

# Matematika IV – 6. přednáška

## Kódování a šifrování

Michal Bulant

Masarykova univerzita  
Fakulta informatiky

27. 3. 2013

# Obsah přednášky

## 1 Úvod do kódování

- $(n, k)$ -kódy
- Lineární kódy

## 2 Pár slov o šifrách

# Doporučené zdroje

- Martin Panák, Jan Slovák, **Drsná matematika**, e-text.
- *Předmětové záložky v IS MU*
- R. B. Ash, Abstract algebra,  
<http://www.math.uiuc.edu/~r-ash/Algebra.html>.
- Alfred J. Menezes, Paul C. van Oorschot and Scott A. Vanstone , *Handbook of Applied Cryptography*, CRC Press, 2001, 780 p., <http://www.cacr.math.uwaterloo.ca/hac/>
- Jan Paseka, Kódování, elektronický text, MU – <http://www.math.muni.cz/~paseka/ftp/lectures/kodovani.ps>.

# Kódování

Při přenosu informace zpravidla dochází k její deformaci. Budeme pro jednoduchost pracovat s modelem, kdy jednotlivé částečky informace jsou buď nuly nebo jedničky (bity, tj. prvky v  $\mathbb{Z}_2$ ) a přenášíme slova o  $k$  bitech. Obdobné postupy jsou možné i nad ostatními konečnými tělesy.

Přenosové chyby chceme

- ① rozpoznávat
- ② opravovat

a za tím účelem přidáváme dodatečných  $n - k$  bitů informace pro pevně zvolené  $n > k$ . Tak dostaneme tzv.  $(n, k)$ -kód.

Všech slov o  $k$  bitech je  $2^k$  a každé z nich má jednoznačně určovat jedno **kódové slovo** z  $2^n$  možných. Máme tedy ještě

$$2^n - 2^k = 2^k(2^{n-k} - 1)$$

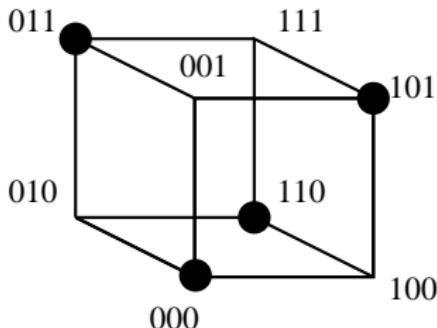
slov, která jsou chybová. Lze tedy tušit, že pro veliké  $k$  nám i malý počet přidaných bitů (tj.  $n - k$ ) dává hodně redundantní informace.

Jednoduchým příkladem je **kód kontrolující paritu**. Kódové slovo o  $k + 1$  bitech je určené tak, aby přidáním prvního bitu byl zaručen sudý počet jedniček ve slově.

Pokud při přenosu dojde k lichému počtu chyb, přijdeme na to.

Dvě různá kódová slova se při tomto kódu vždy liší alespoň ve dvou pozicích, chybové slovo se ale od dvou různých (vhodných) kódových slov liší pouze v pozici jedné. Nemůžeme proto umět chyby opravovat, ani kdybychom věděli, že došlo k právě jedné chybě.

Navíc neumíme detektovat tak obvyklé chyby, jako je záměna dvou sousedních bitů ve slově.



## Definice

**Hammingova vzdálenost** dvou slov je rovna počtu bitů, ve kterých se liší.

## Věta

- ① Kód odhaluje  $r$  a méně chyb, právě když je minimální Hammingova vzdálenost kódových slov právě  $r + 1$ .
- ② Kód opravuje  $r$  a méně chyb, právě když je minimální Hammingova vzdálenost kódových slov právě  $2r + 1$ .

Jak konstruovat kódová slova, abychom je snadno rozpoznali?

Kontrolu parity jsme už viděli, další triviální možnost je prosté opakování bitů – např.  $(3, 1)$ -kód bere jednotlivé bity a posílá je třikrát po sobě.

Systematickou cestou je pak využití dělitelnosti polynomů. Zpráva  $b_0 b_1 \dots b_{k-1}$  je reprezentována jako polynom  
 $m(x) = b_0 + b_1 x + \dots + b_{k-1} x^{k-1}$ .

## Definice

Nechť  $p(x) = a_0 + a_1 x + \dots + a_{n-k} x^{n-k} \in \mathbb{Z}_2[x]$  je polynom s  $a_0 = 1$ ,  $a_{n-k} = 1$ . **Polynomiální kód generovaný polynomem**  $p(x)$  je  $(n, k)$ -kód, jehož slova jsou polynomy dělitelné  $p(x)$  stupně menšího než  $n$ .

Zpráva  $m(x)$  je zakódována jako  $v(x) = r(x) + x^{n-k} m(x)$ , kde  $r(x)$  je zbytek po dělení polynomu  $x^{n-k} m(x)$  polynomem  $p(x)$ .

Z definice víme

$$v(x) = x^{n-k} m(x) + r(x) = q(x)p(x) + r(x) + r(x) = q(x)p(x).$$

Budou tedy všechna kódová slova dělitelná  $p(x)$ .

Původní zpráva je obsažena přímo v polynomu  $v(x)$ , takže dekódování správného slova je snadné.

### Příklad

- ① Polynom  $p(x) = 1 + x$  generuje  $(n, n - 1)$ -kód kontroly parity pro všechna  $n \geq 3$ .
- ② Polynom  $p(x) = 1 + x + x^2$  generuje pro  $k = 1$   $(3, 1)$ -kód opakování bitů.

První tvrzení plyne z toho, že  $1 + x$  dělí polynom  $v(x)$  tehdy a jen tehdy, když  $v(1) = 0$  a to nastane tehdy, když je ve  $v(x)$  sudý počet nenulových koeficientů. Druhé je zřejmé.

## Příklad

Uvažme polynom  $p(x) = 1 + x + x^2$  pro  $n = 5, k = 3$ .

Kódovými slovy jsou

$0 \cdot p(x), 1 \cdot p(x), x \cdot p(x), (x + 1) \cdot p(x), \dots, (x^2 + x + 1) \cdot p(x)$ ,  
tj. kódování slov je následující

$$000 \mapsto 000\ 00$$

$$001 \mapsto 001\ 11$$

$$010 \mapsto 010\ 01$$

$$011 \mapsto 011\ 10$$

$$100 \mapsto 100\ 10$$

$$101 \mapsto 101\ 01$$

$$110 \mapsto 110\ 11$$

$$111 \mapsto 111\ 00$$

Přenos slova  $v \in \mathbb{Z}_2^n$  dopadne příjmem polynomu

$$u(x) = v(x) + e(x)$$

kde  $e(x)$  je tzv. **chybový polynom** reprezentující vektor chyby přenosu.

Chyba je rozpoznatelná pouze, když generátor kódu  $p(x)$  nedělí  $e(x)$ . Máme proto zájem o polynomy, které nevystupují jako dělitelé příliš často.

### Definice

Ireducibilní polynom  $p(x) \in \mathbb{Z}_2[x]$  stupně  $m$  se nazývá **primitivní**, jestliže  $p(x)$  dělí polynom  $x^k - 1$  pro  $k = 2^m - 1$  ale nedělí jej pro žádná menší  $k$ .

## Věta

*Je-li  $p(x)$  primitivní polynom stupně  $m$ , pak pro všechna  $n \leq 2^m - 1$  rozpoznává příslušný  $(n, n - m)$ -kód všechny jednoduché a dvojité chyby.*

## Důsledek

*Je-li  $q(x)$  primitivní polynom stupně  $m$ , pak pro všechna  $n \leq 2^m - 1$  rozpoznává  $(n, n - m - 1)$ -kód generovaný polynomem  $p(x) = q(x)(1 + x)$  všechny dvojité chyby a všechna slova s lichým počtem chyb.*

Tabulka dává informace o výsledcích předchozích dvou vět pro několik polynomů:

primitivní polynom	kontrolní bity	délka slova
$1 + x + x^2$	2	3
$1 + x + x^3$	3	7
$1 + x + x^4$	4	15
$1 + x^2 + x^5$	5	31
$1 + x + x^6$	6	63
$1 + x^3 + x^7$	7	127
$1 + x^2 + x^3 + x^4 + x^8$	8	255
$1 + x^4 + x^9$	9	511
$1 + x^3 + x^{10}$	10	1023

# Lineární kódy

## Definice

**Lineární kód** je injektivní lineární zobrazení  $g : (\mathbb{Z}_2)^k \rightarrow (\mathbb{Z}_2)^n$ . Matice  $G$  typu  $k/n$  reprezentující toto zobrazení v standardních bazích se nazývá generující **matice kódu**.

Pro každé slovo  $v$  je

$$u = G \cdot v$$

příslušné kódové slovo.

## Věta

Každý polynomiální  $(n, k)$ -kód je lineární kód.

Generující matice  $(7, 4)$ -kódu příslušná k polynomu  
 $p(x) = 1 + x^2 + x^3$  je

$$G = \begin{pmatrix} 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 \\ 1 & 1 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}.$$

## Věta

*Je-li  $g : (\mathbb{Z}_2)^k \rightarrow (\mathbb{Z}_2)^n$  lineární kódování s maticí*

$$G = \begin{pmatrix} P \\ \mathbb{E}_k \end{pmatrix},$$

*potom zobrazení  $h : (\mathbb{Z}_2)^n \rightarrow (\mathbb{Z}_2)^{n-k}$  s maticí*

$$H = (\mathbb{E}_{n-k} \quad P)$$

*má následující vlastnosti*

- ①  $\text{Ker } h = \text{Im } g$ , tj.
- ② přijaté slovo  $u$  je kódové slovo, právě když je  $H \cdot u = 0$

Matici  $H$  z věty se říká **kontrolní matici** příslušného  $(n, k)$ -kódu.

# Samoopravné kódy

Jak jsme viděli, přenos zprávy  $u$  dává výsledek

$$v = u + e.$$

To je ale nad  $\mathbb{Z}_2$  ekvivalentní s  $e = u + v$ .

Pokud tedy známe podprostor  $V \subset (\mathbb{Z}_2)^n$  správných kódových slov, víme u každého výsledku, že správné slovo (s opravenými případnými chybami) je ve třídě rozkladu  $v + V$  prostoru  $(\mathbb{Z}_2)^n / V$ . Zobrazení (homomorfismus grup)  $h : (\mathbb{Z}_2)^n \rightarrow (\mathbb{Z}_2)^{n-k}$  má  $V$  za jádro, proto indukuje injektivní lineární zobrazení  $h : (\mathbb{Z}_2)^n / V \rightarrow (\mathbb{Z}_2)^{n-k}$ . Jeho hodnoty jsou jednoznačně určeny hodnotami  $H \cdot u$ .

## Definice

Hodnota  $H \cdot u$  se nazývá **syndrom** slova  $u$ .

## Věta

*Dvě slova jsou ve stejné třídě rozkladu právě tehdy, když mají týž syndrom.*

Samoopravné kódy lze konstruovat tak, že pro každý syndrom určíme prvek v příslušné třídě, který je nevhodnějším slovem.

## Příklad

Bud' dán  $(6, 3)$ -kód nad  $\mathbb{Z}_2$  generovaný polynomem  $x^3 + x^2 + 1$ .

- ➊ Určete jeho generující matici a matici kontroly parity.
- ➋ Dekódujte zprávu 111101, předpokláde-li, že při přenosu došlo k nejmenšímu možnému počtu chyb.

## Řešení

Protože se jedná o lineární kód, stačí určit jak se zakódují bázové vektory  $1$ ,  $x$  a  $x^2$ , tedy určit zbytky polynomů  $x^3$ ,  $x^4$  a  $x^5$  po dělení polynomem  $x^3 + x^2 + 1$ . Máme

$$x^3 \equiv x^2 + 1 \pmod{x^3 + x^2 + 1}$$

$$x^4 = x(x^3) \equiv x(x^2 + 1) \equiv x^2 + x + 1 \pmod{x^3 + x^2 + 1}$$

$$x^5 = x(x^4) \equiv x(x^2 + x + 1) \equiv x + 1 \pmod{x^3 + x^2 + 1}$$

## Řešení (pokr.)

Bázové vektory (zprávy) 100, 010 a 001 se tedy zakódují do vektorů (kódů) 101100, 111010 a 110001, generující matice, resp. matice kontroly parity kódu jsou tedy

$$G = \begin{pmatrix} 1 & 1 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad \text{resp.} \quad H = \begin{pmatrix} 1 & 0 & 0 & 1 & 1 & 1 \\ 0 & 1 & 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 0 & 0 & 1 \end{pmatrix}$$

Vynásobíme-li přijatou zprávu 111101 maticí kontroly parity, dostáváme syndrom 100 a víme, že při přenosu došlo k chybě. Sestavme tabulku všech syndromů a jím odpovídajících kódových slov.

Syndrom	Slova s daným syndromem							
000	<b>000000</b>	110001	111010	101100	010110	001011	011101	100111
001	<b>001000</b>	111001	110010	100100	011110	000011	010101	101111
010	<b>010000</b>	100001	101010	111100	000110	011011	001101	110111
100	<b>100000</b>	010001	011010	001100	110110	101011	111101	000111
011	<b>011000</b>	101001	100010	110100	001110	010011	<b>000101</b>	111111
101	101000	011001	010010	<b>000100</b>	111110	100011	110101	001111
110	110000	<b>000001</b>	001010	011100	100110	111011	101101	010111
111	111000	001001	<b>000010</b>	010100	101110	110011	100101	011111

## Řešení (dokončení)

Syndrom 000 mají všechna kódová slova. Počínaje druhým řádkem, je každý řádek tabulky affinním prostorem jehož zaměřením je vektorový prostor daný prvním řádkem. Zejména je tedy rozdíl každých dvou slov ve stejném řádku nějakým kódovým slovem. Všechna slova s daným syndromem dostaneme přičtením syndromu (doplňeného nulami na délku kódového slova) ke všem kódovým slovům. Tzv. vedoucím reprezentantem třídy (řádku, affinního prostoru) odpovídající danému syndromu je slovo s nejmenším počtem jedniček v řádku, a tedy i nejmenším počtem bitových změn, jež je třeba provést, abychom dostali kódové slovo – v našem případě jde o slovo 100000 a jeho odečtením od obdrženého slova dostaneme platné kódové slovo 011101. Je to platné kódové slovo s nejmenší Hammingovou vzdáleností od obdrženého slova. Odeslaná zpráva tedy byla 101.

# RSA

*Ron Rivest, Adi Shamir, Leonard Adleman (1977; C. Cocks, GCHQ – 1973)*

- každý účastník  $A$  potřebuje dvojici klíčů – veřejný  $V_A$  a soukromý  $S_A$
- generování klíčů: zvolí dvě velká prvočísla  $p, q$ , vypočte  $n = pq$ ,  $\varphi(n) = (p - 1)(q - 1)$  [ $n$  je veřejné, ale  $\varphi(n)$  nelze snadno spočítat ]
- zvolí **veřejný klíč**  $e$  a ověří, že  $(e, \varphi(n)) = 1$
- např. pomocí Euklidova algoritmu spočítá **tajný klíč**  $d$  tak, aby  $e \cdot d \equiv 1 \pmod{\varphi(n)}$
- zašifrování numerického kódu zprávy  $M$ :  $C = C_e(M) \equiv M^e \pmod{n}$
- dešifrování šifry  $C$ :  $OT = D_d(C) \equiv C^d \pmod{n}$

Důkaz.

Fermatova, resp. Eulerova věta.



# Princip digitálního podpisu

## Podepisování (např. DSA)

- ① Vygeneruje se otisk (hash)  $H_M$  zprávy pevně stanovené délky (např. 160 nebo 256 bitů).
- ② Podpis zprávy  $S_A(H_M)$  je vytvořen (pomocí dešifrování) z tohoto hashe s nutností znalosti soukromého klíče podepisujícího.
- ③ Zpráva  $M$  (případně zašifrovaná veřejným klíčem příjemce) je spolu s podpisem odeslána.

## Ověření podpisu

- ① K přijaté zprávě  $M$  se (po jejím případném dešifrování) vygeneruje otisk  $H'_M$
- ② S pomocí veřejného klíče (deklarovaného) odesílatele zprávy se rekonstruuje původní otisk zprávy  $V_A(S_A(H_M)) = H_M$ .
- ③ Oba otisky se porovnají  $H_M = H'_M$ ?

## Příklad

- **Generování klíče.** Alice vybere prvočísla  $p = 2357$ ,  $q = 2551$ , a vypočte  $n = p \cdot q = 6012707$  a  $\varphi(n) = (p - 1)(q - 1) = 6007800$ . Alice zvolí  $e = 3674911$  a pomocí Euklidova algoritmu vypočte  $d = 422191$  ( $e \cdot d \equiv 1 \pmod{\varphi(n)}$ ). Soukromý klíč Alice je  $d$ , veřejný pak  $(n, e)$ .
- Chce-li Bob poslat Alici zprávu  $m = 5234673$ , pomocí modulárního umocňování vypočte

$$c \equiv m^e \equiv 5234673^{3674911} \equiv 3650502 \pmod{n},$$

a tu odešle Alici.

- Alice zprávu dešifruje díky výpočtu

$$c^d \equiv 3650502^{422191} \equiv 5234673.$$

# Diffie-Hellman key exchange, ElGamal

*Whitfield Diffie, Martin Hellman* (1976; M. Williamson, GCHQ - 1974)

Výměna klíčů pro symetrickou kryptografií bez předchozího kontaktu (tj. nahrazení jednorázových klíčů, kurýrů s kufříky, ...).

- Dohoda stran na **cyklické grupě**  $G$  a jejím generátoru  $g$  (veřejné)
- Alice vybere náhodné  $a$  a pošle  $g^a$
- Bob vybere náhodné  $b$  a pošle  $g^b$
- Společným klíčem pro komunikaci je  $g^{ab}$ .

## Poznámka

- Problém diskrétního logaritmu (DLP)
- Nezbytná autentizace (*man in the middle attack*)

Z protokolu DH na výměnu klíčů odvozen šifrovací algoritmus ElGamal:

- Alice zvolí cyklickou grupu  $G$  spolu s generátorem  $g$
- Alice zvolí **soukromý klíč**  $x$ , spočítá  $h = g^x$  a zveřejní **veřejný klíč**  $(G, g, h)$
- šifrování zprávy  $M$ : Bob zvolí náhodné  $y$  a vypočte  $C_1 = g^y$  a  $C_2 = M \cdot h^y$  a pošle  $(C_1, C_2)$
- dešifrování zprávy:  $OT = C_2 / C_1^x$

### Poznámka

Opět lze odvodit podepisování.

# Rabinův kryptosystém

Prvním veřejným kryptosystémem, k jehož prolomení je prokazatelně potřeba faktorizovat modul, je **Rabinův kryptosystém**, který si uvedeme ve zjednodušené verzi:

- každý účastník  $A$  potřebuje dvojici klíčů – veřejný  $V_A$  a soukromý  $S_A$
- generování klíčů:  $A$  zvolí dvě podobně velká prvočísla  $p, q \equiv 3 \pmod{4}$ , vypočte  $n = pq$ .
- $V_A = n, S_A = (p, q)$
- zašifrování numerického kódu zprávy  $M$ :  
$$C = C_e(M) \equiv M^2 \pmod{n}$$
- dešifrování šifry  $C$ : vypočtou se (čtyři) odmocniny z  $C$  modulo  $n$  a snadno se otestuje, která z nich byla původní zprávou.

Výpočet druhé odmocniny z  $C$  modulo  $n = pq$ ,  
kde  $p \equiv q \equiv 3 \pmod{4}$

- vypočti  $r = C^{(p+1)/4} \pmod{p}$  a  $s = C^{(q+1)/4} \pmod{q}$
- vypočti  $a, b$  tak, že  $ap + bq = 1$
- polož<sup>a</sup>  $x = (aps + bqr) \pmod{n}$ ,  $y = (aps - bqr) \pmod{n}$
- druhými odmocninami z  $C$  modulo  $n$  jsou  $\pm x$ ,  $\pm y$ .

---

<sup>a</sup>Uvědomte si, že jde vlastně o aplikaci Čínské zbytkové věty!

## Příklad

V Rabinově kryptosystému Alice zvolila za svůj soukromý klíč  $p = 23$ ,  $q = 31$ , veřejným klíčem je pak  $n = pq = 713$ . Zašifrujte zprávu  $m = 327$  pro Alici a ukažte, jak bude Alice tuto zprávu dešifrovat.

## Řešení

$c = 692$ , kandidáti původní zprávy jsou  $\pm 4 \cdot 23 \cdot 14 \pm 3 \cdot 31 \cdot 18 \pmod{713}$ .

# Eliptické křivky

Eliptické křivky jsou rovinné křivky o rovnici tvaru  $y^2 = x^3 + ax + b$  a zajímavé jsou tím, že na jejich bodech lze definovat operace tak, že výslednou strukturou bude komutativní grupa.

Přitom uvedené operace lze efektivně provádět a navíc se ukazuje, že mají (nejen) pro kryoprogramy zajímavé vlastnosti – srovnatelné bezpečnosti jako RSA lze dosáhnout již s podstatně kratšími klíči. Výhodou je rovněž velké množství použitelných eliptických křivek (a tedy grup různé struktury) podle volby parametru  $a, b$ .

Protokoly:

- ECDH - přímá varianta DH na eliptické křívce (jen místo generátoru se vybere *vhodný* bod na křívce)
- ECDSA - digitální podpis pomocí eliptických křivek.

## Poznámka

Problém diskrétního logaritmu (ECDLP).

Navíc se ukazuje, že eliptické křivky jsou velmi dobře použitelné při faktorizaci prvočísel.