

Theorie de l'information

D. Kohel
13/01/2022



(1)

Distance de Hamming

$d: A^n \times A^n \rightarrow \mathbb{N}$, mesure le nombre de caractères différentes.

Remarque Pour un mot c transmis et mot r reçu, $d(c, r) = \# d'erreurs$.

La boule de rayon t : Pour $x \in A^n$, $B(x, t) = \{y \in A^n : d(x, y) \leq t\}$.

Remarque. Tandis que $B(x, t)$ est nommé une boule, elle est discrète:

- On peut définir des sphères:

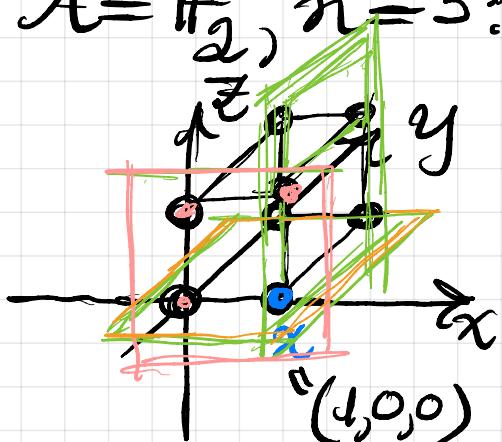
$$S(x, t) = \{y \in A^n : d(x, y) = t\}$$

et alors t

$$B(x, t) = \bigcup_{i=0}^t S(x, i), \text{ union disjointe}$$

- $B(x, t)$ est l'union de droites ($t=1$), plans ($t=2$), ou hyperplans de dimension t :

Ex. $A = \mathbb{F}_2$, $n=3$: $A^3 = \mathbb{F}_2^3$ est un espace vect.



$B(1,0,0), 2)$ est l'union de trois plans de \mathbb{F}_2^3 .

Attention. Le seul point qui n'est pas dans $B(1,0,0), 2)$ est $(0,1,1)$.

Ex. Soit $C = \{00000, 10110, 01011, 11101\}$ (2)

$$C_0 \quad C_1 \quad C_2 \quad C_3 \subseteq \mathbb{F}_2^5$$

Les distances

entre mots de code sont :

$d(x, y)$	C_0	C_1	C_2	C_3
$0 = C_0$	0	3	3	4
C_1	3	0	4	3
C_2	3	4	0	3
C_3	4	3	3	0

On voit que
 $C_3 = C_1 + C_2$,
alors C est
linéaire, de
dimension 2.

Alors $d(C_1, C_2) = d(0, C_3)$, et

$d(C_1, C_3) = d(0, C_2)$, $\quad C_0 \quad C_1 + C_2 + C_2 - C_1$

$d(C_2, C_3) = d(0, C_1)$.

Le tableau est déterminé par

- (i) 0 sur la diagonale
- (ii) les trois valeurs $d(0, c)$, $c \neq 0$.

Pour A^n en général, on a
besoin de $|A^n| - 1$ distances
non triviales, $q^n - 1$ en nombre,
où $q = |A|$.

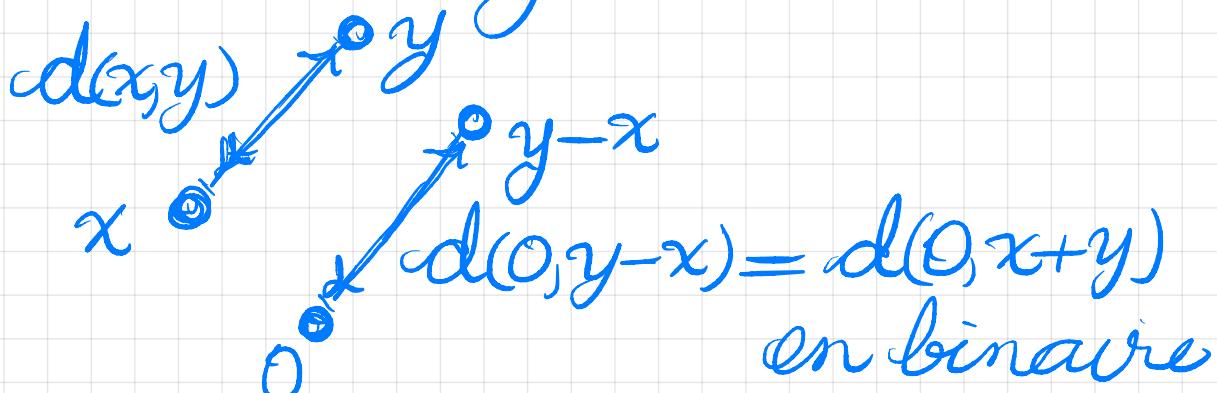
• On note que $C_1 + C_2 + C_3 = 0$, alors

$C_1 + C_2 = C_3$, $C_2 + C_3 = C_1$, etc, car
 $-c = c$ en binnaire ($A = \mathbb{F}_2$)

• $d(C_i, C_j) = d(0, C_i + C_j)$, par

③

linéarité de la distance
de Hamming :



Invariance par translation.

La distance minimum,

$$\begin{aligned}d(\mathcal{C}) &= \min\{d(x,y) : x, y \in \mathcal{C}, x \neq y\} \\&\stackrel{\text{linearité}}{=} \min\{d(0,x) : x \in \mathcal{C} \setminus \{0\}\}\end{aligned}$$

est égale à 3.

Décodage: Soit c un mot transmis ($c \in \mathcal{C}$) et r le mot reçu ($r \in \mathcal{A}^n$). On veut décoder r , en corrigeant des erreurs, et/ou détecter des erreurs.

On dit que \mathcal{C} est t-correcteur (d erreurs) si les boules de rayon t autour des mots $c \in \mathcal{C}$ sont (deux à deux) disjointes.

Exercice. Supposer $|A|=q$.

Montrer que

$$|B(x, t)| = \sum_{i=0}^t |S(x, i)| = \sum_{i=0}^t \binom{n}{i} (q-1)^i.$$

Preuve.

$\binom{n}{i}$ = nombre de choix de i positions changées parmi n .
 $(q-1)^i$ = cardinal des choix de coordonnées changées.

Ex. $A^n = \mathbb{F}_2^3$, $x = \begin{pmatrix} 1, 0, 0 \\ 100 \end{pmatrix}$

Indépendant
de $x \in A^n$.

On note que $q=2$,
alors $q-1=1$.

$$|S(x, 0)| = 1 = |\{x\}| = \{(1, 0, 0)\}$$

$$|S(x, 1)| = \binom{3}{1} = 3 = |\{000, 110, 101\}|$$

$$|S(x, 2)| = \binom{3}{2} = 3 = |\{111, 001, 010\}|$$

$$|S(x, 3)| = 1 = |\{011\}|$$

Total : 8 éléments de \mathbb{F}_2^3 .

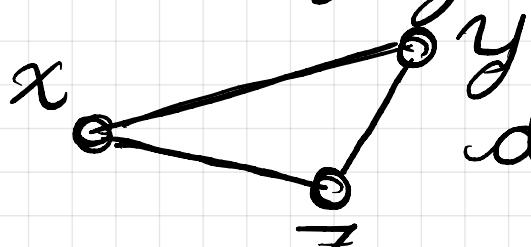
On en déduit de l'exercice que C est t -correcteurssi

$$\bullet |B(C, t)| = |C| \sum_{i=0}^t \binom{n}{i} (q-1)^i, \text{ssi } d(C) \geq 2t+1.$$

Indication $B(x,t) \cap B(y,t) = \emptyset$ ⑤

ssi $d(x,y) \geq 2t+1$.

Attention. La distance de Hamming satisfait la loi du triangle:



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

On a également: si $d(x,y) = s+t$, il existe $z (\in A^n)$ tel que

$$d(x,z) = s \text{ et } d(z,y) = t.$$

Stratégies de décodage.

Avec une stratégie de décoder r reçue à un mot de code dans $B(r,t)$ si $B(r,t) \cap C \neq \emptyset$, sinon d'annoncer l'existence des erreurs ("déetecter" des erreurs: On peut:

① corriger (correctement)

t erreurs si $2t+1 \leq d(C)$,

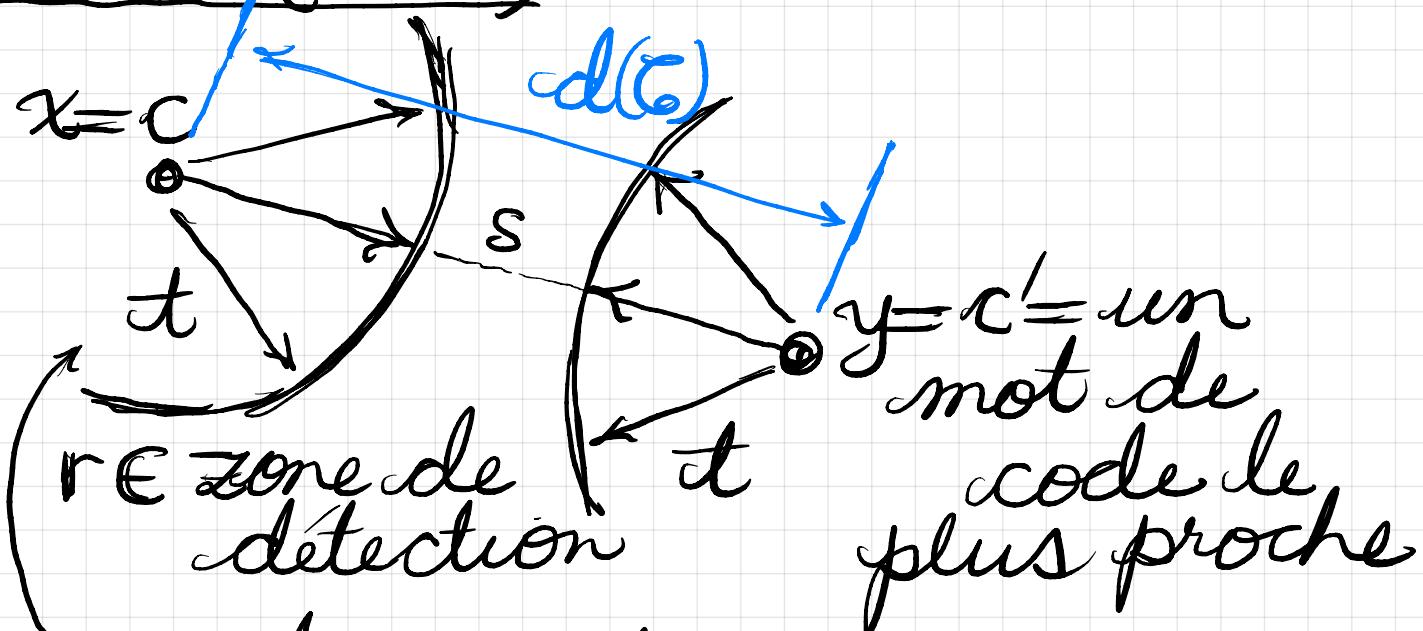
② déetecter s erreurs ($t=0$)

si $s+1 \leq d(C)$, ou

③ corriger t erreurs et déetecter entre $t+1$ et $s+t$ err.

si $2t + s + 1 \leq d(C)$.

Preuve (idée):



$r \in$ zone de correction

Codes linéaires

Supposons que $A = \mathbb{Z}/q\mathbb{Z}$:

$$\mathbb{Z}/q\mathbb{Z} := \{0, 1, \dots, q-1\}$$

avec addition et multiplication mod q (en prenant le reste après division par q).

Si q est premier (e.g. $q=2$), on écrit \mathbb{F}_q pour $\mathbb{Z}/q\mathbb{Z}$, et \mathbb{F}_q est un corps — tout élément non nul est inversible (comme \mathbb{Q} (rationnels), \mathbb{R} (réels) ou \mathbb{C} (complexes)).

On dit que $C \subseteq A^n = (\mathbb{Z}/q\mathbb{Z})^n$ (7)
est linéaire si $= \mathbb{F}_q^n$
pour tout $x, y \in C$ et $a, b \in \mathbb{F}_q$,
alors $ax + by \in C$.
Alors, on a $\vec{0} = (0, \dots, 0) \in C$,
en mettant $a = b = 0$, et C
est un sous-espace vectoriel
de \mathbb{F}_q^n .

Defn. Si $A = \mathbb{Z}/q\mathbb{Z}$, on a $0 \in A$,
élément distingué, ce qui
permet de définir le poids
de $x \in A^n$:

$$\|x\| = d(x, \vec{0}) = |\{i : 1 \leq i \leq n, x_i \neq 0\}|.$$

Defn. La dimension d'un
codage linéaire sur un corps
 \mathbb{F}_q est la taille minimum
d'un sous-ensemble $B \subseteq C$
tel que

$$C = \left\{ \sum_{x \in B} a_x x : a_x \in \mathbb{F}_q \right\}.$$

Si C est un code linéaire sur \mathbb{F}_q
de dimension k , alors $|C| = q^k$.

On rappelle...

Proposition Soit $C \subseteq \mathbb{F}_q^n$ un code linéaire. Alors $0 = (0, \dots, 0) \in C$ et

$d(C) = \min \{d(x, y) : x \in C \setminus \{y\}\}$ pour tout $y \in C$, et en particulier

$$d(C) = \min \{ \|x\| : x \in C \setminus \{0\} \}.$$

Ex $C = \{\underline{000000}, \underline{010101}, \underline{101010}, \underline{111111}\}$ est linéaire de dimension 2 sur \mathbb{F}_2 , et $d(C) = 3$ (= poids non nul minimum).

Les boules de rayon $t=1$ autour des mots de code sont disjointes, donc

$$|B(C, 1)| = |C| |B(0, 1)| = 4(1+6) = 28$$

$$< 2^6 - |\mathbb{F}_2^6| = 64.$$

Exercice. Montrer que $B(C, 2) = \mathbb{F}_2^6$.

Supposons qu'on utilise ce code pour transmission sur un canal binaire symétrique avec probabilité d'erreur E .

} sans mémoire

Si c est le mot (de code) transmis et r le mot reçu, on a
 $d(c,r)$ prob

0	$(1-\varepsilon)^6$	$\left. \begin{array}{l} r \in B(c,1) \\ \text{et } r \neq c \end{array} \right\}$
1	$6(1-\varepsilon)^5 \varepsilon$	
2	$15(1-\varepsilon)^4 \varepsilon^2$	
3	$20(1-\varepsilon)^3 \varepsilon^3$	dont 2 sont $\in B(c,1)$
4	$15(1-\varepsilon)^2 \varepsilon^4$	dont 6 sont $\in B(c,1)$
5	$6(1-\varepsilon) \varepsilon^5$	$\left. \begin{array}{l} \text{tous } \in B(c,1) \\ \text{dans } C \end{array} \right\}$
6	ε^6	$\left. \begin{array}{l} \text{dans } C \\ \text{et } r \neq c \end{array} \right\}$

$(r = c + 111111)$

Ce tableau nous permet de déterminer

- (i) la probabilité d'une bonne correction (avec $t=1$)
- (ii) la probabilité de détection d'erreur (non corrigé)
- (iii) la probabilité d'une mauvaise correction (vers un mot de code $\neq c$).

mauvaise correction

Bornes sur les paramètres des codes

10

Les paramètres qui nous intéressent sont $n = \text{longueur}$ ($\mathcal{C} \subseteq \mathbb{F}_q^n$), $k = \dim(\mathcal{C}) = \frac{\log |\mathcal{C}|}{\log q}$ et $d = d(\mathcal{C})$.

(si linéaire, égalité)

On dit que

\mathcal{C} est un code $[n, k, d]$. (définition plus générale)

Soit A un alphabet de q éléments.

Théorème (Borne de Singleton).

Soit \mathcal{C} un code en bloc de longueur n ($\mathcal{C} \subseteq A^n$) et distance minimum d . Alors $|\mathcal{C}| \leq q^{n-d+1}$.

Remarque. Donc

$$k = \frac{\log |\mathcal{C}|}{\log q} \leq n - d + 1,$$

où k est un entier si \mathcal{C} est linéaire.

Défn Si $|\mathcal{C}| = q^{n-d+1}$, on dit que \mathcal{C} est MDS (separation de distance maximale)

Démonstration. Soit π la projection $\mathcal{C} \xrightarrow{\pi} A^{n-d+1}$

$$A^n \xrightarrow{\pi} x_1 \dots x_n \mapsto x_1 \dots x_{n-d+1}$$

La restriction à \mathcal{C} est injective, car $\pi(x) = \pi(y)$ seulement si $d(x, y) \leq d-1$, alors $x = y \in \mathcal{C}$.

Donc

$$\mathcal{C} \xrightarrow{\pi} \pi(\mathcal{C}) \subseteq A^{n-d+1}$$

est une bijection, alors

$$|\mathcal{C}| = |\pi(\mathcal{C})| \leq |A^{n-d+1}| = q^{n-d+1} \quad \square$$

Ex Soit $\mathcal{C} = \langle 1001, 0101, 0011 \rangle$,

$$\mathcal{C} \subseteq \mathbb{F}_2^4$$

Alors

$$d(\mathcal{C}) = 2 \quad (\text{car } d(\mathcal{C}) \leq 2 \text{ et } d(\mathcal{C}) \neq 1)$$

$$\text{et } k = \dim_{\mathbb{F}_2} \mathcal{C} = 3,$$

et donc

$$n-d+1 = 4-2+1 = 3 = d(\mathcal{C}).$$

Alors \mathcal{C} est MDS.

* On observe que \mathcal{C} est le sous espace de vecteurs de poids pair, donc $d(\mathcal{C})$ est pair.

Pourquoi?

Théorème (Borne de Hamming)
 Soit C un code en bloc de longueur n ($C \subseteq A^n$) et distance minimum $d \geq 2t+1$. Alors

$$|C| V(q, n, t) \leq q^n, \quad (*)$$

$$\text{où } V(q, n, t) = |B(x, t)| = \sum_{i=0}^n \binom{n}{i} (q-1)^i.$$

Preuve. Par l'hypothèse $d = d(C) \geq 2t+1$, les boules de rayon t autour des mots de code sont disjointes, or

$$|A^n| \geq |B(C, t)| = |C| V(q, n, t). \quad \square$$

$\frac{|A|^n}{q^n}$ rendement

Corollaire. Le taux de transmission de C est au maximum

$$1 - \frac{\log V(q, n, t)}{n \log q}.$$

Preuve. $R := \frac{\log |C|}{n \log q} \leq \frac{\log V(q, n, t)}{n \log q}$, en prenant log de $(*)$, divisant par $n \log q$. \square

Définition Un code qui satisfait $\text{IC} = q^n / N(q, n, t)$ s'appelle parfait. (12)

Remarque. Un code est parfait si

- C'est t -correcteur, avec $d(C) = 2t + 1$, et
- les boules de rayon t autour de C couvrent tout A^n ($= B(C, t)$).

C'est à dire, qu'il n'y a pas d'espace entre les boules.