

Informatika – Kódování

Radim Farana

Podklady předmětu Informatika
pro akademický rok 2007/2008

Obsah

- Základy pojmy z diskretních kódů.
- Druhy kódů.
- Nejkratší kódy.
- Detekce chyb, Hammingova vzdálenost.
- Kontrolní a samoopravné kódy.
 - Lineární kódy.
 - Cyklické kódy.

Kód

- Popis přiřazení kódových slov jednotlivým zprávám (kódová kniha).
- Kódové slovo je posloupnost znaků použité abecedy.
- Abeceda je množina znaků (binární abeceda $Z_2 = \{0, 1\}$)
- Minimální délka kódového slova:
 $N(x) = -\log_2(P(x))$ [bit]

Vlastnosti kódu

- **prosté kódování:** různým zprávám odpovídají různá kódová slova,
- **jednoznačná dekódovatelnost:** ze znalosti zakódované zprávy lze jednoznačně určit zprávu zdrojovou,
- Kód K : A → B musí být **prostým** **zobrazením**.

Problém dekódování

Zpráva



Kód A	0	01	001	111
-------	---	----	-----	-----

Posloupnost zpráv (kódových slov): 001001011111 nelze jednoznačně dekódovat

Kód B	0	01	011	111
-------	---	----	-----	-----

Posloupnost zpráv (kódových slov): 001011011111 lze jednoznačně dekódovat?



Ano, ale jen „odzadu“, po přijetí celé posloupnosti zpráv.

Kód C	0	10	110	111
-------	---	----	-----	-----

Posloupnost zpráv (kódových slov): 010110101111 můžeme dekódovat on-line.

Důvod? Žádné kódové slovo není začátkem jiného kódového slova (prefixem).

Druhy kódů

- **Prefixový kód** je prosté kódování u kterého žádné kódové slovo není začátkem jiného kódového slova.
- **Blokový kód** je prosté kódování u kterého mají všechna kódová slova stejnou délku (počet znaků). Protože musí být prostým zobrazením, je nutně také prefixovým kódem.

Použití kódů

- Nejkratší (optimální) kódy $R \rightarrow 0, L \rightarrow \min$,
- Bezpečnostní kódy
 - detekční kódy (odhalují chyby),
 - samoopravné kódy (opravují chyby),
- Speciální kódy
 - kódy konstantní změny (Grayův kód),
 - čárové kódy,
 - alfanumerické kódy,
 - číselné kódy (datové formáty), ...

Nejkratší kódy

- Pokud má $R \rightarrow 0$, neboli $L \rightarrow \min$, pak
- $N(i) \rightarrow N^*(i)$ pro $i = 1, 2, \dots, n$.
- Hledáme vhodný algoritmus konstrukce takového kódu:
 - Huffmanův kód (1952),
 - Shannonův kód.

Algoritmy se liší, stejně tak i dosažené výsledky, Huffmanův kód se snáze algoritmuje a tedy také realizuje



Huffman, David A.
 * 1925, USA
 † 7. 10. 1999 California, USA
<http://www.usoc.edu/currents/99-00/10-11/huffman.html>

Huffmanův kód

Triviální případ

Zpráva	$P(i)$	kód
1	>	0
2	<	1

Redukovaná abeceda

Zpráva	$P(i)$	redukce	kód	expanze
1	»	1	0	0
2	>	2,3	1	10
3	<			11

Postup:

- seřazení podle pravděpodobnosti,
- postupná redukce a oprava pořadí,
- přiřazení znaků 0, 1 a zpětná expanze.

Příklad

Zpráva	A	B	C	D	E
$P(i)$	0,4	0,3	0,1	0,1	0,1
1.redukce	0,4	0,3	0,2	0,1	
2.redukce	0,4	0,3	0,3		
3.redukce	0,6	0,4			
znaky	0	1			
kód	1	00	011	0100	0101


Problémy:

- definice pořadí zpráv pro stejnou $P(i)$,
- zařazení skupin se stejnou $P(i)$,
- pořadí přiřazení znaků 0, 1.

Detekce chyb

- Množinu všech slov rozdělíme na slova kódová a slova nekódová.
- t -násobná chyba změní kódové slovo na nekódové, pokud se dvě kódová slova liší ve více než t znacích.
- Hammingova vzdálenost je počet znaků ve kterých se dvě kódová slova liší.
- Hammingova vzdálenost kódu d je nejmenší z nich.

Hammingova vzdálenost



Hamming, Richard Wesley

* 11. 2. 1915 Chicago, IL, USA
 + 7. 1. 1992 Monterey, Cal., USA
<http://om.bell-labs.com/olun/hamming/>


Kód odhaluje t -násobné chyby, pokud je Hammingova vzdálenost kódu $d > t$.

Označení kódů (blokových): (n, k) -kód

počet znaků ↗ ↘ počet informačních znaků

$(4, 3)$ -kód má jeden kontrolní znak, je schopen mít $d = 2$.

Opravování chyb



Kód opravuje t -násobné chyby, pokud je Hammingova vzdálenost kódu $d > 2.t$.

Lineární kódy (maticové kódy)

- Kódové slovo chápeme jako řádkový vektor $\mathbf{v} = [0\ 0\ 1]$.
- Lineární kombinací libovolného počtu kódových slov vznikne opět kódové slovo.
- Kód je možno popsat pomocí generující matice (kterou tvoří báze kódu).

$$\mathbf{G} = \begin{bmatrix} 1 & 0 & 0 & 1 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad \mathbf{v} = \mathbf{z} \cdot \mathbf{G}$$

Systematické kódy

- Informační slovo tvoří začátek kódového slova. $\mathbf{G} = [\mathbf{E} | \mathbf{B}]$
- Určení informačního slova (dekódování) je triviální.
- Je možno snadno určit kontrolní matici kódu $\mathbf{H} = [-\mathbf{B}^T | \mathbf{E}]$
- A syndrom přijatého slova $\mathbf{s} = \mathbf{H} \cdot \mathbf{v}^T$
- Nenulový syndrom indikuje chybu.

Hammingovy kódy

- Opravují jednoduché chyby a
- jsou perfektní = při daných vlastnostech mají minimální možnou redundanci.
- Kód s m kontrolními znaky ($m = 2, 3, \dots$) má délku $n = 2^m - 1$.
- Sloupce kontrolní matice tvoří binární rozvoj čísel $1, 2, \dots, 2^m - 1$
- Nenulový syndrom je binárním rozvojem pozice chyby.

Cyklické kódy (polynomické kódy)

- Jsou podtřídou lineárních kódů. Kódové slovo chápeme jako zápis polynomu.
- **Cyklickým** posunem znaků kódového slova vznikne opět kódové slovo.
- Kromě generující matice mohou být popsány také generujícím **polynomem**.
- Jsou schopny dobře detekovat (opravovat) i shlukové chyby.

Realizace cyklických kódů

- Informační slovo dělíme generujícím polynomem,
- určíme zbytek po dělení,
- zbytek připojíme za informační slovo.
- Celé kódové slovo je dělitelné generujícím polynomem beze zbytku.
- Pod označením CRC-kódy (**Cyclic Redundance Code**) mají široké použití

Typické CRC kódy

počet kontrolních bitů	označení	generující polynom	použití
8	LRCC-8	$z^8 + 1$	kontrolní Byte je součet datových Byte modulo 2
12	CRC-12	$z^{12} + z^{11} + z^3 + z^2 + z + 1$	používá se pro šestibitové znaky
16	LCRC-16	$z^{16} + 1$	kontrolní součet dvojice Byte (Word) modulo 2
16	CRC-16	$z^{16} + z^{15} + z^7 + 1$	binární synchronní protokol
16	CRC-16 reverzní	$z^{16} + z^{14} + z + 1$	
16	SDLC	$z^{16} + z^{12} + z^5 + 1$	linkový protokol IBM, standard CCITT
16	SDLC reverzní	$z^{16} + z^{11} + z^4 + 1$	
32	CRC-32	$z^{32} + z^{26} + z^{23} + z^{22} + z^{16} + z^{12} + z^{11} + z^{10} + z^8 + z^7 + z^5 + z^4 + z^2 + z + 1$	Ethernet, HDLC, ZMODEM
