = \frac{2.33}{2} = 1.165$$

V porovnání s kódem  $C_H$ , pro který platí  $L(C_H) = 1.3$ , tak byla zvýšena komprese o 10 %, ovšem za cenu připojení větší kódovací tabulky a prodloužení odezvy při kódování.

## Shrnutí

- ▶ dolní mez komprese je rovna **entropii** informačního zdroje
- ▶ **Huffmanovo kódování** je optimální kompresní algoritmus pro jednu diskrétní náhodnou veličinu
- ▶ **blokové kódování** umožňuje asymptoticky optimálně zkomprimovat libovolný **bezpaměťový** zdroj informace
- ▶ ovšem kódování **není jednopřechodové**, je nutno nejdříve načíst celý vstupní soubor
- ▶ umíme optimálně komprimovat **zdroje s pamětí**?

- Kódy
- Kraftova nerovnost
- Konstrukce kódů
- Huffmanovo kódování
- Zdroje s pamětí

## Zdroj s pamětí

- ▶ bezpaměťový zdroj je posloupnost  $(X_n)_{n \in \mathbb{N}}$  nezávislých a stejně rozdělených náh. veličin nad konečnou abecedou  $\Lambda$
- ▶ většina informačních zdrojů (texty, bitmapy) však vykazuje velmi silnou závislost mezi sousedními znaky  $X_i$  a  $X_{i+1}$  či sousedními řetězci  $X_{i-k} \dots X_i$  a  $X_{i+1}$  (**markovské zdroje**)
- ▶ pro zdroje s pamětí  **nemusí být Huffmanovo kódování optimální**
- ▶ komprimovatelnost stacionárního zdroje s pamětí určuje  **rychlost entropie**



## Příklad zdroje s pamětí

### Entropie českého textu - viz tato studie

Předpokládejme, že náhodně vybraný vzorek dlouhého českého textu (např. beletrie) tvoří **stacionární zdroj informace** nad abecedou

$$\Lambda = \{a, \dots, z, \acute{a}, \dots, \acute{z}, \text{ch}\}.$$

Odhadneme jeho rychlost entropie  $H((X_n)_{n \in \mathbb{N}})$ . Nejprve stanovíme entropii rovnoměrného modelu:

$$\log |\Lambda| = 5.39 \text{ bitu.}$$

Vezmeme-li v úvahu četnosti výskytu jednotlivých písmen, dostaneme entropii bezpaměťového zdroje:

$$H(X) = 4.72 \text{ bitu.}$$

## Příklad zdroje s pamětí

### Entropie českého textu - pokr.

Pokud uvažujeme bigramy (markovský zdroj), dostaneme entropii

$$H(X_2|X_1) = 3.69 \text{ bitu.}$$

Při použití trigramů (2-markovský zdroj)

$$H(X_3|X_2, X_1) = 3.18 \text{ bitu.}$$

Další přiblížení jsou výpočetně náročná. Rychlost entropie lze odhadnout jako

$$H((X_n)_{n \in \mathbb{N}}) \approx 2.07 \text{ bitu.}$$

**Závěr:** písmeno v průměrném textu nese asi 2 bity informace. Pro abecedu s mezerou je výsledek téměř stejný.

## Jak komprimovat zdroje s pamětí?

- ▶ autoři Lempel a Ziv publikovali 2 základní varianty algoritmu **LZ77** a **LZ78** (1977-1978)
- ▶ algoritmus má mnoho různých variací, jako je např. Lempel-Ziv-Welsh **LZW** (compress v Unixu, ZIP, RAR, komprese v modemech, GIF, PDF)
- ▶ jde o třídu adaptivních kompresních algoritmů se **slovníkem**
- ▶ nevyžaduje znalost rozdělení zdroje, kódování probíhá **jednoprůchodově**

## LZ78 (stromová verze LZ)

- ▶ řetězec  $x_1 \dots x_n \in \Lambda^n$  je sekvenčně testován na výskyt **nejkratších řetězců**, které se nevyskytly v předchozím kroku
- ▶ každý takový řetězec je označen a uložen do **slovníku**
- ▶ díky minimalitě ukládaného řetězce jsou jeho **prefixy** již ve slovníku: řetězec  $x_i \dots x_k$  byl uložen do slovníku před  $x_i \dots x_k x_{k+1}$

Kód tvoří posloupnost dvojic  $(U_k, x_k)$ , kde

- ▶  $x_k$  je poslední znak řetězce  $x_i \dots x_\ell x_k$ ,
- ▶  $U_k$  je ukazatel na odpovídající prefix  $x_i \dots x_\ell$ .

## Ilustrace LZ78

### Příklad

$\Lambda = \{A, B\}$ , řetězec *ABBABBABBBBAABABAA*

Dostaneme následující řetězce:

*A, B, BA, BB, AB, BBA, ABA, BAA*

Výsledný kód:

*0A 0B 2A 2B 1B 4A 5A 3A*

## Efektivita LZ78

Nechť  $c(n)$  je počet slov ve slovníku pro zprávu  $x_1 \dots x_n \in \{0, 1\}^n$ .

- ▶ kód se skládá z  $c(n)$  dvojic (ukazatel, poslední bit)
- ▶ potřebujeme tedy celkem nejvýše

$$c(n)(\log c(n) + 1) \text{ bitů}$$

- ▶ pro stacionární ergodický zdroj informace  $(X_n)_{n \in \mathbb{N}}$  je LZ78 **asymptoticky optimální komprimátor**, neboť platí

$$\frac{c(n)(\log c(n) + 1)}{n} \rightarrow H((X_n)_{n \in \mathbb{N}})$$

s pravděpodobností 1

# Část V

## Informační kanály

- Kódy
- Kraftova nerovnost
- Konstrukce kódů
- Huffmanovo kódování
- Zdroje s pamětí

## Motivace

### Příklad (Vajda, 2004)

Holub má přepravit 1 bit informace (výhra/prohra bitvy). Jaká je **kapacita** použitého informačního kanálu v případě, že

- 1 bude holub sežrán sokolem s pravděpodobností 0.2,
- 2 holub se vyhne sokolům, ale s pravděpodobností 0.2 je odchycen špiónem, který mu zprávu změní na opačnou.



# Informační kanál

## Definice

**Informační kanál** je trojice  $\mathcal{K} = (\Lambda, \mathbf{P}, \Omega)$ , kde


- ▶  $\Lambda$  je  $m$ -prvková vstupní abeceda
- ▶  $\Omega$  je  $n$ -prvková výstupní abeceda
- ▶  $\mathbf{P}$  je matice  $m \times n$  podmíněných pravděpodobností:

$$\mathbf{P} = \begin{pmatrix} p_{Y|X}(y_1|x_1) & p_{Y|X}(y_2|x_1) & \dots & p_{Y|X}(y_n|x_1) \\ p_{Y|X}(y_1|x_2) & p_{Y|X}(y_2|x_2) & \dots & p_{Y|X}(y_n|x_2) \\ \dots & \dots & \dots & \dots \\ p_{Y|X}(y_1|x_m) & p_{Y|X}(y_2|x_m) & \dots & p_{Y|X}(y_n|x_m) \end{pmatrix}$$

Typicky  $\Lambda = \Omega = \{0, 1\}$ .

## Příklad: binární symetrický kanál

$$\Lambda = \Omega = \{0, 1\}$$



$$\mathbf{P} = \begin{pmatrix} 1-p & p \\ p & 1-p \end{pmatrix}$$

- Model komunikace
- Kapacita kanálu
- Shannonova věta o kapacitě

## Přenositelnost informace kanálem

**Vstup:** informační zdroj  $X$  s pravděpodobnostmi

$$(p_X(x_1), \dots, p_X(x_m))$$

**Výstup:** informační zdroj  $Y$  s pravděpodobnostmi

$$(p_Y(y_1), \dots, p_Y(y_n)) = (p_X(x_1), \dots, p_X(x_m)) \cdot \mathbf{P}$$

- ▶ pravděpodobnosti  $p_{X|Y}(x_i|y_j)$  lze určit pomocí Bayesova vzorce
- ▶ přenositelnost zdroje  $X$  popisuje **vzájemná informace**

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

## Informační kapacita

Volba pravděpodobností  $p_X$  je na uživateli, neboť ty odpovídají četnostem použitých znaků kanálové abecedy  $\Lambda$ .

### Definice

**Informační kapacita** kanálu  $\mathcal{K} = (\Lambda, \mathbf{P}, \Omega)$  je

$$C(\mathcal{K}) = \sup_{p_X} I(X; Y).$$

- ▶  $I(X; Y)$  je spojitou funkcí  $p_X$  na kompaktní množině  $\Delta_m$ , suprema se nabývá pro nějaké  $p_X \in \Delta_m$
- ▶ vztah pro  $I(X; Y)$  je symetrický:

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

## Vlastnosti kapacity

### Věta

Nechť  $\mathcal{K} = (\Lambda, \mathbf{P}, \Omega)$  je informační kanál. Potom:

- ▶  $C(\mathcal{K}) \geq 0$
- ▶  $C(\mathcal{K}) \leq \log |\Lambda|$
- ▶  $C(\mathcal{K}) \leq \log |\Omega|$



## Výpočet kapacity

- ▶ hledáme maximum rozdílu  $H(Y) - H(Y|X)$  pro  $X$
- ▶ výpočet je snadný pro kanály, v nichž se pravděpodobnostní funkce  $p_{Y|X}(\cdot|x_i)$ ,  $p_{Y|X}(\cdot|x_j)$  liší pouze **permutací** odpovídajících pravděpodobností
- ▶ odpovídající matice přechodu  $\mathbf{P}$  je tak tvořena permutacemi jednoho řádku
- ▶ to znamená, že  $H(Y|x_i) = H(Y|x_j)$  pro každé  $x_i, x_j \in \Lambda$  a proto

$$H(Y|X) = \sum_{x_k \in \Lambda} p_X(x_k) H(Y|x_k) = H(Y|x_i)$$

## Binární bezšumový kanál

$$\Lambda = \Omega = \{0, 1\}$$




$$\text{Kapacita } C(\mathcal{K}) = 1$$



## Binární symetrický kanál


$$\Lambda = \Omega = \{0, 1\}$$



$$\text{Kapacita } C(\mathcal{K}) = 1 - H(p, 1-p)$$

## Binární kanál se zámlkou

$$\Lambda = \{0, 1\}, \Omega = \{0, 1, z\}$$



$$\text{Kapacita } C(\mathcal{K}) = 1 - p$$


## Zámka lepší než záměna

### Věta

Kapacita binárního kanálu s pravděpodobností *zámky*  $2p$  ( $0 < p < \frac{1}{2}$ ) je větší než kapacita binárního symetrického kanálu s pravděpodobností *záměny*  $p$ .

- Model komunikace
- Kapacita kanálu
- Shannonova věta o kapacitě

## Schéma komunikace



- ▶ **náhodnost** spočívá v přítomnosti šumu a zdrojové zprávy  $M$
- ▶ **uživatel** volí kodér  $\varphi$  a dekodér  $\psi$ , délku kód. slova  $n$

## Složky modelu komunikace

- 1 **zdroj** je náhodná veličina  $M$  s rovnoměrným rozdělením na konečné množině zpráv  $\mathcal{M}$

- 2 **kodér** je zobrazení

$$\varphi : \mathcal{M} \rightarrow \Lambda^n,$$

keré každé zdrojové zprávě  $i \in \mathcal{M}$  přiřazuje vstupní kódové slovo  $\varphi(i) = x_1 \dots x_n \in \Lambda^n$

- 3 **bezpaměťový informační kanál**  $\mathcal{K} = (\Lambda, \mathbf{P}, \Omega)$ , ten splňuje

$$P_{Y_k | X_1 \dots X_k Y_1 \dots Y_{k-1}} = P_{Y_k | X_k}$$

- 4 **dekodér** je zobrazení

$$\psi : \Omega^n \rightarrow \mathcal{M},$$


keré každému výstupu kanálu  $y_1 \dots y_n \in \Omega^n$  přiřazuje odhad  $\psi(y_1 \dots y_n) \in \mathcal{M}$  zaslané zprávy  $M$

## Kanálové kódování

### Definice

$(|\mathcal{M}|, n)$ -kódovací schéma pro kanál  $(\Lambda, \mathbf{P}, \Omega)$  je tvořeno

- ▶ množinou  $\mathcal{M}$  stejně pravděpodobných zpráv,
- ▶ kódérem  $\varphi$ , který každé zprávě  $i \in \mathcal{M}$  přiřazuje slovo  $x_1 \dots x_n \in \Lambda^n$ ,
- ▶ dekodérem  $\psi$ , který každému výstupu  $y_1 \dots y_n \in \Omega^n$  přiřazuje odhad původní zasláné zprávy z  $\mathcal{M}$ .



## Rychlost přenosu

### Definice

**Rychlost**  $(|\mathcal{M}|, n)$ -kódovacího schématu je

$$R = \frac{\log |\mathcal{M}|}{n} \quad \text{bit/znak kanálové abecedy.}$$

- ▶  $R$  udává rychlost komunikace daným kanálem
- ▶ jiné jednotky: bit/1 přenos kanálem
- ▶ chceme  $R \rightarrow \text{MAX}$  při současné minimální chybě!



## Pravděpodobnosti chyb

### Definice

Pro libovolné  $(|\mathcal{M}|, n)$ -kódovací schéma pro kanál  $\mathcal{K}$  definujeme:

- ▶ **podmíněná pravděpodobnost chyby** pro  $i \in \mathcal{M}$  je

$$\lambda_i = P[\psi(Y_1 \dots Y_n) \neq i | (X_1 \dots X_n) = \varphi(i)]$$

- ▶ **maximální pravděpodobnost chyby** je

$$\lambda^{(n)} = \max_{i \in \mathcal{M}} \lambda_i$$

- ▶ **průměrná pravděpodobnost chyby** je  $p_e^{(n)} = \frac{1}{|\mathcal{M}|} \sum_{i=1}^{|\mathcal{M}|} \lambda_i$

## Hlavní cíl kanálového kódování

Hledáme  $(|\mathcal{M}|, n)$ -kódovací schéma **minimalizující** maximální pravděpodobnost chyby  $\lambda^{(n)}$  pro **zadanou** rychlost  $R$ .

Jak navrhnout dekodér  $\psi : \Omega^n \rightarrow \mathcal{M}$ , aby tohoto cíle dosáhl?

Položme

$$\psi(y_1 \dots y_n) = \arg \max_{i \in \mathcal{M}} p_{Y_1 \dots Y_n | X_1 \dots X_n}(y_1 \dots y_n | \varphi(i))$$

pro každé  $y_1 \dots y_n \in \Omega^n$ .

## Co říká Shannonova věta?

### Věta

Nechť  $\mathcal{K}$  je informační kanál. Potom:

- ▶ Lze nalézt kód o rychlosti  $R < C(\mathcal{K})$  takový, že chyba  $\lambda^{(n)}$  bude libovolně malá pro  $n \rightarrow \infty$ .
- ▶ Naopak, kód o rychlosti přenosu  $R > C(\mathcal{K})$  má nutně chybu  $\lambda^{(n)} > 0$  pro  $n \rightarrow \infty$ .

Kapacita kanálu  $C(\mathcal{K})$  je tak mezí spolehlivé komunikace **nezávisle** na použitém kódovacím algoritmu!

## Komentář k Shannonově větě

- ▶ důkaz je konstruktivní
- ▶ ovšem je nutno prohledat všechny kodéry, těch je  $O(2^{2^n})$
- ▶ pro velká  $n$  má navíc systém pomalou odezvu a složitá pravidla
- ▶ pro praktické použití se tedy nehodí...
- ▶ honba za kódy, jejichž rychlost se přibližuje kapacitě kanálu, začala v 50.letech minulého století a pokračuje dodnes

Část VI

Dodatek

## Značení a konvence

- ▶  $\log$  znamená  $\log_2$
- ▶ pokud  $A$  je konečná množina, pak  $|A|$  značí počet prvků v  $A$
- ▶ pro libovolné  $x \in \mathbb{R}$  značí symbol  $\lceil x \rceil$  nejmenší celé číslo  $y$  takové, že  $x \leq y$

## Jensenova nerovnost

### Věta

Nechť  $f: (a, b) \rightarrow \mathbb{R}$  je konkávní funkce. Je-li  $t_1, \dots, t_n \in (a, b)$ , potom pro všechna  $\alpha_1, \dots, \alpha_n \in \langle 0, 1 \rangle$  splňující  $\sum_{i=1}^n \alpha_i = 1$  platí

$$f\left(\sum_{i=1}^n \alpha_i t_i\right) \geq \sum_{i=1}^n \alpha_i f(t_i).$$

Pokud je  $f$  ryze konkávní, potom rovnost v Jensenově nerovnosti implikuje  $t_1 = \dots = t_n$ .

### Pravděpodobnostní interpretace

Je-li  $X$  náhodná veličina s konečným výběrovým prostorem  $\mathcal{X} \subseteq \mathbb{R}$  a  $f$  je konkávní funkce na nějakém intervalu obsahujícím  $\mathcal{X}$ , potom

$$f(EX) \geq E(f(X)).$$

## Kam dále v teorii informace?

- ▶ **ergodická teorie** stacionárních náhodných procesů nad konečnou abecedou jako základní rámec pro moderní kompresní algoritmy (LZW)
- ▶ **kanálové kódování** jako algebraická teorie pro spolehlivou komunikaci
- ▶ **ztrátová** komprese
- ▶ **Gaussovské** informační kanály
- ▶ **kvantová** teorie informace



# Literatura



Thomas M. Cover and Joy A. Thomas.  
*Elements of Information Theory*.  
Wiley-Interscience [John Wiley & Sons], NJ, 2006.



S.M. Moser.  
Information Theory  
<http://moser-isi.ethz.ch/scripts.html>



I. Vajda.  
*Teorie informace*.  
Vydavatelství ČVUT, 2004.



A. Drozdek.  
*Elements of Data Compression*.  
Brooks/Cole, 2002.