

# Codes correcteurs

## Contents

<b>I</b>	<b>Généralités</b>	<b>2</b>
<b>1</b>	<b>Transmission de messages</b>	<b>3</b>
<b>2</b>	<b>Le NIR</b>	<b>3</b>
<b>3</b>	<b>Le code de répétition</b>	<b>4</b>
<b>4</b>	<b>La notion de codage</b>	<b>4</b>
<b>5</b>	<b>La matrice génératrice</b>	<b>5</b>
<b>6</b>	<b>La distance de Hamming</b>	<b>6</b>
6.1	Le poids . . . . .	6
6.2	Loi suivie par $w(e)$ . . . . .	6
6.3	Propriété . . . . .	6
<b>7</b>	<b>La matrice de contrôle</b>	<b>7</b>
7.1	La matrice de contrôle . . . . .	7
7.2	La distance du code . . . . .	8

<b>8</b>	<b>Les codes parfaits</b>	<b>8</b>
	<b>II</b>	
	<b>Le code de Hamming(7, 4, 3)</b>	<b>8</b>
<b>9</b>	<b>La matrice de contrôle</b>	<b>9</b>
<b>10</b>	<b>La correction</b>	<b>9</b>
	10.1 Un rappel . . . . .	9
	10.2 Le syndrome . . . . .	9
	10.3 Que représente le syndrome ? . . .	10
<b>11</b>	<b>La matrice génératrice</b>	<b>10</b>
<b>12</b>	<b>Les codes cycliques</b>	<b>11</b>
	12.1 Définition . . . . .	11
<b>13</b>	<b>Retour au code de Hamming</b>	<b>12</b>
<b>14</b>	<b>La majoration de Singleton</b>	<b>12</b>
<b>15</b>	<b>Le code de Golay</b>	<b>13</b>

# Part I

## Généralités

### 1 Transmission de messages

Entre téléphones, ordinateurs, clés USB, CD, sondes spatiales...

#### Exemple de message

That's one small step for a man, a giant leap for mankind

#### Un premier exercice

Message reçu :

“ les plofs, ils ne fcnt riin, ils sont touuuurs en vacancts ”.

Trouver l'original.

#### Un deuxième

0660124983

#### Différence entre les deux ?

Que faire pour corriger les numéros de téléphone erronés ?

#### Le schéma

$$m \xrightarrow{\text{codage}} c \xrightarrow{\text{transmission}} c' \xrightarrow{\text{correction}} c \xrightarrow{\text{décodage}} m$$

#### L'erreur

On note

$$e = c' - c$$

C'est l'erreur causée par la transmission.

### 2 Le NIR

Le numéro d'inscription au répertoire (numéro de sécurité sociale) :

1 chiffre pour le sexe, 2 pour l'année de naissance... .

Au total, un nombre  $n$  à 13 chiffres, et une clé  $q$  à 2 chiffres.

### La clé

C'est l'opposé de  $n$  modulo 97 :

$$n + q \equiv 0 [97]$$

La clé peut servir à déceler une erreur, pas à corriger.

## 3 Le code de répétition

### Codage

Chaque bit est répété trois fois ; pourquoi pas deux fois ?

$$m = 1 \rightarrow c = 111$$

$$m = 0 \rightarrow c = 000$$

### Correction

$c' = 111$ , ou 110, ou 101, ou 011  $\rightarrow c = 111$

### Le CBS

(canal binaire symétrique) : on fait l'hypothèse suivante :

Chaque bit a une probabilité  $p \ll 1$  d'être modifié par la transmission.

### En utilisant le code de répétition

Pour chaque bit, probabilité de ne pas être corrigé correctement :

$$p^3 + \binom{3}{2}p^2(1-p) = 3p^2 - 2p^3$$

Par exemple, si 1 sur 1000 est incorrect ( $p = 10^{-3}$ ), seulement 3 sur un million avec codage et correction.

## 4 La notion de codage

On suppose  $K = \mathbb{F}_2 = \mathbb{Z}/2\mathbb{Z}$ ,  $1 \leq k \leq n$  ; on note  $E = K^n$ .

Un codage est une application  $f$  de  $K^k$  dans  $E$  *injective*.

$$R = \frac{k}{n}$$

est appelé taux de transmission ou rendement (rate).

### Codage systématique

On dit que le codage est systématique si  $m$  est toujours un préfixe de

$$c = f(m)$$

Le codage est donc obtenu en ajoutant  $n - k$  bits dits de redondance au message  $m$ .

### Les codes linéaires

Dans la suite, on supposera  $f$  linéaire.

On note  $C$  l'image de  $f$  ; c'est un SEV de  $E$  de dimension  $k \geq 1$  : l'ensemble des messages codés ;  $k$  est la longueur du message  $m$ ,  $n$  est la longueur de  $c = f(m)$ .

## 5 La matrice génératrice

Notons  $(e_1, \dots, e_k)$  la base canonique de  $K^k$ .

On peut exprimer le codage à l'aide d'une matrice  $G$ , dite matrice génératrice. Les lignes de  $G$  sont les

$$L_i = f(e_i)$$

Elles constituent une base de  $C$  ; le codage  $f$  :

$$m \rightarrow m.G = c$$

Pour le code de répétition :  $n = 3, k = 1$ .  $G = [ 1 \ 1 \ 1 ]$ .

### Le code de répétition sur 2 bits

Chaque mot est répété trois fois ;  $n = 6, k = 2$  ; codage :

$$m = 10 \rightarrow c = 101010$$

$$m = 00 \rightarrow c = 000000$$

$$m = 01 \rightarrow c = 010101$$

La matrice génératrice :

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

### Le codage systématique

Dans le cas précédent, la matrice  $G$  est de la forme

$$[I_k, Q]$$

On peut toujours écrire

$$G = [A, B]$$

avec  $A$  carrée de taille  $k$  ; si  $A$  est inversible, on peut se ramener à un codage systématique, sans changer le code  $C$ .

Dans le cas général, ce n'est possible qu'après permutation des colonnes, donc des variables.

## 6 La distance de Hamming

### 6.1 Le poids

Soit  $x \in E$  ; on appelle poids de  $x$ , noté  $w(x)$ , le nombre de bits non nuls dans  $x$  ; on vérifie aisément que

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

#### La distance

On pose

$$d(x, y) = w(x - y)$$

On définit ainsi une distance sur  $E$ .

Pour un code  $C$ , on appelle distance minimum du code, notée  $d(C)$ , ou  $d$ , la plus petite distance entre deux éléments distincts de  $C$ .

#### Remarque

$C$  étant un SEV,  $d(C)$  est aussi le minimum des poids des éléments non nuls de  $C$ .

### 6.2 Loi suivie par $w(e)$

Le nombre de bits transmis incorrectement suit une loi, laquelle ?

#### Réponse

$$w(e) \sim B(n, p)$$

### 6.3 Propriété

Les boules fermées de centre dans  $C$  de rayon  $t$  sont disjointes si et seulement si  $2t + 1 \leq d$  ; dans ce cas,  $C$  peut corriger  $t$  erreurs.

Plus précisément, cela signifie que si l'on est sûr qu'il y a au plus  $t$  erreurs au cours de la transmission, alors on peut retrouver  $c$  à partir de  $c'$ .

### Indication

Supposons  $d \leq 2t$ .

Supposons par exemple l'existence de  $c \in C \setminus \{0\}$  tel que  $c[2t:]$  soit nul. On construit alors  $x$  en remplaçant  $c[:t]$  par des zéros.

On constate que  $x$  est dans l'intersection des boules de rayon  $t$ , de centres  $0$  et  $c$ .

### Exemple

Pour les codes de répétition,  $d = 3$  ; ce code permet de corriger une erreur.

### Le cardinal d'une boule

Dans  $E = K^n$ , le cardinal d'une boule de rayon  $t$  est

$$\sum_{k=0}^t \binom{n}{k}$$

Plus généralement, si le corps est de cardinal  $q$  :

$$\sum_{k=0}^t \binom{n}{k} (q-1)^k$$

## 7 La matrice de contrôle

### Rappel

Les lignes d'une matrice donnent un système d'équations du noyau.

### 7.1 La matrice de contrôle

$C$  étant de dimension  $k$  dans  $E = K^n$ , on peut aussi le décrire par  $n - k$  équations indépendantes :

$$C = \ker H$$

où  $H \in M_{n-k,n}(K)$ , de rang  $n - k$ .

On dit que  $H$  est une matrice de contrôle ; on notera  $H_1, \dots, H_n$  ses colonnes.

En résumé

$$c \in C \iff H.c^T = 0$$

### Pour le code de répétition sur 2 bits

$x_1 = x_3, x_2 = x_4, x_1 = x_5, x_2 = x_6$  ; ce qui équivaut à  $H.X = 0$  avec

$$H = \begin{bmatrix} 1 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 \end{bmatrix}$$

### Remarque

Si  $G = [ I_k \quad Q ]$ , une possibilité pour  $H$  est  $[ -Q^T \quad I_{n-k} ]$ .

## 7.2 La distance du code

Sur l'exemple,  $c = (1, 0, 1, 0, 1, 0) \in C = \ker H$ , ce qui se traduit pour  $H$  par

$$H_1 + H_3 + H_5 = 0$$

Plus généralement,  $d$  est le plus petit nombre de colonnes de  $H$  formant une famille liée.

## 8 Les codes parfaits

On dit qu'un code est parfait s'il existe un entier  $t \geq 1$  tel que les boules fermées de rayon  $t$  et de centre dans  $C$  constituent une partition de  $E$ .

### Exercice

Montrer que dans ce cas

$$d = 2t + 1$$

### Indication

Utiliser un mot  $x$  de poids  $t + 1$ .

### Codes parfaits avec $t = 1$ et $d = 3$

Cardinal d'une boule :  $n + 1$  ; nombre de boules :  $2^k$  ; nécessairement :

$$2^n = (n + 1) 2^k$$

Donc  $n = 2^{n-k} - 1$ , soit 3, 7, 15...

Pour  $n = 3$ , on retrouve le code de répétition.

## Part II

# Le code de Hamming(7, 4, 3)

## 9 La matrice de contrôle

On cherche à décrire le code à l'aide de la matrice de contrôle  $H$ .

Les paramètres :  $n = 7$ ,  $n - k = 3$ ,  $k = 4$ ,  $d = 3$ ,  $R = \frac{4}{7}$

On cherche donc une matrice à 3 lignes et 7 colonnes non nulles *distinctes* ;  
on n'a guère le choix :

$$H = \begin{bmatrix} 1 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix}$$

Le code obtenu est appelé code de Hamming de type (7, 4, 3).

On obtient des codes équivalents en permutant les colonnes.

$$\begin{cases} x_1 + x_3 + x_5 + x_7 = 0 \\ x_2 + x_3 + x_6 + x_7 = 0 \\ x_4 + x_5 + x_6 + x_7 = 0 \end{cases}$$

## 10 La correction

Dans le cas de la matrice

$$H = \begin{bmatrix} 1 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix}$$

on va voir que la correction est particulièrement simple.

### 10.1 Un rappel

Soit  $M$  une matrice à  $p$  lignes et  $q$  colonnes :  $M \in M_{p,q}(K)$ .

Soit  $E_j = (0, \dots, 0, 1, 0, \dots)^T$  la  $j$ -ième colonne canonique de taille  $q$ .

Que représente  $M.E_j$ ?

### Réponse

La  $j$ -ième colonne de  $M$ .

### 10.2 Le syndrome

Notons  $e = c' - c$  : l'erreur ; on suppose  $w(e) \leq 1$ .

On appelle syndrome :

$$s = H.e^T$$

En détail :

$$s = \begin{bmatrix} e_1 + e_3 + e_5 + e_7 \\ e_2 + e_3 + e_6 + e_7 \\ e_4 + e_5 + e_6 + e_7 \end{bmatrix}$$

On ne connaît pas  $e$ , mais on connaît  $s$ , car  $H.c^T = 0$ , donc

$$s = H.(c' - c)^T = H.(c')^T$$

### La correction

$w(e) \leq 1$  ; par exemple, si  $e = (0, 0, 1, 0, 0, 0, 0)$  :

$$s = H.e^T = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$$

Plus généralement :

Si l'erreur porte sur le  $j^{\text{ième}}$  bit :  $e^T = E_j$ .

Donc  $s = H.E_j = H_j$  : c'est la  $j^{\text{ième}}$  colonne de  $H$ .

En résumé, le syndrome est l'écriture en base 2 de la position de l'erreur.

Et s'il n'y a pas d'erreur ?

Dans ce cas,  $s = 0$ .

### 10.3 Que représente le syndrome ?

Il existe une base de  $E$  ( $u_1, \dots, u_n$ ) dont les  $k$  premiers vecteurs constituent une base de  $C$ , dans laquelle le syndrome est constitué des  $n - k$  dernières coordonnées de  $c'$ , ou de  $e$ .

$C$  est défini dans cette base par

$$y_{k+1} = \dots = y_{n-1} = y_n = 0$$

## 11 La matrice génératrice

La matrice  $H$  définit le code  $C$ . Evidemment,  $C$  ne possède pas une base unique.

On peut choisir

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

## 12 Les codes cycliques

### 12.1 Définition

Soit

$$T : (x_0, \dots, x_{n-1}) \rightarrow (x_{n-1}, x_0, \dots, x_{n-2})$$

$T$  est évidemment un endomorphisme de  $E = K^n$  ; un code  $C$  est dit cyclique s'il est invariant par  $T$ . Exemples : les codes de répétition.

#### Représentation à l'aide de polynômes

Il est commode d'identifier  $E = K^n$  à  $K_{n-1}[X]$  et  $(p_0, \dots, p_{n-1})$  à

$$P = p_0 + p_1X + \dots + p_{n-1}X^{n-1}$$

Avec ces notations :

$$T(P) = XP - p_{n-1}(X^n - 1)$$

C'est donc le reste de la division euclidienne de  $XP$  par  $X^n - 1$ .

#### Passage à l'anneau quotient

les notations se simplifient si on remplace  $K[X]$  par l'anneau quotient

$$A = K[X] / (X^n - 1)$$

$T$  s'écrit alors  $T : P \rightarrow X.P$  ; un SEV est stable par  $T$  si et seulement si c'est un idéal de  $A$  ; c'est l'ensemble des multiples d'un polynôme  $g$ , appelé générateur, qui divise  $X^n - 1$ .

#### Exemple : le code de répétition

$E = K^3$  ; un diviseur de  $X^3 - 1$  est  $g = X^2 + X + 1$  ; rappelons que

$$G = \begin{bmatrix} 1 & 1 & 1 \end{bmatrix}, H = \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & 1 \end{bmatrix}$$

#### Un codage systématique

On cherche une matrice génératrice de la forme  $G = [A, I_k]$  ; la ligne  $i$  représente un polynôme  $P_i$  qui est multiple de  $g$ , et qui est de la forme

$$X^{n-k+i-1} - R_i$$

avec  $\deg(R_i) < n - k$  ;  $R_i$  est donc le reste de la division euclidienne de  $X^{n-k+i}$  par  $g$  ; le codage d'un polynôme  $P$  est donc :

$$P \rightarrow (-R, P)$$

où  $R$  est le reste de la division euclidienne de  $X^{n-k}.P$  par  $g$ .

### 13 Retour au code de Hamming

Dans  $\mathbb{F}_2[X]$  :

$$X^7 - 1 = (X + 1)(X^3 + X + 1)(X^3 + X^2 + 1) = (X^3 + X + 1)(X^4 + X^2 + X + 1)$$

Choisissons  $g = 1 + X + X^3$  ; on obtient

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

Comment trouver une matrice de contrôle ?

#### La matrice de contrôle

Soit  $C$  un code cyclique, de polynôme générateur  $g$  ; soit  $h$  tel que

$$X^n - 1 = g.h$$

Une matrice de contrôle  $H$  est obtenue à partir du polynôme réciproque  $\tilde{h}$  de  $h$  ; ici :

$$h = 1 + X + X^2 + X^4, \tilde{h} = 1 + X^2 + X^3 + X^4$$

$$H = \begin{bmatrix} 1 & 0 & 1 & 1 & 1 & 0 & 0 \\ 0 & 1 & 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 0 & 1 & 1 & 1 \end{bmatrix}$$

On retrouve un code de Hamming.

### 14 La majoration de Singleton

$$k + d \leq n + 1$$

On dit que le code est MDS (maximum distance separable) s'il y a égalité ; pour les codes de répétition,  $d = 3$ ,  $n = 3k$  ; donc MDS si et seulement si  $k = 1$  et  $n = 3$ .

#### Démonstration

On introduit  $E'$ , l'ensemble des éléments  $x$  de  $E$  tels que

$$x_d = x_{d+1} = \dots = x_n = 0$$

On constate que  $C \cap E' = \{0\}$ .

### Autre forme

$$d \leq 1 + n(1 - R)$$

Donc pour augmenter la capacité de correction, à taux de transmission donné, il faut nécessairement augmenter  $n$ .

### Remarque

Il n'y a guère de codes linéaires MDS intéressants si  $K = \mathbb{F}_2$  ; voir les codes de Reed-Solomon.

## 15 Le code de Golay

On peut remarquer que

$$\binom{23}{0} + \binom{23}{1} + \binom{23}{2} + \binom{23}{3} = 2^{11} = 2048$$

On peut donc conjecturer l'existence d'un code parfait de type  $(23, 12, 7)$  :

$n = 23, k = 12, d = 7, t = 3, R = \frac{12}{23}$  ; un tel code existe : le code binaire de Golay (voir codes cycliques).

### Comparaison avec le code de répétition

On suppose que l'on veut transmettre  $12N$  bits ; pour chaque paquet de 3 bits, la probabilité d'une erreur non corrigée est d'environ  $3p^2$ .

Espérance du nombre d'erreurs :  $36N.p^2$

### Avec le code de Golay

Pour chaque paquet de 23 bits, la probabilité d'une erreur non corrigée est d'environ  $8855.p^4$

Espérance du nombre de blocs incorrects :

$$8855.N.p^4$$

Moins d'erreurs avec un taux de transmission supérieur ; remarquons que ce n'est vrai que si  $p \ll 1$ .

### Le code de Golay ternaire

$$1 + 2\binom{11}{1} + 4\binom{11}{2} = 3^5 = 243$$

Il existe un code de type  $(11, 6, 5)$  sur le corps  $\mathbb{F}_3$  (code ternaire).