

# 20SK – Signály a kódy

---

## Přednáška 8 – Prefixové kódy, komprese dat (19.11.2018)

Probíraná témata:

- Formální definice kódu.
- Kódy s pevnou délkou slova (blokové kódy).
- Kódy s proměnnou délkou slova.
- Jednoznačná dekódovatelnost.
- Kraftova nerovnost pro prefixové kódy.
- Optimální prefixový kód, Huffmanovo kódování.

Relevantní literatura je [1, kapitola 2], [2, kapitola 2], [3, odstavec 1.2] a [4, celá kapitola I].

### Seznam literatury

- [1] Gallager, R.: Course materials for 6.450 *Principles of Digital Communications I*, Fall 2006. MIT OpenCourseWare (<http://ocw.mit.edu/>), Massachusetts Institute of Technology.
- [2] Adámek, J: *Foundations of Coding: Theory and Applications of Error-Correcting Codes with an Introduction to Cryptography and Information Theory*. Wiley Interscience, 1991, 352 pp.
- [3] Seibt, P.: *Algorithmic Information Theory – Mathematics of Digital Information Processing*. Springer, 2006, 447 pp.
- [4] Adámek, J: Kódování. *Matematika pro vysoké školy technické, sešit XXXI*. SNTL, 1989, 192 pp.

# Kódování informace z diskretivních zdrojů

## Typy zdrojů:

- a) analogové zdroje: spojitý ulový signál
- b) analogové zdroje: diskretivní v čase<sup>lv</sup> spojitě v hodnotě
- c) diskretivní zdroje: symboly z nějaké abecedy X diskretivní v čase

libovolná konečná množina symbolů

$$X = \{A, B, C, \dots, |, \& \}$$

$$X = \{0, 1, \dots, |, \dots\}$$

$$X = \{0, 1, 2, \dots, |, \dots\}$$

# Základní pravidlo pro kódování

Kód musí být jednoznačně dekódovatelný!  
Fungují pouze pro diskretivní zdroje!

## Kódování - definice

- zdrojová abeceda ... A (vstup)
- kódová abeceda ... B (výstup) ... u nás vždy binární, B = {0, 1}
- slovo v A či B ... konečná posloupnost symbolů z A či B, A<sup>101010</sup>, A<sup>10101010</sup>
- kódování: symbol z A mapuje na slovo v B  
ale: lze i slovo v A → slovo v B

$$A^{101010} \rightarrow A^{10101010}$$

→ vyřazení při kóování



Př: Kód 2 z 5

0	→	00011
1	→	11000
2	→	10100
3	→	01100
4	→	10010
5	→	01010
6	→	00110
7	→	10001
8	→	01001
9	→	00101

**A**      **B**

Př: 0 → 0 → 0000  
 9 → 9 → 1001  
 10 → A → 1010  
 11 → B  
 15 → F → 1111

173 → 11000 10001 01100

↓

blokový kód - pevná délka slova  
 fixed-length

počet bitů blokového kódu:

M ... počet symbolů  
 L ... počet bitů

$$M \leq 2^L$$

$$L = \lceil \log_2 M \rceil$$

Základní pravidlo pro kódování

Kód musí být jednoznačně dekodovatelný!  
 Fungují pouze pro diskrétní zdroj!

Kódování - definice

- zdrojová abeceda ...  $X$  (vstup)
- kódová abeceda ...  $B$  (výstup) ... u nás vždy binární,  $B = \{0,1\}$
- slovo  $v \in X$  či  $B$  ... konečná posloupnost symbolů z  $X$  či  $B$ ,  $AHOJ$
- kódování: symbol z  $X$  mapuje na slovo  $v \in B$ ,  $A \rightarrow 010$ ,  $H \rightarrow 011$


ale: lze i slovo  $v \in X \rightarrow$  slovo  $v \in B$   
 $\hookrightarrow AHOJ \rightarrow 01001010$  → využívání při kompresi

Př: A → 010      A?      010 < C?  
 C → 010      C?

Př: Naprefixový kód

a → 1  
b → 10  
c → 100

abba → 110101001



Prefixové kódy

(prefix-free ; instantaneous codes)

- žádné kódové slovo není prefixem jiného kódového slova
- v komunikaci, kdy přijmu poslední bit kódového slova, mohu jej dekódovat
- pokud máme blokový kód s M různými kódovými slovy, je prefixový
- pokud známe pravděpodobnosti rozdělení symbolů zdroje, mohu konstruovat prefixový kód optimální délky → Huffmanovo kódování

Kódy s proměnnou délkou slova

idea: ne všechny symboly a mají stejnou pravděpodobnost výskytu

⇒ entropie závisí na výšce, než nezávisle nulová

Výše: kódovat časté symboly a jako kratší slova a méně časté symboly jako delší slova

Př: Morseova

Př: Jednoduchý bin. kód po tři symboly

E → .  
T → -  
A → . -  
:

a → 0  
b → 10  
c → 11

abba → 01010110

a → 0  
b → 1  
c → 10

abba → 011100 → 011100

*Nová jednovnošně dekódovatelné!*

## Pr: Naprefixový kód

a → 1  
b → 10  
c → 100

abcbca → 110101001

## Prefixové kódy

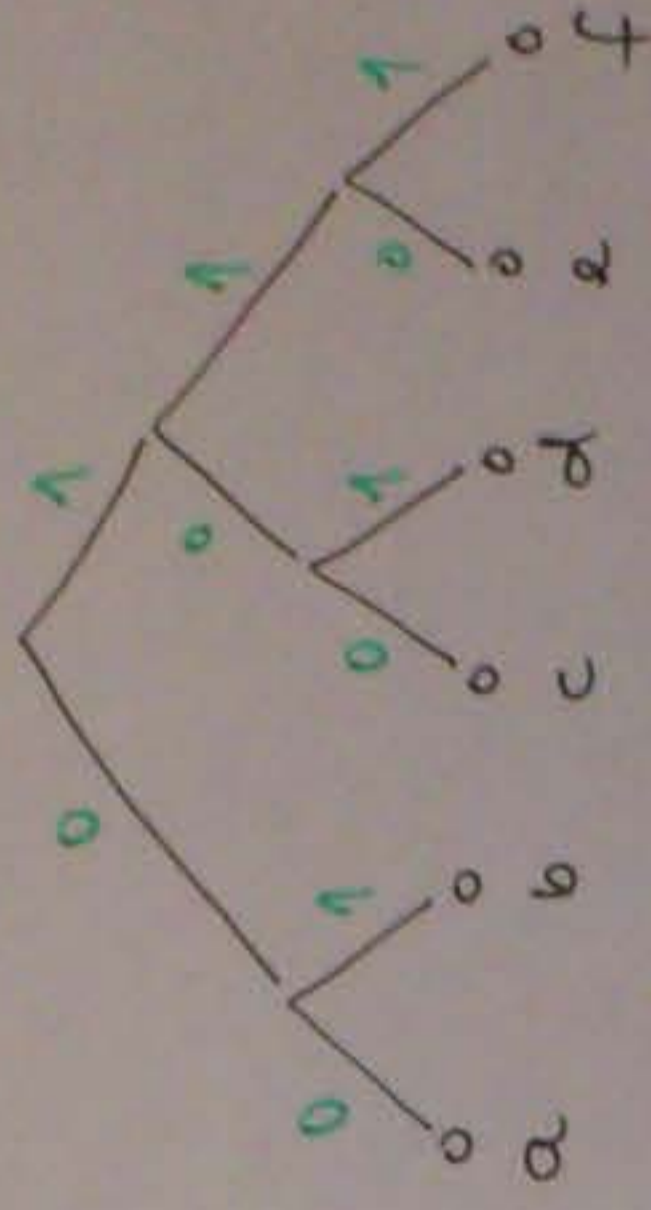
(prefix-free; instantaneous codes)

- žádné kódové slovo není prefixem jiného kódového slova
- v okamžiku, kdy přijmu poslední bit kódového slova, mohu jej dekódovat
- pokud máme dobrý kód s M výstupními kódovými slovy, je prefixový
- pokud známe pravděpodobnostní rozdělení symbolů zdroje, mohu zkonstruovat prefixový kód optimální délky → Huffmanovo kódování

## Pr: A = {a, b, c, d, e, f}


→ prefix. kód ⇒ binární strom se symboly z A v listech

a → 0b  
b → 01  
c → 100  
d → 101  
e → 110  
f → 111



→ optimální kód:

konstrukce stromu podle pravděpodobnosti  
nosného zastoupení symbolů



② Lze zkonstruovat binární pref. kód s danou množinou délek kódových slov?

**Kraftova nerovnost**

$$L = \{l_1, l_2, \dots, l_n\} \dots \text{délky kódových slov}$$

$$\sum_{i=1}^n 2^{-l_i} \leq 1$$

Pokud  $\sum_{i=1}^n 2^{-l_i} > 1$ , kód sestavit lze!

$\rightarrow \sum \dots = 1 \dots$  jde o úplný pref. kód

- může do něj přidat žádný další symbol
- pokud je  $n$  liché, kód nebude úplný nikdy!

**Huffmanovo kódování**

... aproximovat délku kódového slova jako  $-\log_2 P_i$


$$X = \{A, B, C, D\}$$

A	...	0.60	—	0.60	—	0.60	>	1.00
B	...	0.20	—	0.20	—	0.40	>	0.40
C	...	0.15	>	0.20				
D	...	0.05						

$P_i$  ↑

A	...	0.30	>	0.55	>	1.00
B	...	0.29				
C	...	0.28				
D	...	0.13	>	0.41		

$\rightarrow$  všechny symboly mají 2 bity



A	→	0
B	→	10
C	→	110
D	→	111