

# Théorie de l'information

## Codes correcteurs

---

Florent Devin

EISTI



---

28 avril 2009

# Introduction

# Résumé

## 1 Introduction

- Introduction
- Détection/correction d'erreurs
- Notations mathématiques

## 2 Codes détecteurs

- Bit de parité

## 3 Codes correcteurs

## 4 Codes linéaires

## 5 D'autres codes correcteurs

# Introduction

- Distinction entre code correcteur, cryptographie et compression
- Code correcteur :
  - Détecte une erreur dans un message
  - Peut corriger une erreur dans un message
- Cryptographie
  - Code un message
  - Peut compresser ce message
- Compression
  - diminue le coût de stockage
  - diminue le coût de transmission

# Application

## Auto correction classique

- Barrettes mémoire : Hamming
- Image de sondes spatiales (en niveau de gris) : Reed - Muller
- Image couleur de sondes spatiales : Golay
- Lecteur CD : CIRC / Reed - Solomon
- Communication sans fil : beaucoup d'algorithmes

# Restrictions et définitions

- Messages transmis : découper en blocs (**mots**)
- Mots : longueur  $n$
- Alphabet :  $\{0, 1\}$
- Code : sous ensemble  $C$  de l'ensemble  $\{0, 1\}^n$  (appelé  $V$ )
- $n$  : longueur de  $C$

# Contexte

- Soit  $\mathcal{T}$  : l'ensemble de transmission
- $\mathcal{T} = \{0 \rightarrow 0, 0 \rightarrow 1, 1 \rightarrow 0, 1 \rightarrow 1\}$
- Soit  $\mathcal{B} = \{0 \rightarrow 0, 1 \rightarrow 1\}$
- Soit  $\mathcal{M} = \{0 \rightarrow 1, 1 \rightarrow 0\}$  appelé  $p$
- $P(\mathcal{B}) + P(\mathcal{M}) = 1$
- Probabilité d'erreur sur une transmission de deux bits :  
 $1 - (1 - p)^2$
- Probabilité de  $q$  erreurs sur une transmission de  $t$  bits :  
 $p^q(1 - p)^{t-q}$

# Résumé

## 1 Introduction

- Introduction
- Détection/correction d'erreurs
- Notations mathématiques

## 2 Codes détecteurs

- Bit de parité

## 3 Codes correcteurs

## 4 Codes linéaires

## 5 D'autres codes correcteurs

# Introduction

- Réception : suite de bits
- Besoin de découper pour extraire les mots
- Utilisation “délicate” des codes de longueur variable

## Exemple : Huffman

Soit la chaîne : "Bonjour monde", un code de Huffman est :

```
1100000111111001011010100011100 00111101100110100
```

Que se passe-t-il si on reçoit :

```
1111100111111001011010100011100 00111101100110100
```

Le message reçu est alors tout autre : "jejBur monde"

# Principe de codage/décodage

- Codage

- Découpage du message en blocs de  $m$  bits
- Codage de chaque blocs en bloc de  $n$  bits
- Concaténation des blocs obtenus
- Transmission

- Décodage

- Découpage du message en blocs de taille  $n$
- Décodage des blocs selon la méthode de la distance minimale
- Extraction des blocs de  $m$  bits
- Assemblage du message

# Distance

- Soit deux mots :
  - $x = (x_1, x_2, \dots, x_n)$
  - $y = (y_1, y_2, \dots, y_n)$
  - distance de **Hamming**  $d(x, y)$  : nombre d'indice  $i | x_i \neq y_i$
- $d$  : distance minimale

# Propriétés

- **Positivité :**

- $d(x, y) \geq 0 \quad \forall (x, y)$
- $d(x, y) = 0 \iff x = y$

- **Symétrie :**

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

- **Inégalité :**

$$d(x, y) \leq d(x, z) + d(z, y) \quad \forall (x, y, z)$$

# Principe du décodage

## Décodage à distance minimum

- Mot reçu :  $r$
- Mot code :  $c$
- $c$  est le plus proche de  $y$  quand  $d(x, y) = \min$
- Application du maximum de vraisemblance

# n-correcteur

Un code est **n-correcteur** quand toute erreur d'au plus  $n$  bits est corrigée correctement

# Distance et capacité

Soit

- $C$  un code de distance  $d$
- $w'$  un mot reçu
- $e$  nombre d'erreur de  $w'$  par rapport à  $w$
- Si  $e < d$  alors  $C$  peut détecter l'erreur
- Si  $e < \frac{d}{2}$  alors  $C$  peut corriger l'erreur

# Résumé

## 1 Introduction

- Introduction
- Détection/correction d'erreurs
- Notations mathématiques

## 2 Codes détecteurs

- Bit de parité

## 3 Codes correcteurs

## 4 Codes linéaires

## 5 D'autres codes correcteurs

# Règles de calcul dans $(\mathbb{Z}/2\mathbb{Z})^n$

- $\mathbb{Z}/2\mathbb{Z}$  : corps (muni des opérations binaire  $+$ ,  $\times$ )
- $(\mathbb{Z}/2\mathbb{Z})^n$  : mots binaires de longueur  $n$
- Définitions de deux lois :
  - L'addition :  $+$  :  $(\mathbb{Z}/2\mathbb{Z})^n \times (\mathbb{Z}/2\mathbb{Z})^n \rightarrow (\mathbb{Z}/2\mathbb{Z})^n$

$$\begin{aligned}(a_1, a_2, \dots, a_n) + (b_1, b_2, \dots, b_n) \\ = (a_1 + b_1, a_2 + b_2, \dots, a_n + b_n)\end{aligned}$$



Pas de report de retenue

- La multiplication :  $\cdot$

# Règles de calcul dans $(\mathbb{Z}/2\mathbb{Z})^n$

- $\mathbb{Z}/2\mathbb{Z}$  : corps (muni des opérations binaire  $+$ ,  $\times$ )
- $(\mathbb{Z}/2\mathbb{Z})^n$  : mots binaires de longueur  $n$
- Définitions de deux lois :
  - L'addition  $+$
  - La multiplication :  $\cdot : \mathbb{Z}/2\mathbb{Z} \times (\mathbb{Z}/2\mathbb{Z})^n \rightarrow (\mathbb{Z}/2\mathbb{Z})^n$

$$\lambda \cdot (a_1, a_2, \dots, a_n) = (\lambda \cdot a_1, \lambda \cdot a_2, \dots, \lambda \cdot a_n)$$

# Remarques

- $0_n = (0, 0, \dots, 0)$
- $1_n = (1, 1, \dots, 1)$
- $\forall x \in (\mathbb{Z}/2\mathbb{Z})^n x + x = 0_n \Rightarrow x = -x$
- $x + y = z \iff x = y + z$
- Multiplication matricielle :

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

# Applications linéaires

## Notation

- $\mathcal{M}_{p,n}$  : matrice de taille  $p \times n$  dans  $(\mathbb{Z}/2\mathbb{Z})^n$

## Définition

Une application  $f : (\mathbb{Z}/2\mathbb{Z})^p \rightarrow (\mathbb{Z}/2\mathbb{Z})^n$  est **linéaire** si et seulement si pour tous mots  $x, y$  de  $(\mathbb{Z}/2\mathbb{Z})^p$  on a  $f(x + y) = f(x) + f(y)$

# Codes détecteurs

# Résumé

- 1 **Introduction**
  - Introduction
  - Détection/correction d'erreurs
  - Notations mathématiques
- 2 **Codes détecteurs**
  - Bit de parité
- 3 **Codes correcteurs**
- 4 **Codes linéaires**
- 5 **D'autres codes correcteurs**

# Bit de parité (paire)

- Signature : nombre total de bit à 1 : pair
- Transmission du vocabulaire cible + signature
- Réception : calcul du nombre de bit à 1
  - Nombre pair : pas de problème détecté
  - Nombre impair : problème détecté

# Exemple

## Parité paire

Message initial : 0000000100100011

Phase de découpage (bloc de 4 bits) :

0000 0001 0010 0011

Phase de codage (rajout du bit de parité) :

00000 00011 00101 00110

Phase de transmission (message assemblé)

00000000110010100110

# Exemple simple

## Répétition

- Code à transmettre : 0110
- Code transmis : 000111111000
- Code reçu : xxzyzyzzyxx
- Permet de corriger les erreurs dans la plupart des cas
- Augmente considérablement le temps de transmission

# Codes correcteurs

# Codes correcteurs

- Plusieurs familles
  - Codes en bloc : codage/décodage ne dépend que du bloc en cours (Famille de type linéaires, cycliques ou non)
  - Codes entrelacé : codage/décodage dépend d'informations déjà transmises (famille de type convolutifs, récurrents ou non)
- Préférence pour les codes linéaires dans les transmissions (quand ceux ci sont utilisés. . .)

# Codage de double parité

- Association à chaque bloc, d'un bit de parité
- Association d'un bloc de parité pour  $x$  bloc transmis
- Codage peu utilisé

```
00000000 01010101 11111111
11111111 00000000 01010101
01010101 11111111 00000000
10101010 10101010 10101010
```

# Codes linéaires

# Codes linéaires

## Notation : $C(n,k,d)$

- $F_2$  : corps à deux éléments (0, 1)
- $F_2^n$  mots de longueur  $n$
- $C \subset F_2^n$  : code linéaire de longueur  $n$
- $k$  : dimension du sous espace vectoriel  $C$
- $2^k$  : nombre de mots du code  $C$
- $w(x)$  : poids du mot  $x$
- $d$  : minimum des poids de  $C$

# Code linéaires

## Explications : code( $n,k,d$ )

- $n$  : dimension du vocabulaire transmis (nombre de symbole des mots)
- $k$  : dimension du vocabulaire initial
- $d$  : distance minimale entre deux mots cibles
- $\frac{k}{n}$  : rendement du code
- $\frac{d}{n}$  : fiabilité du code
- Permet de détecter  $d - 1$  erreurs
- Permet de corriger  $\lfloor \frac{d-1}{2} \rfloor$  erreurs

# Borne de Singleton

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

On ne peut avoir une bonne correction et un vocabulaire riche sur une longueur fixe de code

# Matrice génératrice

- Code linéaire : représentable par une matrice génératrice  $G$
- $G$  de taille  $k \times n$  ( $k$  lignes,  $n$  colonnes)
- Lignes de  $G$  : base du code  $C$
- Si  $m$  vecteur ligne de  $k$  composantes (mot original)
- $mG \in C$  : mot de  $n$  composantes (mot codé)
- $d$  : distance de Hamming la plus petite de toutes les lignes
- Permutation de deux colonnes : code équivalent

# Matrice sous forme systématique

- Si  $G = [I_k|A]$  alors  $G$  est sous forme systématique
- N'existe pas toujours
- Si existence alors l'écriture est unique
- Début du code : mot initial

## Exemple de matrice

$$\left( \begin{array}{ccc|cccc} 1 & 0 & 0 & 1 & 1 & 0 & 1 \\ 0 & 1 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 1 & 1 & 0 \end{array} \right)$$

# Méthodes de corrections

## Deux possibilités

- Par génération de toutes les combinaisons possibles, puis comparaison du mot reçu avec ceux possibles (très long, très volumineux, lent)
- Par utilisation d'une matrice de contrôle et des syndromes associés

# Matrice de contrôle

## Code dual (noté $C^\perp$ )

- $y = (y_1, y_2, \dots, y_n) \in \mathbb{F}_q^n$
- $x = (x_1, x_2, \dots, x_n) \in C$
- $x \cdot y = x_1 y_1 + x_2 y_2 + \dots + x_n y_n = 0$
- $y$  : ensemble des vecteurs de  $C^\perp$
- $H$  : matrice génératrice de  $C^\perp$
- $H$  : matrice de contrôle de  $C$

# Matrice de contrôle et syndrome

- $G$  : Matrice sous forme systématique ( $G = [I_k|A]$ )
- $H$  : Matrice de contrôle ( $H = [{}^tA|I_{n-k}]$ )
- Syndrome de  $x$  (noté  $\sigma$ ) : vecteur colonne  $\in \mathbb{F}_q^n$ 
  - $\sigma(x) = H^t x$
  - $\sigma(x) = \sum_{i=1}^n x_i h_i$
  - $\sigma(x) = 0 \iff x \in C$

# Intérêt du syndrome

- $y$  : mot reçu
- $x$  : mot émis
- $e = y - x$  : erreur de transmission
- $\sigma(y) = \sigma(x + e) = \sigma(e)$
- Application en TD : Hamming

## Propriété importante

Le syndrome ne dépend que de l'erreur

# D'autres codes correcteurs

# D'autres codes correcteurs

- Reed Muller : Code linéaire permettant de corriger 7 erreurs
- Golay : code cyclique (topologie particulière des codes linéaires)
- BCH (Bose, Ray-Chaudhuri, Hocquenghem) : Code cyclique à plusieurs niveaux
- Reed Solomon : Code par bloc (basé sur les corps Galois)
- Goppa : code de géométrie algébrique (extension des code de Reed - Solomon)
- ...