

1. Introduction

Le codage de l'information concerne les méthodes de représenter l'information afin de pouvoir la manipuler, la stocker ou la transmettre. La méthode de codage est choisie suivant l'application voulue:

- * Le codage de source permet de faire la compression de données.
- * Le codage visuel (destiné au code barre, QR code, ...)
- * Le chiffrement est le codage qui permet à masquer ou brouiller une information.
- * Le codage de canal permet une représentation des données de façon à résister aux erreurs de transmission.

Dans ce cours on va s'intéresser à ce dernier codage où l'échange de l'information s'effectue par transmission d'un émetteur vers un récepteur à travers un canal.

Il est aussi possible de représenter plus simplement cette information par un signal.
Ce dernier codage fait naissance à la théorie des codes correcteurs qui est basée sur la redondance, en plus des corrections d'erreurs elle a des applications en cryptage, authentification, partage de secret et en stéganographie...

2. Codes Correcteurs

L'information est transformée en une grandeur mathématique: suite, vecteur, mot, polynôme, ...

Si $A = \{a_1, \dots, a_m\}$ est un alphabet (ensemble fini), un mot de longueur n est un élément de A^n . Ses composantes sont appelées lettres ou bits, quand $A = \{0, 1\}$ on parle de mots binaires.

Quand le canal est soumis à des perturbations, les bits du mot envoyé peuvent être modifiés.

En théorie des codes correcteurs l'idée de base est d'allonger le mot envoyé c'est à dire lui ajouter des bits (redondance) de sorte à appartenir à un ensemble C appelé code.

La redondance est conçue pour détecter ou corriger les erreurs.

Codes en blocs

Soit n un entier naturel et A un alphabet.

Un code en blocs C de longueur n est une partie de A^n :

$$C \subset A^n.$$

Il y a des codes où les mots ne sont pas de même longueur, citons les codes en treillis, codes convolutionnels...

Exemples:

a)* Soit $A = \{0, 1\}$, $C = \{001, 101, 111\}$ est un code en blocs binaire de longueur 3.

* Si $A = \{a, b, c\}$, $C = \{aa, ba, ac\}$ est un code en blocs de longueur 2.

b) Pour tout alphabet A , A^n est appelé code trivial, $C = \{\underbrace{aaa \dots a}_n : a \in A\}$ est dit code répétition de longueur n .

c) Codes contrôle de parité

Pour n fixé, aux n bits du message $m = a_1 \dots a_n$ on ajoute un bit supplémentaire qui est la somme $\sum_{i=1}^n a_i$.

$$a_i \in \mathbb{F}_2, m = a_1 \dots a_n \xrightarrow{\text{codage}} m' = a_1 \dots a_n (\sum_{i=1}^n a_i) \in C.$$

À la réception si la somme des bits de m' n'est pas nulle cela signifie qu'il y a au moins une erreur.

Exemple:

$C = \{000, 101, 011, 110\}$ est un code contrôle de parité de longueur 3.

d) Code ISBN (International Standard Book Number)

est un numéro qui permet d'identifier chaque livre publié. Le code ISBN à 10 chiffres est composé de 4 segments: A-B-C-D où

A identifie un groupe de codes pour un pays ou une zone linguistique.

B identifie l'éditeur de la publication.

C est un numéro d'ordre de l'ouvrage chez l'éditeur.

D est un nombre pour détecter les erreurs.

Le code ISBN 10 est une suite a_1, \dots, a_{10} tels que
 $a_i \in \frac{\mathbb{Z}}{11\mathbb{Z}} = \{0, 1, \dots, 10=x\}$ et $\sum_{k=1}^{10} k a_k \equiv 0 [11]$.

Exemple:

ISBN 1-58182-008-9 est le code de l'ouvrage :

James Reasoner, Manassas, Cumberland House (1999).

La première partie 1 concerne le groupe linguistique Anglais.

$$\sum_{k=1}^{10} k a_k = 1 \cdot 1 + 2 \cdot 5 + 3 \cdot 8 + 4 \cdot 1 + 5 \cdot 8 + 6 \cdot 2 + 7 \cdot 0 + 8 \cdot 0 + \\ 9 \cdot 8 + 10 \cdot 9 = 253 \equiv 0 [11].$$

Vu l'augmentation du nombre de publications électroniques, la capacité de numérotation du système ISBN 10 est devenue insuffisante, pour cela en Janvier 2007 la longueur a été étendue à 13 chiffres.

Distance de Hamming.

La distance de Hamming est utilisée en télécommunications pour compter le nombre de bits altérés dans la transmission d'un message de longueur fixée.

Définition:

Soit A un alphabet.

Si $x = (x_1, \dots, x_n)$ et $y = (y_1, \dots, y_n)$ sont deux éléments de A^n , la distance de Hamming entre x et y

Correspond au nombre de composantes pour lesquelles ces deux vecteurs diffèrent.

$$d(x, y) = \text{card} \{ i : x_i \neq y_i, 1 \leq i \leq n \}.$$

Distanse minimale:

Soit $C \subset A^n$ un code de longueur n , sa distance minimale de Hamming d_{\min} est définie par

$$d_{\min} = \min \{ d(x, y) : x, y \in C \text{ et } x \neq y \}.$$

Exemple:

$$\text{Soit } C = \{ a=1001, b=0101, c=0111 \}.$$

$$\text{On a } d(a, b) = 2, d(a, c) = 3, d(b, c) = 1$$

$$\text{Donc } d_{\min}(C) = 1.$$

Poids d'un vecteur

Soit $x \in A^n$, $x = (x_1, \dots, x_n)$, son poids $w(x)$ est le nombre de ses composantes non nulles:

$$w(x) = \text{card} \{ i : x_i \neq 0 \}.$$

Décodage

Soit un message $m = (x_1, \dots, x_k)$ de longueur k .

Soit C un code de longueur n , ($n > k$), pour coder m on le plonge dans C (par une application injective).

m codé devient $c = c_1 \dots c_n$ et il est envoyé par le canal, à la réception le mot reçu $\tilde{c} = \tilde{c}_1 \dots \tilde{c}_n$ est de longueur n , le nombre d'erreurs est exactement $d(c, \tilde{c})$.

Pour décoder et retrouver m on cherche le mot de C , le plus proche de \tilde{c} , ceci est possible si le nombre d'erreurs ne dépasse pas la capacité de correction e de C .

Définition :

On dit que $C \subset A^n$ corrige t erreurs si pour tout $x \in A^n$ il existe au plus $c \in C$ tel que $d(x, c) \leq t$.

On dit que C est de capacité e si C corrige e erreurs mais il ne corrige pas $e+1$ erreurs.

On montre que :

Si C est un code de distance minimale d , il détecte $d-1$ erreurs et sa capacité de correction est $e = \left[\frac{d-1}{2} \right]$ où $[x]$ est la partie entière de x .

Des détails supplémentaires seront donnés dans les prochaines sections.

3. Codes linéaires

Soit K un corps fini.

Définition :

On appelle code linéaire de longueur n tout sous-espace vectoriel C de K^n .

Si $\dim C = k$ et C est de distance minimale d on dit que C est un $[n, k, d]$ code sur K .

Donc si $|K| = q$ on note K par \mathbb{F}_q et on a

$$|C| = |\mathbb{F}_q|^{\dim C} = q^k.$$

Exemples :

a) Sur $\mathbb{F}_3 = \{0, 1, 2\}$, $C = \{00, 11, 22\}$ est $[2, 1, 2]$ code, il est engendré par 11 :

$$C = \{0 \cdot 11 = 00, 1 \cdot 11 = 11, 2 \cdot 11 = 22\}.$$

b) Le code contrôle de parité binaire de longueur n est défini par :

$$C = \{(x_1, \dots, x_n) \in \mathbb{F}_2^n : \sum_{i=1}^n x_i = 0\}.$$

$$\text{On a } x_n = \sum_{i=1}^{n-1} x_i \text{ et } \{e_1, \dots, e_{n-1}\} \text{ avec } e_i = (0, \dots, 1, \dots, 0)$$

est une base de C , d'où $\dim C = n-1$.

Propriétés :

a) si $x, y \in K^n$, on a $w(x-y) = w(x-y)$

$$\Leftrightarrow w(x) = 0 \Leftrightarrow x = 0$$

b) $w(x+y) \leq w(x) + w(y)$

c) $w(\lambda x) = w(x)$ pour $\lambda \in K - \{0\}$

b) Si C est un code linéaire, $d(C) = \min_{\substack{\text{min} \\ C}} \{w(x) : x \in C - \{0\}\}$

c) Inégalité de Singleton :

Soit C un $[n, k, d]$ code alors $d \leq n-k+1$.

Remarque :

quand $d = n-k+1$ le code C est dit MDS

(Maximum Distance Separable).

Description des codes par les matrices génératrices

En algèbre linéaire, il est connue l'image d'une application linéaire est un sous-espace vectoriel de l'espace d'arrivée et son noyau est un sous-espace vectoriel de l'espace de départ, ce qui permet d'associer à tout code linéaire C deux matrices :

une matrice génératrice G et une matrice de contrôle H .

Définition :

Soit C un code linéaire de longueur n , de dimension k sur K .

Une matrice génératrice G de C est une matrice $k \times n$ à éléments dans K dont les lignes forment une base de C .

Alors $C = \{(x_1, \dots, x_k)G : (x_1, \dots, x_k) \in K^k\}$.

Donc un $[n, k]$ code est complètement déterminé par une matrice $k \times n$ de rang k sur K .

Exemple:

Considérons le code contrôle de parité de longueur 3 :

$$C = \{000, 101, 011, 110\}.$$

Comme $\{101, 110\}$ est une base de C , $G = \begin{pmatrix} 1 & 0 & 1 \\ 1 & 1 & 0 \end{pmatrix}$ est une matrice génératrice de C d'ordre 3.

$$C = \{(x_1, x_2)G = (x_1 + x_2, x_2, x_1) : x_i \in \mathbb{F}_2\}.$$

A une autre base de C : $\{011, 100\}$ on associe une autre matrice génératrice $\begin{pmatrix} 0 & 1 & 1 \\ 1 & 1 & 0 \end{pmatrix}$, donc une matrice génératrice n'est pas unique.

Définition:

Un $[n, k]$ code est dit systématique si il admet une matrice génératrice de la forme $G = [I_k | A]$ où I_k est la matrice d'identité d'ordre k et $A \in M_{(k, n-k)}$.

Dans ce cas G est dite normalisée et une partie du mot codé coïncide avec le message.

Exemple: Soient $G = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \end{pmatrix}$ et $m = (x_1, x_2)$

$$\text{alors } mG = (\underbrace{x_1, x_2}_m, x_1 + x_2).$$

Description des codes par les matrices de contrôle

Soit C un $[n, k]$ code linéaire sur K .

on appelle matrice de contrôle de C , toute matrice H de type $(n-k) \times n$, de rang $n-k$ telle que

$$C = \{ x \in K^n : x \cdot {}^t H = 0 \} \text{ où } {}^t H \text{ est la transposée de } H.$$

Donc la matrice H contrôle l'appartenance d'un élément x au code C : $x \in C \iff x \cdot {}^t H = 0$

Remarque :

a) Soit C un code de matrice génératrice G et $H \in M_{n-k, n}(K)$, on montre que

$$H \text{ est une matrice de contrôle de } C \iff \begin{aligned} & 1) \text{ rang}(H) = n-k \\ & \text{et} \\ & 2) G \cdot {}^t H = 0 \end{aligned}$$

b) Pour un code systématique C de matrice normalisée $G = (F_k | A)$ il est possible de calculer une matrice de contrôle par $H = ({}^t A | -I_{n-k})$.

Exemple :

Soit le code binaire de matrice génératrice

$$G = \left(\begin{array}{ccc|cc} 1 & 0 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 1 \end{array} \right) \quad (\text{normalisée}).$$

Une matrice de contrôle H est donnée par $\left(\begin{array}{ccc|cc} 1 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 1 \end{array} \right)$.

Pour expliciter les éléments de C on calcule

$$(x_1, x_2, x_3) G = (x_1, x_2, x_3, x_1+x_2, x_1+x_3) \text{ avec } x_i \in \mathbb{F}_2.$$

dim $C = \{ 00000, 10011, 01010, 00101, 11011, 01111, 10110, 11100 \}$.

on peut retrouver les éléments de C en utilisant H :

$$(x_1, x_2, x_3, x_4, x_5) \in C \iff (x_1, x_2, x_3, x_4, x_5) \begin{pmatrix} 1 & 1 \\ 1 & 0 \\ 0 & 1 \\ 1 & 0 \\ 0 & 1 \end{pmatrix} = (0, 0)$$

en résolvant le système

$$\begin{cases} x_1 + x_2 + x_4 = 0 \\ x_1 + x_3 + x_5 = 0 \end{cases}$$

on obtient $x_1 = x_3 + x_5$ et $x_2 = x_3 + x_4 + x_5$

et $C = \{ (x_3 + x_5, x_3 + x_4 + x_5, x_3, x_4, x_5) ; x_3, x_4, x_5 \in \mathbb{F}_2 \}$.

Master CS

Département d'informatique

TD 1 : Théorie des codes linéaires

EX:1

a) Combien y a-t-il de codes binaires de longueur 3 ?

b) Combien y a-t-il de codes sur \mathbb{F}_q et de longueur n ?

EX:2

Montrer que la distance de Hamming vérifie :

$$a) d(x, y) = d(y, x)$$

$$b) x = y \iff d(x, y) = 0$$

$$c) d(x, y) \leq d(x, z) + d(z, y)$$

Pour $x, y, z \in K^n$.

EX:3

Calculer la distance minimale d pour les codes suivants :

a) $C = A^n$, (A étant un alphabet).

b) C code répétition sur A de longueur n .

EX:4

Soit $K = \mathbb{F}_q$ un corps fini de cardinal q .

a) Combien y-a-t-il de mots de K^n de poids m , $m \leq n$?

distinguer les deux cas : $q = 2 \rightarrow q \neq 2$.

b) Expliquer ces nombres pour $q = 2$, $n = 2k$, $m = 2$,
les nombres obtenus sont appelés nombres hexagonaux.

EX:5

On considère les codes binaires suivants:

$$C_1 = \{011, 110, 101, 000\}$$

$$C_2 = \{1100, 1010, 1001\}$$

$$C_3 = \{00000, 10101, 01111, 11010\}$$

Dire dans chaque cas si le code est linéaire?

EX:6

Soit A un alphabet de cardinal q et a un élément fixe de A .

Posons $C = \left\{ c = \underbrace{x \dots x}_d \underbrace{a \dots a}_{n-d} : x \in A \right\}$

a) Calculer la distance minimale de C et $|C|$.

b) Si $A = \mathbb{F}_q$ est un corps fini, C est-il linéaire?

EX:7 Soit la matrice binaire

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

1) Déterminer $C = \{(x_1, x_2, x_3) G : x_i \in \mathbb{F}_2\}$

et vérifier que C est linéaire.

2) Déterminer sa dimension, son cardinal et sa distance minimale.

EX:8

Considérons C le code ISBN (10).

a) Montrer que C est linéaire et préciser sa matrice de contrôle.

b) Déterminer ses paramètres: n, k, d .

EX: 9

Soit C un code contrôlé de parité de longueur n :

$$C = \left\{ (x_1, \dots, x_n) \in \mathbb{F}_2^n : \sum_{i=1}^n x_i = 0 \right\}$$

- Déterminer une matrice de contrôle de C ,
- Calculer les paramètres de C : n, k, d .

EX: 10

Soit C un code linéaire de longueur n sur \mathbb{F}_q .

- Vérifier que si $x, y \in C$, $d(x, y) = w(x - y)$.
- Montrer $d_{\min} = w_{\min}$.
- Comparer le nombre de possibilités dans le calcul de la distance minimale par les deux méthodes:

$$d_{\min} \rightarrow w_{\min}$$

EX: 11

Soit C un code linéaire sur \mathbb{F}_3 de matrice génératrice

$$G = \begin{pmatrix} 1 & 1 & 2 & 0 \\ 2 & 1 & 0 & 2 \end{pmatrix}$$

- Écrire les éléments de C .
- C est-il MDS?
- Peut-on calculer une matrice de contrôle de C .