


I Codes correcteurs d'erreurs

(communication internet (fibre ou satellite), lecture d'un CD)

Idee generale: La transmission d'un signal n'est pas totalement fiable, probleme de "bruit".
On veut etre capable de detecter des erreurs, voire de les corriger.



Def: (x_1, \dots, x_n) "mot de code"
 $\frac{k}{n}$ taux de transmission (partie informative du signal envoye)
 $r = n - k$ redondance

Question: Peut-on obtenir $(v_1, \dots, v_k) = (u_1, \dots, u_k)$ si un certain nombre de y_j sont $\neq x_j$?

methode: Exploiter une structure lineaire (voire algebrique)

1) 3 Exemples historiques simples:

a) "Test de parite"

Pour un ~~signal~~ $(u_1, \dots, u_k) \in \mathbb{F}_2^k$, on ~~envoie~~ envoie $(u_1, \dots, u_k, \sum_{i=1}^k u_i)$
 c'est la redondance est de 1.

Pour $k=6$, 101011, on a $x_7 = 0$

* Si il y a une erreur dans le signal recue (element de \mathbb{F}_2^7), on le detecte car alors $y_7 \neq \sum_{i=1}^6 y_i$ mais on ne sait pas localiser (ni corriger l'erreur).

* Si il y a 2 erreurs dans le signal recue, on a $y_7 = \sum_{i=1}^6 y_i$. Et le destinataire ne peut pas detecter qu'il n'a pas recue le bon message.

b) le code a repetition

On repete chaque bit 3 fois.

Ex: $(u_1, u_2, u_3, u_4) \mapsto (u_1, u_1, u_1, u_2, u_2, u_2, u_3, u_3, u_4, u_4, u_4)$

"decodage majoritaire"

Pour chaque groupe de 3 bits, il y a un element ~~present~~ 2 ou 3 fois, c'est celui qu'on choisit.

Taux de transmission = $\frac{1}{3}$.

On peut corriger 1 erreur mais pas toujours 2.

1) Premier code de Hamming

4 bits d'information, 5 bits de redondance, "longueur" = 4 + 5 = 9.

u_1	u_2	$u_1 + u_2$
u_3	u_4	$u_3 + u_4$
$u_1 + u_3$		$u_2 + u_4$
$u_1 + u_4$		$\sum u_i$

Ex: 1101 \rightarrow

1	1	0
0	1	1
1	0	1

 \rightarrow 110011101

Supposons que le destinataire reçoit comme 5^e bit 0 au lieu de 1

(élément souligné = erreur)

1	1	0
0	0	1
1	0	1

la 2^e et la 2^e colonne ont un souci.

En supposant qu'il n'y a 1 seule erreur dans la transmission, l'erreur est corrigable.

Taux de transmission: $\frac{4}{9}$ ($\rightarrow \frac{1}{3}$ du code à répétition)

On peut corriger une erreur, et en détecter 3.

Ex: avec le même signal initial,

si on reçoit

1	1	0
0	0	1
1	0	0

, on peut qu'il y a ≥ 2 erreurs, mais on ne sait pas où (pourrait être l'initial ou

1	1	0
0	0	0
1	1	0

)

si on reçoit

1	1	0
0	0	0
1	0	0

, le système de correction croit qu'il y a 1 erreur (et non 3) et corrige faussement en

1	1	0
0	0	0
1	1	0

si on reçoit

0	0	0
1	0	1
1	0	1

, le destinataire croit avoir reçu le bon message

Idee: Améliorer cette idée en utilisant de l'algèbre linéaire.

On va définir un code de Hamming avec $k=4$ (i.e. $r=3$ et $taux = \frac{4}{7} > \frac{1}{2}$)
 $n=7$
qui corrige 1 erreur et en détecte 2.

* Formaliser ses idées en mettant ces notions de distance, de code, de correction dans un contexte mathématique général.

2) Théorie des codes correcteurs linéaires

On travaille sur un corps fini \mathbb{F}_q (très souvent $q=2$ ou une puissance de 2)

Def * Pour un vecteur (pensé ensuite comme un vecteur ligne) $x \in \mathbb{F}_q^n$, on définit son poids $w(x)$ par son nombre de composantes non nulles.
D'où $0 \leq w(x) \leq n$.

Prop L'application $d_H : \mathbb{F}_q^n \times \mathbb{F}_q^n \rightarrow \mathbb{N}$, $(x, y) \mapsto w(x-y)$ est une distance (dite "de Hamming") sur \mathbb{F}_q^n .

Def * On appelle code linéaire de longueur n un sous-espace vectoriel C de \mathbb{F}_q^n .

* les vecteurs (x_1, \dots, x_n) de C sont les motus du code.
Il y a q^k motus de code si C est de dimension k .

* la distance minimale du code C est définie par

$$d = \min_{x \in C \setminus \{0\}} w(x) = \min_{\substack{x \neq y \\ x, y \in C}} w(x-y)$$

* On dit alors que C est un $[[n, k, d]]$ -code (ou un code de paramètres $[[n, k, d]]$)

Rem On peut définir le poids complet d'un ~~code~~ vecteur par la collection:

$$(w_k(x) = \{i \in [1, n], x_i = k\})_{k \in \mathbb{F}_q}$$

$$\text{Alors } w(x) = \sum_{k \in \mathbb{F}_q \setminus \{0\}} w_k(x)$$

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

(~~Intuition~~ intuition de cette prop: la distance est plus petite que la redondance + 1)

Preuve Soit V le sev de \mathbb{F}_q^n formé des vecteurs dont les $k-1$ dernières composantes sont 0.
C'est un sev de dimension $n-k+1$.

Comme $\dim C + \dim V = n+1$, on a $C \cap V \neq \{0\}$.
~~Soit~~ $\exists x \in C \cap V \setminus \{0\}$, $w(x) \leq n-k+1$.
Comme d est le minimum des $w(x)$ où $x \in C \setminus \{0\}$, on a $d \leq w(x) \leq n-k+1$.

Prop: Soit C un $[[n, k, d]]$ -code.
Les boules (pour la distance de Hamming) fermées et centrées sur les motus du code C et de rayon $t = \lfloor \frac{d-1}{2} \rfloor$ sont 2 à 2 disjointes.

Preuve: Supposons qu'il existe un $y \in \mathbb{F}_q^n$ dans 2 boules, c'à d $y \in \bar{B}(x_1, t) \cap \bar{B}(x_2, t)$ où $x_1, x_2 \in C$.
Alors $d(x_1, x_2) \leq d(x_1, y) + d(x_2, y) \leq 2t < d$.
D'où $x_1 = x_2$.

Rem: Cette propriété signifie que si le destinataire reçoit un message $x \in \mathbb{F}_q^n$ et qu'on suppose qu'il y a moins de t erreurs dans la transmission, alors x est dans (au plus) une boule de la forme $\bar{B}(c, t)$ pour $c \in C$.
Ce mot c est alors le message que l'expéditeur voulait transmettre.

Q: En pratique, pour un $x \in \mathbb{F}_q^n$ reçu comment retrouver le c initial?
Méthode naïve: "table des syndromes" (cf. matrice de contrôle).

Inégalité de Hamming:

En notant $r = n - k$ (la redondance) et $t = \lfloor \frac{d-1}{2} \rfloor$, on a:

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

" q^t

nombre d'éléments d'une boule fermée de rayon t .

(en multipliant par q^k (= nombre de mots du code), on obtient que le nombre d'éléments de \mathbb{F}_q^n dans les boules disjointes est inférieur au cardinal de \mathbb{F}_q^n)

Ex: Pour $q=2$ et $t=1$, on a $1 + 4r \leq 2^n$, d'où $r \geq 3$ et $k=4$.

Ceci signifie que la redondance est d'au moins 3, donc que le taux de transmission est $\leq \frac{4}{7}$.

On verra par la suite l'exemple d'un tel code atteignant cette borne: le code de Hamming binaire (qui sera une amélioration du 1^{er} code de Hamming).

Def: On dit qu'un code est parfait si l'inégalité de Hamming est une égalité. Cette condition est équivalente à:

$$\mathbb{F}_q^n = \bigcup_{c \in C} \{x \in \mathbb{F}_q^n, d(c, x) \leq t\}$$

Def Une matrice de contrôle d'un $[n, k, d]$ -code est une matrice $H \in M_{n-k, n}(\mathbb{F}_q)$ (ou de parité)
 tq $\forall x \in C, H \cdot^t x = 0$ (i.e $C = \text{Ker } H$)

H est la matrice génératrice du code dual $C^\perp = \{x' \in \mathbb{F}_q^n, \forall x \in C, \langle x, x' \rangle = 0\}$
 pour la forme bilin sym non dég : $\langle \cdot, \cdot \rangle : \mathbb{F}_q^n \times \mathbb{F}_q^n \rightarrow \mathbb{F}_q$
 $(x, y) \mapsto \sum x_i y_i$

En particulier, H est de rang $n-k$ et $H \cdot^t G = 0$

Prop Pour G matrice génératrice de C s'écrivant $G = \begin{pmatrix} I_k & M \end{pmatrix}$ avec $M \in M_{k, n-k}(\mathbb{F}_q)$,
 une matrice de contrôle de C est $H = \begin{pmatrix} -M^t & I_{n-k} \end{pmatrix}$.

Preuve : ~~On veut s'orthogonaliser~~ On note $M = (v_{ij})$
 $(x_1, \dots, x_{k+n}) \in C \Leftrightarrow \sum x_i v_{ij} = 0 \forall j \in [1, n-k]$
 $\Leftrightarrow \forall j \in [1, n-k], (x_1, \dots, x_{k+n})$ orthogonal à la j -e ligne de H .
 D'où $C \subseteq \text{Ker } H$.
 Or les dimensions sont les mêmes.

Ex : Pour H_3 , où $G = \begin{pmatrix} 1 & 1 & 1 & 0 \\ 1 & 0 & 1 & 1 \\ 1 & 0 & 1 & 1 \end{pmatrix}$, on a $H = \begin{pmatrix} 1 & 1 & 0 & 1 & | & 1 & 0 & 0 \\ 1 & 0 & 1 & 1 & | & 0 & 1 & 0 \\ 0 & 1 & 1 & 1 & | & 0 & 0 & 1 \end{pmatrix}$

Obs : * chaque colonne de H correspond à un nombre binaire entre 1 et $2^3 - 1 = 7$
 On peut définir H_m par sa matrice de contrôle $m \times (2^m - 1)$ dont les colonnes sont les éléments non nuls de $(\mathbb{F}_2)^m$
 * Le plus petit nombre de colonnes linéairement dépendantes dans H est 3 et la distance de C est 3 .

Prop Soit C un $[n, k, d]$ -code et H matrice de contrôle de C .
 Alors d est le plus petit nombre de colonnes linéaires dépendantes dans H .

Preuve * Supp que tout ensemble de s colonnes de H est libre sur \mathbb{F}_q .
 Alors pour tout x de $C \setminus \{0\}$, on a $H \cdot^t x = 0$, c'ad $\sum x_j c_j(H) = 0$
 d'où $w(x) > s$ et donc $d > s$ (car C fini).
 * Réciproquement, supposons $\exists s$ colonnes de H lin dépendantes sur \mathbb{F}_q .
 Donc $\exists x = (x_1, \dots, x_n) \in \mathbb{F}_q^n \setminus \{0\}$ avec $w(x) \leq s$ et $\sum_{j=1}^n x_j c_j(H) = 0$ (i.e $H \cdot^t x = 0$) et donc $x \in C$.
 D'où $d \leq s$.

Ex Décoder le mot reçu (01111110) pour le code de Hamming H_3

1) On a $0111001 \in C$
 La différence est 0000111 et $000111 \in C$.
 D'où $01111110 \in C$ et est à distance 1 du mot reçu. \rightarrow c'est le mot envoyé.

2) On calcule $\sum_{j=1}^n y_j \cdot^t H$
 $(01111110) \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} = (1, 1, 1) = \begin{pmatrix} 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 \\ 0 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$
 = \mathbb{E} erreur = $y - x$ (car $x \cdot^t H = 0$)

Def "syndrome" $y \cdot^t H$, qui vaut $\mathbb{E} \cdot^t H$

Ici calculer tous les syndromes se fait en prenant les s colonnes de H , qui sont $e_i \cdot^t H$. En pratique trop de syndromes à calculer pour les codes

Méthode de décodage "par syndrome"

Soit H la matrice de contrôle de C

x mot émis $\in C$

y mot reçu

$\varepsilon = y - x$ l'erreur, de poids au plus $t-1$ (de telle sorte que $y \in C \Leftrightarrow \varepsilon = 0$)

Def le syndrome de y est le vecteur ligne $y \cdot {}^t H$

Prop: $y \in C \Leftrightarrow y \cdot {}^t H = 0$ ($\Leftrightarrow H \cdot {}^t y = 0 \Leftrightarrow {}^t y \in \text{Ker } H = C$)

* $y \cdot {}^t H = (x + \varepsilon) \cdot {}^t H = \varepsilon \cdot {}^t H$ (car $x \cdot {}^t H = 0$)

~~Prop~~ On peut précalculer la table des syndromes pour les mots de poids $\leq t = \lfloor \frac{d-1}{2} \rfloor$

Prop: Pour ε et ε' de poids au plus t , $(\varepsilon \cdot {}^t H = \varepsilon' \cdot {}^t H) \Rightarrow \varepsilon = \varepsilon'$

Preuve: En effet, $(\varepsilon - \varepsilon') \cdot {}^t H = 0$, donc $\varepsilon - \varepsilon' \in C$. Comme $\varepsilon - \varepsilon'$ est de poids $\leq d-1$, on a $\varepsilon - \varepsilon' = 0$.

Ceci signifie que le syndrome caractérise l'erreur

Ex pour H_3 , on calcule les syndromes pour les 7 mots de poids ≤ 1

Mots de poids ≤ 1	Syndromes
1000000	110
0100000	101
e_i	$i^{\text{e}} \text{ ligne de } {}^t H = i^{\text{e}} \text{ ligne de } H$

Décodeurs $y = 1111000$: $(1111000) \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} = (111) = 4^{\text{e}} \text{ ligne de } {}^t H = 4^{\text{e}} \text{ colonne de } H$

D'où $\varepsilon = e_4$ et $x = y - e_4 = (1110000)$

$y = 1001001$ $y \cdot {}^t H = (000)$ d'où $x = y \in C$

$y = 0011000$ $y \cdot {}^t H = (100)$ d'où $\varepsilon = e_5$ et $x = 0011100$

• pour le 1^{er} code de Hamming:

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

Le syndrome de poids 1 sont les colonnes de H .
 $t = 1$ car $d = 4$.

Décodeurs $y = 111101011$ $y \cdot {}^t H = (01011) = 4^{\text{e}} \text{ col}$ $x = 111001011$

$y = 011101011$

$y \cdot {}^t H = (11110) = C_1 + C_4 = C_2 + C_3$

$y = 001001011$

$y \cdot {}^t H = (11000) = C_1 + C_2 = C_3 + C_4 = C_5 + C_6$ dans deux cas possible

Rem: Peu de codes parfaits: Répétition, Hamming H_m et codes de Golay (semaine prochaine?) (24)

Hamming H_m : code $[2^m - 1, 2^m - m - 1, 3]$ sur F_2

défini par sa matrice de contrôle $m \times (2^m - 1)$ dont les colonnes sont les éléments non nuls de $\{0, 1\}^m$

Prop $d=3$

Prine $\begin{cases} \text{2 colonnes sont toujours indépendantes.} \\ \text{3 triplets de colonnes liés.} \end{cases}$

Prop le code est parfait:

$$1 + n = 3^n \text{ d'où } n = 2^r - 1, k = 2^r - r - 1.$$

Réciproquement, un code binaire parfait avec $d=3$ (donc $t=1$) a ces paramètres

Ex: Pour $m=7$, on trouve un code $[127, 119, 3]$

le minimal utilisait un code $[128, 120, 3]$ (où on a ajouté un bit de parité)
 $120 = 15 \times 8$, c'est à dire chaque paquet avait 15 octets.

Meilleure correction:

Pour $t=2$: $1 + n(q-1) + \frac{n(n-1)}{2} (q-1)^2 = q^n$

Il y a une (unique) solution entière: $q=3, n=11, r=5$ (i.e. $k=6$) [Golay ternaire]
la boule unitaire a $3^5 = 243$ éléments, d'où 243 syndromes.

$[11, 6, 3]$
sur F_3

Pour $t=3$

$$1 + n(q-1) + \frac{n(n-1)}{2} (q-1)^2 + \frac{n(n-1)(n-2)}{6} (q-1)^3 = q^n$$

Solution unique: $q=2, n=23, r=11$ ($k=12$) [23, 12, 7] sur F_2
la boule a 2048 éléments.

