

## Cours 2. Entropie. Introduction au codage.

A. Désilles

6 avril 2010

# Résumé

- 1 Rappels
- 2 Théorie de l'information et cryptographie
- 3 Codage. Position du problème
- 4 Codage de source
  - Arbres et codes instantanés

# Résumé

- 1 Rappels
- 2 Théorie de l'information et cryptographie
- 3 Codage. Position du problème
- 4 Codage de source
  - Arbres et codes instantanés

# Résumé

- 1 Rappels
- 2 Théorie de l'information et cryptographie
- 3 Codage. Position du problème
- 4 Codage de source
  - Arbres et codes instantanés

# Résumé

- 1 Rappels
- 2 Théorie de l'information et cryptographie
- 3 Codage. Position du problème
- 4 Codage de source
  - Arbres et codes instantanés

# Résumé

## Rappels : Modèle de communication

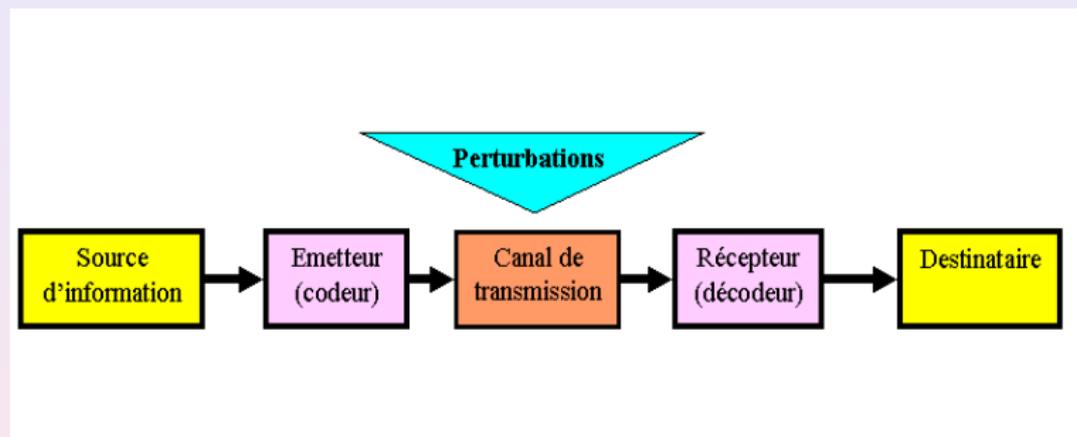


Figure: Paradigme de Shannon

# Rappels : Représentation mathématique d'une source

- Une source d'information peut être :
  - un texte
  - un son
  - une image
- Elle est représentée par un ensemble fini d'éléments, appelé alphabet.
- Les éléments de l'alphabet sont appelés symboles (caractères, lettres).
- Toute séquence finie d'éléments d'alphabet est appelée mot (message).

# Rappels : Représentation mathématique d'une source

- Une source d'information peut être :
  - un texte
  - un son
  - une image
- Elle est représentée par un ensemble fini d'éléments, appelé alphabet.
- Les éléments de l'alphabet sont appelés symboles (caractères, lettres).
- Toute séquence finie d'éléments d'alphabet est appelée mot (message).

# Rappels : Représentation mathématique d'une source

- Une source d'information peut être :
  - un texte
  - un son
  - une image
- Elle est représentée par un ensemble fini d'éléments, appelé alphabet.
- Les éléments de l'alphabet sont appelés symboles (caractères, lettres).
- Toute séquence finie d'éléments d'alphabet est appelée mot (message).

# Rappels : Représentation mathématique d'une source

- Une source d'information peut être :
  - un texte
  - un son
  - une image
- Elle est représentée par un ensemble fini d'éléments, appelé alphabet.
- Les éléments de l'alphabet sont appelés symboles (caractères, lettres).
- Toute séquence finie d'éléments d'alphabet est appelée mot (message).

# Rappels : Représentation mathématique d'une source

- Une source d'information peut être :
  - un texte
  - un son
  - une image
- Elle est représentée par un ensemble fini d'éléments, appelé alphabet.
- Les éléments de l'alphabet sont appelés symboles (caractères, lettres).
- Toute séquence finie d'éléments d'alphabet est appelée mot (message).

# Rappels : Représentation mathématique d'une source

- Une source d'information peut être :
  - un texte
  - un son
  - une image
- Elle est représentée par un ensemble fini d'éléments, appelé alphabet.
- Les éléments de l'alphabet sont appelés symboles (caractères, lettres).
- Toute séquence finie d'éléments d'alphabet est appelée mot (message).

# Rappels : Représentation mathématique d'une source

- Une source d'information peut être :
  - un texte
  - un son
  - une image
- Elle est représentée par un ensemble fini d'éléments, appelé alphabet.
- Les éléments de l'alphabet sont appelés symboles (caractères, lettres).
- Toute séquence finie d'éléments d'alphabet est appelée mot (message).

## Modèle d'une source d'information

Une source d'information  $X$  est décrite par un couple  $(\Omega_X, P_X)$  où  $\Omega_X$  est un alphabet fini et  $P_X$  est une distribution de probabilités sur  $\Omega_X$ .

## Entropie d'une source

Soient  $\Omega_X = \{x_1, \dots, x_m\}$  l'alphabet fini d'une source et  $X$  la variable aléatoire associée t.q.  $P[\omega_i] = p_i$ ,  $i = 1, \dots, m$ . On appelle **entropie** ou encore **quantité moyenne d'information** de la source la quantité

$$H(X) = H(p_1, p_2, \dots, p_n) = E[h(x)] = - \sum_{i=1}^m p_i \log_2(p_i)$$

L'unité de mesure de cette quantité est le "bit par symbole".

# Cryptographie. Vocabulaire.

- La **cryptographie** est une science qui étudie les méthodes permettant de transmettre des messages de façon confidentielle.
- **message clair** : un ensemble de données (texte, image, ...) que l'on souhaite transmettre.
- Le **chiffrement** est un procédé permettant de transformer le message clair de telle sorte qu'il soit incompréhensible par qui que ce soit d'autre que l'auteur du message et le destinataire.
- Le **chiffré** est le résultat du chiffrement.
- Le **déchiffrement** est le procédé permettant de retrouver le message clair à partir du chiffré.
- La **clé de chiffrement** est un paramètre qui est utilisé dans le procédé de chiffrement ou déchiffrement.

# Cryptographie. Vocabulaire.

- La **cryptographie** est une science qui étudie les méthodes permettant de transmettre des messages de façon confidentielle.
- **message clair** : un ensemble de données (texte, image, ...) que l'on souhaite transmettre.
- Le **chiffrement** est un procédé permettant de transformer le message clair de telle sorte qu'il soit incompréhensible par qui que ce soit d'autre que l'auteur du message et le destinataire.
- Le **chiffré** est le résultat du chiffrement.
- Le **déchiffrement** est le procédé permettant de retrouver le message clair à partir du chiffré.
- La **clé de chiffrement** est un paramètre qui est utilisé dans le procédé de chiffrement ou déchiffrement.

# Cryptographie. Vocabulaire.

- La **cryptographie** est une science qui étudie les méthodes permettant de transmettre des messages de façon confidentielle.
- **message clair** : un ensemble de données (texte, image, ...) que l'on souhaite transmettre.
- Le **chiffrement** est un procédé permettant de transformer le message clair de telle sorte qu'il soit incompréhensible par qui que ce soit d'autre que l'auteur du message et le destinataire.
- Le **chiffré** est le résultat du chiffrement.
- Le **déchiffrement** est le procédé permettant de retrouver le message clair à partir du chiffré.
- La **clé de chiffrement** est un paramètre qui est utilisé dans le procédé de chiffrement ou déchiffrement.

# Cryptographie. Vocabulaire.

- La **cryptographie** est une science qui étudie les méthodes permettant de transmettre des messages de façon confidentielle.
- **message clair** : un ensemble de données (texte, image, ...) que l'on souhaite transmettre.
- Le **chiffrement** est un procédé permettant de transformer le message clair de telle sorte qu'il soit incompréhensible par qui que ce soit d'autre que l'auteur du message et le destinataire.
- Le **chiffré** est le résultat du chiffrement.
- Le **déchiffrement** est le procédé permettant de retrouver le message clair à partir du chiffré.
- La **clé de chiffrement** est un paramètre qui est utilisé dans le procédé de chiffrement ou déchiffrement.

# Cryptographie. Vocabulaire.

- La **cryptographie** est une science qui étudie les méthodes permettant de transmettre des messages de façon confidentielle.
- **message clair** : un ensemble de données (texte, image, ...) que l'on souhaite transmettre.
- Le **chiffrement** est un procédé permettant de transformer le message clair de telle sorte qu'il soit incompréhensible par qui que ce soit d'autre que l'auteur du message et le destinataire.
- Le **chiffré** est le résultat du chiffrement.
- Le **déchiffrement** est le procédé permettant de retrouver le message clair à partir du chiffré.
- La **clé de chiffrement** est un paramètre qui est utilisé dans le procédé de chiffrement ou déchiffrement.

# Cryptographie. Vocabulaire.

- La **cryptographie** est une science qui étudie les méthodes permettant de transmettre des messages de façon confidentielle.
- **message clair** : un ensemble de données (texte, image, ...) que l'on souhaite transmettre.
- Le **chiffrement** est un procédé permettant de transformer le message clair de telle sorte qu'il soit incompréhensible par qui que ce soit d'autre que l'auteur du message et le destinataire.
- Le **chiffré** est le résultat du chiffrement.
- Le **déchiffrement** est le procédé permettant de retrouver le message clair à partir du chiffré.
- La **clé** de chiffrement est un paramètre qui est utilisé dans le procédé de chiffrement ou déchiffrement.

# Cryptosystème

## Définition

Un **cryptosystème** est un quintuplé  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  formé de

- un ensemble de clés  $\mathcal{K}$
- un ensemble de messages clairs possibles,  $\mathcal{M}$ ,
- un ensemble de messages chiffrés possibles  $\mathcal{C}$
- un algorithme de chiffrement, représenté par une fonction  $E : \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ ,
- et un procédé de déchiffrement, représenté par une fonction  $D : \mathcal{K} \times \mathcal{C} \rightarrow \mathcal{M}$ .

On suppose que pour tout  $m \in \mathcal{M}$  il existe une paire de clés de chiffrement et de déchiffrement telles que la relation

$$D(k_D, E(k_E, m)) = m$$

est assurée

# Cryptosystème

## Définition

Un **cryptosystème** est un quintuplé  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  formé de

- un ensemble de clés  $\mathcal{K}$
- un ensemble de messages clairs possibles ,  $\mathcal{M}$ ,
- un ensemble de messages chiffrés possibles  $\mathcal{C}$
- un algorithme de chiffrage, représenté par une fonction  $E : \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ ,
- et un procédé de déchiffrage , représenté par une fonction  $D : \mathcal{K} \times \mathcal{C} \rightarrow \mathcal{M}$ .

On suppose que pour tout  $m \in \mathcal{M}$  il existe une paire de clés de chiffrement et de déchiffrement telles que la relation

$$D(k_D, E(k_E, m)) = m$$

est assurée

# Cryptosystème

## Définition

Un **cryptosystème** est un quintuplé  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  formé de

- un ensemble de clés  $\mathcal{K}$
- un ensemble de messages clairs possibles ,  $\mathcal{M}$ ,
- un ensemble de messages chiffrés possibles  $\mathcal{C}$
- un algorithme de chiffrement, représenté par une fonction  $E : \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ ,
- et un procédé de déchiffrement , représenté par une fonction  $D : \mathcal{K} \times \mathcal{C} \rightarrow \mathcal{M}$ .

On suppose que pour tout  $m \in \mathcal{M}$  il existe une paire de clés de chiffrement et de déchiffrement telles que la relation

$$D(k_D, E(k_E, m)) = m$$

est assurée

# Cryptosystème

## Définition

Un **cryptosystème** est un quintuplé  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  formé de

- un ensemble de clés  $\mathcal{K}$
- un ensemble de messages clairs possibles ,  $\mathcal{M}$ ,
- un ensemble de messages chiffrés possibles  $\mathcal{C}$
- un algorithme de chiffrement, représenté par une fonction  $E : \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ ,
- et un procédé de déchiffrement , représenté par une fonction  $D : \mathcal{K} \times \mathcal{C} \rightarrow \mathcal{M}$ .

On suppose que pour tout  $m \in \mathcal{M}$  il existe une paire de clés de chiffrement et de déchiffrement telles que la relation

$$D(k_D, E(k_E, m)) = m$$

est assurée

# Cryptosystème

## Définition

Un **cryptosystème** est un quintuplé  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  formé de

- un ensemble de clés  $\mathcal{K}$
- un ensemble de messages clairs possibles ,  $\mathcal{M}$ ,
- un ensemble de messages chiffrés possibles  $\mathcal{C}$
- un algorithme de chiffrement, représenté par une fonction  $E : \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ ,
- et un procédé de déchiffrement , représenté par une fonction  $D : \mathcal{K} \times \mathcal{C} \rightarrow \mathcal{M}$ .

On suppose que pour tout  $m \in \mathcal{M}$  il existe une paire de clés de chiffrement et de déchiffrement telles que la relation

$$D(k_D, E(k_E, m)) = m$$

est assurée.

# Cryptosystème

## Définition

Un **cryptosystème** est un quintuplé  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  formé de

- un ensemble de clés  $\mathcal{K}$
- un ensemble de messages clairs possibles ,  $\mathcal{M}$ ,
- un ensemble de messages chiffrés possibles  $\mathcal{C}$
- un algorithme de chiffrement, représenté par une fonction  $E : \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ ,
- et un procédé de déchiffrement , représenté par une fonction  $D : \mathcal{K} \times \mathcal{C} \rightarrow \mathcal{M}$ .

On suppose que pour tout  $m \in \mathcal{M}$  il existe une paire de clés de chiffrement et de déchiffrement telles que la relation

$$D(k_D, E(k_E, m)) = m$$

est assurée.

# Cryptosystème

## Définition

Un **cryptosystème** est un quintuplé  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  formé de

- un ensemble de clés  $\mathcal{K}$
- un ensemble de messages clairs possibles,  $\mathcal{M}$ ,
- un ensemble de messages chiffrés possibles  $\mathcal{C}$
- un algorithme de chiffrement, représenté par une fonction  $E : \mathcal{K} \times \mathcal{M} \rightarrow \mathcal{C}$ ,
- et un procédé de déchiffrement, représenté par une fonction  $D : \mathcal{K} \times \mathcal{C} \rightarrow \mathcal{M}$ .

On suppose que pour tout  $m \in \mathcal{M}$  il existe une paire de clés de chiffrement et de déchiffrement telles que la relation

$$D(k_D, E(k_E, m)) = m$$

est assurée.

# Cryptographie. Un peu d'histoire

- **Cryptographie** signifie "écriture cachée" ( **kryptos** = caché, **graphein**= écriture)
- Kàma-Sutra recommandait aux femmes d'apprendre 60 arts, dont les échecs, la reliure, la tapisserie et... l'écriture secrète pour cacher leur liaisons
- L'une des premières méthodes de cryptage par substitution connue est celle de César (50 av. J.C). Chaque lettre de message à transmettre était remplacée par la lettre située dans l'alphabet trois positions plus loin.
- Par exemple, A est remplacé par "D", "Z" par "C".

# Cryptographie. Un peu d'histoire

- **Cryptographie** signifie "écriture cachée" ( **kryptos** = caché, **graphein**= écriture)
- Kàma-Sutra recommandait aux femmes d'apprendre 60 arts, dont les échecs, la reliure, la tapisserie et... l'écriture secrète pour cacher leur liaisons
- L'une des premières méthodes de cryptage par substitution connue est celle de César (50 av. J.C). Chaque lettre de message à transmettre était remplacée par la lettre située dans l'alphabet trois positions plus loin.
- Par exemple, A est remplacé par "D", "Z" par "C".

# Cryptographie. Un peu d'histoire

- **Cryptographie** signifie "écriture cachée" ( **kryptos** = caché, **graphein**= écriture)
- Kàma-Sutra recommandait aux femmes d'apprendre 60 arts, dont les échecs, la reliure, la tapisserie et... l'écriture secrète pour cacher leur liaisons
- L'une des premières méthodes de cryptage par substitution connue est celle de César (50 av. J.C). Chaque lettre de message à transmettre était remplacée par la lettre située dans l'alphabet trois positions plus loin.
- Par exemple, A est remplacé par "D", "Z" par "C".

# Cryptographie. Un peu d'histoire

- **Cryptographie** signifie "écriture cachée" ( **kryptos** = caché, **graphein**= écriture)
- Kàma-Sutra recommandait aux femmes d'apprendre 60 arts, dont les échecs, la reliure, la tapisserie et... l'écriture secrète pour cacher leur liaisons
- L'une des premières méthodes de cryptage par substitution connue est celle de César (50 av. J.C). Chaque lettre de message à transmettre était remplacée par la lettre située dans l'alphabet trois positions plus loin.
- Par exemple, A est remplacé par "D", "Z" par "C".

# Cryptographie. Un peu d'histoire.

- Les méthodes de substitution, analogues à celle de César, consistent à appairer les lettres de l'alphabet et à remplacer chaque lettre de message par la lettre de sa paire
- Elles ont été massivement utilisées jusqu'à la fin du 1er millénaire
- IXème siècle : le savant arabe AL-Kindi rédige le premier traité connu sur l'analyse fréquentielle comme technique de cryptanalyse
- Il montre comment retrouver le message en analysant les fréquences d'occurrence de caractères dans une langue donnée
- Le cryptage par substitution devient trop vulnérable

# Cryptographie. Un peu d'histoire.

- Les méthodes de substitution, analogues à celle de César, consistent à appairer les lettres de l'alphabet et à remplacer chaque lettre de message par la lettre de sa paire
- Elles ont été massivement utilisées jusqu'à la fin du 1er millénaire
- IXème siècle : le savant arabe AL-Kindi rédige le premier traité connu sur l'analyse fréquentielle comme technique de cryptanalyse
- Il montre comment retrouver le message en analysant les fréquences d'occurrence de caractères dans une langue donnée
- Le cryptage par substitution devient trop vulnérable

# Cryptographie. Un peu d'histoire.

- Les méthodes de substitution, analogues à celle de César, consistent à appairer les lettres de l'alphabet et à remplacer chaque lettre de message par la lettre de sa paire
- Elles ont été massivement utilisées jusqu'à la fin du 1er millénaire
- IXème siècle : le savant arabe AL-Kindi rédige le premier traité connu sur l'analyse fréquentielle comme technique de cryptanalyse
- Il montre comment retrouver le message en analysant les fréquences d'occurrence de caractères dans une langue donnée
- Le cryptage par substitution devient trop vulnérable

# Cryptographie. Un peu d'histoire.

- Les méthodes de substitution, analogues à celle de César, consistent à appairer les lettres de l'alphabet et à remplacer chaque lettre de message par la lettre de sa paire
- Elles ont été massivement utilisées jusqu'à la fin du 1er millénaire
- IXème siècle : le savant arabe AL-Kindi rédige le premier traité connu sur l'analyse fréquentielle comme technique de cryptanalyse
- Il montre comment retrouver le message en analysant les fréquences d'occurrence de caractères dans une langue donnée
- Le cryptage par substitution devient trop vulnérable

# Cryptographie. Un peu d'histoire.

- Les méthodes de substitution, analogues à celle de César, consistent à appairer les lettres de l'alphabet et à remplacer chaque lettre de message par la lettre de sa paire
- Elles ont été massivement utilisées jusqu'à la fin du 1er millénaire
- IXème siècle : le savant arabe AL-Kindi rédige le premier traité connu sur l'analyse fréquentielle comme technique de cryptanalyse
- Il montre comment retrouver le message en analysant les fréquences d'occurrence de caractères dans une langue donnée
- Le cryptage par substitution devient trop vulnérable

# Cryptographie. Notion de sécurité.

## Principe de A. Kerckhoffs ( fin XIXe)

La sécurité d'un cryptosystème ne doit pas reposer sur la non divulgation de la fonction de cryptage mais uniquement sur la non divulgation de la clé.

# Sécurité : approche de Shannon

- 1949. Publication par C. Shannon de l'article "Communication Theory of Secrecy Systems" dans la revue Bell System Technical Journal.
- Le concept d'entropie est utilisé pour analyser et quantifier la sécurité d'un cryptosystème.

# Sécurité : approche de Shannon

- 1949. Publication par C. Shannon de l'article "Communication Theory of Secrecy Systems" dans la revue Bell System Technical Journal.
- Le concept d'entropie est utilisé pour analyser et quantifier la sécurité d'un cryptosystème.

# Cryptosystème parfaitement sûr

- On associe au cryptosystème  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  trois variables aléatoires :
  - $M \in \mathcal{M}$  représente le choix d'un message clair
  - $K \in \mathcal{K}$  représente le choix d'une clé
  - $C \in \mathcal{C}$  représente le choix d'un chiffré
  - on suppose que le message clair et la clé sont choisis de façon indépendante

# Cryptosystème parfaitement sûr

- On associe au cryptosystème  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  trois variables aléatoires :
- $M \in \mathcal{M}$  représente le choix d'un message clair
- $K \in \mathcal{K}$  représente le choix d'une clé
- $C \in \mathcal{C}$  représente le choix d'un chiffré
- on suppose que le message clair et la clé sont choisis de façon indépendante

# Cryptosystème parfaitement sûr

- On associe au cryptosystème  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  trois variables aléatoires :
- $M \in \mathcal{M}$  représente le choix d'un message clair
- $K \in \mathcal{K}$  représente le choix d'une clé
- $C \in \mathcal{C}$  représente le choix d'un chiffré
- on suppose que le message clair et la clé sont choisis de façon indépendante

# Cryptosystème parfaitement sûr

- On associe au cryptosystème  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  trois variables aléatoires :
- $M \in \mathcal{M}$  représente le choix d'un message clair
- $K \in \mathcal{K}$  représente le choix d'une clé
- $C \in \mathcal{C}$  représente le choix d'un chiffré
- on suppose que le message clair et la clé sont choisis de façon indépendante

# Cryptosystème parfaitement sûr

- On associe au cryptosystème  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$  trois variables aléatoires :
- $M \in \mathcal{M}$  représente le choix d'un message clair
- $K \in \mathcal{K}$  représente le choix d'une clé
- $C \in \mathcal{C}$  représente le choix d'un chiffré
- on suppose que le message clair et la clé sont choisis de façon indépendante

# Cryptosystème parfaitement sûr

## Définition

Soit un cryptosystème  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$ . Soient  $M$  et  $C$  les variables aléatoires représentant le choix d'un message clair et d'un chiffré. Le système est dit **parfaitement sûr** ssi

$$H(M|C) = H(M)$$

La connaissance du chiffré n'apporte aucune information sur le message clair.

# Cryptosystème parfaitement sûr

## Définition

Soit un cryptosystème  $(\mathcal{K}, \mathcal{M}, \mathcal{C}, E, D)$ . Soient  $M$  et  $C$  les variables aléatoires représentant le choix d'un message clair et d'un chiffré. Le système est dit **parfaitement sûr** ssi

$$H(M|C) = H(M)$$

La connaissance du chiffré n'apporte aucune information sur le message clair.

# Exemple de chiffrement parfaitement sûr : le chiffre de Vernam

- Cette méthode a été proposée en 1917.
- Les messages clairs sont des suites de bits de longueur  $n$ . L'espace des messages est alors  $\mathcal{M} = 0, 1^n$ .
- Les clés sont les suites binaires de même longueur que les messages :  $\mathcal{K} = \mathcal{M} = 0, 1^n$ .
- La fonction de chiffrement : pour tout  $m = m_1 \dots m_n$  et pour tout  $k = k_1 \dots k_n$

$$c = E(k, m) = k \oplus m = m_1 \oplus k_1 \dots m_n \oplus k_n$$

# Exemple de chiffrement parfaitement sûr : le chiffre de Vernam

- Cette méthode a été proposée en 1917.
- Les messages clairs sont des suites de bits de longueur  $n$ . L'espace des messages est alors  $\mathcal{M} = 0, 1^n$ .
- Les clés sont les suites binaires de même longueur que les messages :  $\mathcal{K} = \mathcal{M} = 0, 1^n$ .
- La fonction de chiffrement : pour tout  $m = m_1 \dots m_n$  et pour tout  $k = k_1 \dots k_n$

$$c = E(k, m) = k \oplus m = m_1 \oplus k_1 \dots m_n \oplus k_n$$

# Exemple de chiffrement parfaitement sûr : le chiffre de Vernam

- Cette méthode a été proposée en 1917.
- Les messages clairs sont des suites de bits de longueur  $n$ . L'espace des messages est alors  $\mathcal{M} = 0, 1^n$ .
- Les clés sont les suites binaires de même longueur que les messages :  $\mathcal{K} = \mathcal{M} = 0, 1^n$ .
- La fonction de chiffrement : pour tout  $m = m_1 \dots m_n$  et pour tout  $k = k_1 \dots k_n$

$$c = E(k, m) = k \oplus m = m_1 \oplus k_1 \dots m_n \oplus k_n$$

## Exemple de chiffrement parfaitement sûr : le chiffre de Vernam

- Cette méthode a été proposée en 1917.
- Les messages clairs sont des suites de bits de longueur  $n$ . L'espace des messages est alors  $\mathcal{M} = 0, 1^n$ .
- Les clés sont les suites binaires de même longueur que les messages :  $\mathcal{K} = \mathcal{M} = 0, 1^n$ .
- La fonction de chiffrement : pour tout  $m = m_1 \dots m_n$  et pour tout  $k = k_1 \dots k_n$

$$c = E(k, m) = k \oplus m = m_1 \oplus k_1 \dots m_n \oplus k_n$$

# Exemple de chiffrement parfaitement sûr : le chiffre de Vernam

## Proposition

Le chiffrement de Vernam est parfaitement sûr

## Théorème

Dans un système cryptographique parfaitement sûr on a

$$H(K) \geq H(M)$$

En particulier, si tous les messages et toutes les clés sont équiprobables, les clés sont de longueur au moins égale à celle des messages.

# Exemple de chiffrement parfaitement sûr : le chiffre de Vernam

## Proposition

Le chiffrement de Vernam est parfaitement sur

## Théorème

Dans un système cryptographique parfaitement sûr on a

$$H(K) \geq H(M)$$

En particulier, si tous les messages et toutes les clés sont équiprobables, les clés sont de longueur au moins égale à celle des messages.

# Attention ! Un chiffrement parfaitement sûr n'est pas invulnérable !

- Dans le cas de chiffrement de Vernam il suffit d'un bloc de message clair pour découvrir la clé :

$$k = c \oplus m$$

- Il est alors nécessaire de changer de clé à chaque bloc ; d'où le nom de "masque jetable" ;
- En pratique, cette procédure est très lourde : les clés ont la même longueur que les messages
- Ce chiffrement a été utilisé pour le téléphone rouge : la clé a été envoyée par porteur

# Attention ! Un chiffrement parfaitement sûr n'est pas invulnérable !

- Dans le cas de chiffrement de Vernam il suffit d'un bloc de message clair pour découvrir la clé :

$$k = c \oplus m$$

- Il est alors nécessaire de changer de clé à chaque bloc ; d'où le nom de "masque jetable" ;
- En pratique, cette procédure est très lourde : les clés ont la même longueur que les messages
- Ce chiffrement a été utilisé pour le téléphone rouge : la clé a été envoyée par porteur

# Attention ! Un chiffrement parfaitement sûr n'est pas invulnérable !

- Dans le cas de chiffrement de Vernam il suffit d'un bloc de message clair pour découvrir la clé :

$$k = c \oplus m$$

- Il est alors nécessaire de changer de clé à chaque bloc ; d'où le nom de "masque jetable" ;
- En pratique, cette procédure est très lourde : les clés ont la même longueur que les messages
- Ce chiffrement a été utilisé pour le téléphone rouge : la clé a été envoyée par porteur

# Attention ! Un chiffrement parfaitement sûr n'est pas invulnérable !

- Dans le cas de chiffrement de Vernam il suffit d'un bloc de message clair pour découvrir la clé :

$$k = c \oplus m$$

- Il est alors nécessaire de changer de clé à chaque bloc ; d'où le nom de "masque jetable" ;
- En pratique, cette procédure est très lourde : les clés ont la même longueur que les messages
- Ce chiffrement a été utilisé pour le téléphone rouge : la clé a été envoyée par porteur

# Le codage

D'une manière générale le codage peut être vu comme une transformation de symboles d'un alphabet donné  $\Omega_1 = \{s_1, \dots, s_n\}$  en suites de symboles d'un autre alphabet  $\Omega_2 = \{c_1, \dots, c_d\}$ .

# Deux problèmes de codage

- 1 **Codage de source ou encore codage sans bruit.** Sous cette hypothèse le meilleur code sera celui qui permettra la transmission la plus rapide possible. **Le premier théorème de Shannon** donne la solution à ce problème.
- 2 **Codage de canal ou encore codage en présence de bruit.** On cherchera une méthode de codage permettant une transmission aussi rapide que possible tout en minimisant la probabilité des erreurs. **Le second théorème de Shannon** donne la solution à ce problème.

# Deux problèmes de codage

- 1 **Codage de source ou encore codage sans bruit.** Sous cette hypothèse le meilleur code sera celui qui permettra la transmission la plus rapide possible. **Le premier théorème de Shannon** donne la solution à ce problème.
- 2 **Codage de canal ou encore codage en présence de bruit.** On cherchera une méthode de codage permettant une transmission aussi rapide que possible tout en minimisant la probabilité des erreurs. **Le second théorème de Shannon** donne la solution à ce problème.

# Vocabulaire

- **Lettre, symbole ou caractère** Tout élément d'un alphabet donné ;
- **Message ou mot** Une séquence finie  $m$  de caractères d'un alphabet donné ;
- **Longueur de mot** Le nombre  $l(m)$  de caractères d'un mot  $m$  ;

# Vocabulaire

- **Lettre, symbole ou caractère** Tout élément d'un alphabet donné ;
- **Message ou mot** Une séquence finie  $m$  de caractères d'un alphabet donné ;
- **Longueur de mot** Le nombre  $l(m)$  de caractères d'un mot  $m$  ;

# Vocabulaire

- **Lettre, symbole ou caractère** Tout élément d'un alphabet donné ;
- **Message ou mot** Une séquence finie  $m$  de caractères d'un alphabet donné ;
- **Longueur de mot** Le nombre  $l(m)$  de caractères d'un mot  $m$  ;

# Un code

- Soit **une source**  $S$  d'alphabet  $\Omega_S = \{s_1, \dots, s_n\}$  et de distribution de probabilité  $P_S = \{p_1, \dots, p_n\}$
- Un code est un ensemble  $\{m_1, m_2, \dots, m_n\}$  de  $n$  mots codes correspondant chacun à un symbole de l'alphabet de la source :  
 $\forall i = 1, \dots, n, m_i = m(s_i)$ .
- Soit  $l_i = l(m_i)$  les longueurs des mots  $m_i$  du code. On définit alors la longueur moyenne du code par

$$\bar{L} = E[L] = \sum_{i=1}^n p_i l_i$$

# Un code

- Soit **une source**  $S$  d'alphabet  $\Omega_S = \{s_1, \dots, s_n\}$  et de distribution de probabilité  $P_S = \{p_1, \dots, p_n\}$
- Un code est un ensemble  $\{m_1, m_2, \dots, m_n\}$  de  $n$  mots codes correspondant chacun à un symbole de l'alphabet de la source :  
 $\forall i = 1, \dots, n, m_i = m(s_i)$ .
- Soit  $l_i = l(m_i)$  les longueurs des mots  $m_i$  du code. On définit alors la longueur moyenne du code par

$$\bar{L} = E[L] = \sum_{i=1}^n p_i l_i$$

# Un code

- Soit **une source**  $S$  d'alphabet  $\Omega_S = \{s_1, \dots, s_n\}$  et de distribution de probabilité  $P_S = \{p_1, \dots, p_n\}$
- Un code est un ensemble  $\{m_1, m_2, \dots, m_n\}$  de  $n$  mots codes correspondant chacun à un symbole de l'alphabet de la source :  
 $\forall i = 1, \dots, n, m_i = m(s_i)$ .
- Soit  $l_i = l(m_i)$  **les longueurs des mots**  $m_i$  du code. On définit alors la **longueur moyenne du code** par

$$\bar{L} = E[L] = \sum_{i=1}^n p_i l_i$$

# Propriétés d'un code

- **Régularité** Un code  $\{m_1, m_2, \dots, m_n\}$  est dit régulier si tous les mots qui le composent sont distincts :  $m_i \neq m_k, \forall i \neq k$ . Un code qui n'est pas régulier est dit **singulier ou irréversible**.
- **Déchiffrabilité** Un code régulier est dit déchiffrable (ou encore à décodage unique) si pour toute suite de mots de code  $m^1 m^2 \dots m^k$  il est possible de distinguer sans ambiguïté tous les mots et donc identifier les symboles  $s^j, j = 1, \dots, k$  composant le message.

# Propriétés d'un code

- **Régularité** Un code  $\{m_1, m_2, \dots, m_n\}$  est dit régulier si tous les mots qui le composent sont distincts :  $m_i \neq m_k, \forall i \neq k$ . Un code qui n'est pas régulier est dit **singulier ou irréversible**.
- **Déchiffrabilité** Un code régulier est dit déchiffrable (ou encore à décodage unique) si pour toute suite de mots de code  $m^1 m^2 \dots m^k$  il est possible de distinguer sans ambiguïté tous les mots et donc identifier les symboles  $s^j, j = 1, \dots, k$  composant le message.

## Propriétés d'un code. Exemples

Soit  $\Omega_S = \{a, b, c, d\}$  de distribution de probabilité

$P_S = \{0.4, 0.3, 0.2, 0.1\}$ . L'entropie de cette source est  $H(S) \simeq 1.85$ .

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

Le code 1 n'est pas régulier. Le code 2 est un code de longueur fixe .

## Propriétés d'un code. Exemples

Soit  $\Omega_S = \{a, b, c, d\}$  de distribution de probabilité

$P_S = \{0.4, 0.3, 0.2, 0.1\}$ . L'entropie de cette source est  $H(S) \simeq 1.85$ .

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

Le code 1 n'est pas régulier. Le code 2 est un code de longueur fixe .

## Propriétés d'un code. Exemples

Soit  $\Omega_S = \{a, b, c, d\}$  de distribution de probabilité

$P_S = \{0.4, 0.3, 0.2, 0.1\}$ . L'entropie de cette source est  $H(S) \simeq 1.85$ .

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

Le code 1 n'est pas régulier. Le code 2 est un code de longueur fixe .

## Propriétés d'un code. Exemples

Soit  $\Omega_S = \{a, b, c, d\}$  de distribution de probabilité

$P_S = \{0.4, 0.3, 0.2, 0.1\}$ . L'entropie de cette source est  $H(S) \simeq 1.85$ .

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

Le code 1 n'est pas régulier. Le code 2 est un code **de longueur fixe** .

## Un code indéchiffrable

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

Le code 3 défini par  $\{0, 10, 01, 010\}$  est régulier mais pas déchiffrable.

La séquence 010 correspond à la fois à trois messages différents : "d", "ca" et "ab".

## Un code indéchiffrable

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

Le code 3 défini par  $\{0, 10, 01, 010\}$  est régulier mais pas déchiffrable.

La séquence 010 correspond à la fois à trois messages différents : "d", "ca" et "ab".

# Un code indéchiffrable

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

Le code 3 défini par  $\{0, 10, 01, 010\}$  est régulier mais pas déchiffrable.

La séquence 010 correspond à la fois à trois messages différents : "d", "ca" et "ab".

# Décodage unique : Solution 1.

## Codes de longueur fixe

Un code régulier de longueur fixe peut toujours être décodé sans ambiguïté.

Désavantage : la longueur moyenne n'est pas optimale.

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

# Décodage unique : Solution 1.

## Codes de longueur fixe

Un code régulier de longueur fixe peut toujours être décodé sans ambiguïté.

Désavantage : la longueur moyenne n'est pas optimale.

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

# Décodage unique : Solution 1.

## Codes de longueur fixe

Un code régulier de longueur fixe peut toujours être décodé sans ambiguïté.

**Désavantage** : la longueur moyenne n'est pas optimale.

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

# Décodage unique : Solution 1.

## Codes de longueur fixe

Un code régulier de longueur fixe peut toujours être décodé sans ambiguïté.

**Désavantage** : la longueur moyenne n'est pas optimale.

S	Proba	Code 1	Code 2	Code 3	Code 4	Code 5	Code 6
a	0.4	1	00	0	0	0	0
b	0.3	0	01	10	01	10	11
c	0.2	1	10	01	011	110	100
d	0.1	0	11	010	0111	1110	101
	Long. Moy.	1	2	1.7	2	2	1.9

## Codes de longueur fixe. Exemple. Encodage de texte

**Les formats courants d'encodage de caractères d'un texte sont les codes à longueur fixe**

- Le code **ASCII** (American Standard Code for Information Interchange) utilise 8 bits (1 octet) dont un bit de parité pour chaque caractère. Il est possible de représenter 128 ( $2^7$ ) caractères.
- La norme **ISO 8859-1** représente 191 caractères, chacun sur 1 octet.
- Les standards du consortium **UNICODE**, utilisent une représentation des caractères sur 2 octets (16 bits). Le format **UTF-16** (Universal Transformation Format, 16 bits) utilise 2 octets pour chaque caractère. **UTF-8** utilise un nombre variable d'octets ( de 2 à 4 ) en fonction du numéro de caractère.

## Codes de longueur fixe. Exemple. Encodage de texte

**Les formats courants d'encodage de caractères d'un texte sont les codes à longueur fixe**

- Le code **ASCII** (American Standard Code for Information Interchange) utilise 8 bits (1 octet) dont un bit de parité pour chaque caractère. Il est possible de représenter 128 ( $2^7$ ) caractères.
- La norme **ISO 8859-1** représente 191 caractères, chacun sur 1 octet.
- Les standards du consortium UNICODÉ, utilisent une représentation des caractères sur 2 octets (16 bits). Le format UTF-16 (Universal Transformation Format, 16 bits) utilise 2 octets pour chaque caractère. UTF-8 utilise un nombre variable d'octets ( de 2 à 4) en fonction du numéro de caractère.

## Codes de longueur fixe. Exemple. Encodage de texte

**Les formats courants d'encodage de caractères d'un texte sont les codes à longueur fixe**

- Le code **ASCII** (American Standard Code for Information Interchange) utilise 8 bits (1 octet) dont un bit de parité pour chaque caractère. Il est possible de représenter 128 ( $2^7$ ) caractères.
- La norme **ISO 8859-1** représente 191 caractères, chacun sur 1 octet.
- Les standards du consortium UNICODE, utilisent une représentation des caractères sur 2 octets (16 bits). Le format UTF-16 (Universal Transformation Format, 16 bits) utilise 2 octets pour chaque caractère. UTF-8 utilise un nombre variable d'octets ( de 2 à 4) en fonction du numéro de caractère.

## Codes de longueur fixe. Exemple. La norme ISO-8859-1

ISO/CEI 8859-1																
	x0	x1	x2	x3	x4	x5	x6	x7	x8	x9	xA	xB	xC	xD	xE	xF
0x	<i>caractères de contrôle et divers non imprimables</i>															
1x	<i>caractères de contrôle et divers non imprimables</i>															
2x		!	"	#	\$	%	&	'	( )	*	+	,	-	.	/	
3x	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4x	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5x	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6x	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7x	p	q	r	s	t	u	v	w	x	y	z	{		}	~	
8x	<i>caractères de contrôle et divers non imprimables</i>															
9x	<i>caractères de contrôle et divers non imprimables</i>															
Ax		ı	¢	£	¤	¥	¦	§	¨	©	ª	«	¬		®	¯
Bx	°	±	²	³	´	µ	¶	·	,	ı	º	»	¼	½	¾	¿
Cx	À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
Dx	Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
Ex	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
Fx	ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

## Décodage unique : Solution 2.

### Utilisation d'un séparateur

Pour un canal binaire, on peut coder le  $i$ -ème symbole de la source  $s_i$  à l'aide de  $i$  caractères "1" et utiliser "0" comme séparateur.

S	Proba	Code 1
a	0.4	10
b	0.3	110
c	0.2	1110
d	0.1	11110
	Long. Moy.	3

et la séquence "abc" donnerait "101101110"

On constate que la longueur moyenne qui tient compte du séparateur est plus élevée que tous les autres codes.

## Décodage unique : Solution 2.

### Utilisation d'un séparateur

Pour un canal binaire, on peut coder le  $i$ -ème symbole de la source  $s_i$  à l'aide de  $i$  caractères "1" et utiliser "0" comme séparateur.

S	Proba	Code 1
a	0.4	10
b	0.3	110
c	0.2	1110
d	0.1	11110
	Long. Moy.	3

et la séquence "abc" donnerait "101101110"

On constate que la longueur moyenne qui tient compte du séparateur est plus élevée que tous les autres codes.

## Décodage unique : Solution 2.

### Utilisation d'un séparateur

Pour un canal binaire, on peut coder le  $i$ -ème symbole de la source  $s_i$  à l'aide de  $i$  caractères "1" et utiliser "0" comme séparateur.

S	Proba	Code 1
a	0.4	10
b	0.3	110
c	0.2	1110
d	0.1	11110
	Long. Moy.	3

et la séquence "abc" donnerait "101101110"

On constate que la longueur moyenne qui tient compte du séparateur est plus élevée que tous les autres codes.

## Décodage unique : Solution 2.

### Utilisation d'un séparateur

Pour un canal binaire, on peut coder le  $i$ -ème symbole de la source  $s_i$  à l'aide de  $i$  caractères "1" et utiliser "0" comme séparateur.

S	Proba	Code 1
a	0.4	10
b	0.3	110
c	0.2	1110
d	0.1	11110
	Long. Moy.	3

et la séquence "abc" donnerait "101101110"

On constate que la longueur moyenne qui tient compte du séparateur est plus élevée que tous les autres codes.

## Décodage unique : Solution 3

### Préfixe

On dit qu'un mot  $W$  est **un préfixe** d'un autre mot  $V$  s'il existe un mot  $U$  tel que  $V = WU$ . Autrement dit, le mot  $V$  commence par le mot  $W$ .

### Un code instantané ou sans préfixe

On dit qu'un code donné est **sans préfixe** ou **instantané** si aucun mot du code n'est un préfixe d'un autre.

Le code  $\mathcal{C}$  défini par  $\{0, 11, 100, 101\}$  est sans préfixe.

## Décodage unique : Solution 3

### Préfixe

On dit qu'un mot  $W$  est **un préfixe** d'un autre mot  $V$  s'il existe un mot  $U$  tel que  $V = WU$ . Autrement dit, le mot  $V$  commence par le mot  $W$ .

### Un code instantané ou sans préfixe

On dit qu'un code donné est **sans préfixe** ou **instantané** si aucun mot du code n'est un préfixe d'un autre.

Le code  $C$  défini par  $\{0, 11, 100, 101\}$  est sans préfixe.

## Décodage unique : Solution 3

### Préfixe

On dit qu'un mot  $W$  est **un préfixe** d'un autre mot  $V$  s'il existe un mot  $U$  tel que  $V = WU$ . Autrement dit, le mot  $V$  commence par le mot  $W$ .

### Un code instantané ou sans préfixe

On dit qu'un code donné est **sans préfixe** ou **instantané** si aucun mot du code n'est un préfixe d'un autre.

Le code 6 défini par  $\{0, 11, 100, 101\}$  est sans préfixe.

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- ➊ Pas 1 Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- ➋ Pas 2  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- ➌ Pas 3  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- ➍ Pas 4  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- ➎ Pas 5  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- ➏ Pas 6  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

# Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- ① **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- ② **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- ③ **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- ④ **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- ⑤ **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- ⑥ **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- 1 **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- 2 **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- 3 **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- 4 **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- 5 **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- 6 **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- 1 **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- 2 **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- 3 **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- 4 **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- 5 **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- 6 **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- ➊ **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- ➋ **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- ➌ **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- ➍ **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- ➎ **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- ➏ **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- 1 **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- 2 **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- 3 **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- 4 **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- 5 **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- 6 **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- ① **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- ② **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- ③ **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- ④ **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- ⑤ **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- ⑥ **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- ① **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- ② **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- ③ **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- ④ **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- ⑤ **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- ⑥ **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

## Décodage d'un code sans préfixe

Prenons une séquence  $W = 011010011101$  du code 6 donné par  $\{0, 11, 100, 101\}$ .

- ① **Pas 1** Le premier mot du code formé en lisant de gauche à droite est  $m^1 = "0"$ . Donc le premier symbole est  $s^1 = a$ . On sépare le mot  $m^1$  de la séquence. On obtient la nouvelle séquence  $W_1 = 11010011101$ .
- ② **Pas 2**  $m^2 = "11" \Rightarrow s^2 = b$  et  $W_2 = 010011101$ .
- ③ **Pas 3**  $m^3 = "0" \Rightarrow s^3 = a$  et  $W_3 = 10011101$ .
- ④ **Pas 4**  $m^4 = "100" \Rightarrow s^4 = c$  et  $W_4 = 11101$ .
- ⑤ **Pas 5**  $m^5 = "11" \Rightarrow s^5 = b$  et  $W_5 = 101$ .
- ⑥ **Pas 6**  $m^6 = "101" \Rightarrow s^6 = d$  et  $W_6 = \emptyset$ .

On obtient en symboles de l'alphabet de la source :  $abacbd$ .

# Codes instantanés : existence

## Problème

Soient l'alphabet de la source  $\Omega_S = \{s_1, \dots, s_n\}$  de taille  $n$  et l'alphabet du canal  $\Omega_C = \{c_1, \dots, c_d\}$  de taille  $d$ . Étant donnés  $n$  nombres entiers positifs  $(l_1, l_2, \dots, l_n) \in \mathbb{Z}_+^*$  existe-t-il un code régulier instantané de  $n$  mots  $\{m_1, \dots, m_n\}$  tel que chaque nombre  $l_i$  soit la longueur du mot de code  $m_i$  ?

# Inégalité de Kraft

## Théorème

Un code instantané de longueurs de mots données  $l_1, \dots, l_n$  existe si et seulement si

$$\sum_{i=1}^n d^{-l_i} \leq 1$$

où  $d$  est la taille de l'alphabet du canal.

## Application aux codes binaires

L'alphabet du canal est  $\Omega_C = \{0, 1\}$  de taille  $d = 2$ . Alors un code instantané de longueurs de mots données  $l_1, \dots, l_n$  existe si et seulement si

$$\sum_{i=1}^n 2^{-l_i} \leq 1.$$

# Inégalité de Kraft

## Théorème

Un code instantané de longueurs de mots données  $l_1, \dots, l_n$  existe si et seulement si

$$\sum_{i=1}^n d^{-l_i} \leq 1$$

où  $d$  est la taille de l'alphabet du canal.

## Application aux codes binaires

L'alphabet du canal est  $\Omega_C = \{0, 1\}$  de taille  $d = 2$ . Alors un code instantané de longueurs de mots données  $l_1, \dots, l_n$  existe si et seulement si

$$\sum_{i=1}^n 2^{-l_i} \leq 1.$$

# Arbres binaires

- 1 Un arbre binaire est un graphe orienté  $(N, R)$  où  $N$  est un ensemble de nœuds et  $R \subset N \times N$  est un ensemble d'arcs.
- 2 Chaque nœud a au plus deux fils et chaque nœud sauf la racine a exactement un père.
- 3 Les nœuds qui n'ont pas de fils s'appellent feuilles de l'arbre.
- 4 On dit qu'un nœud est de **niveau**  $n$  si le chemin qui le relie à la racine est de longueur  $n$ .
- 5 On appelle **profondeur** d'un arbre la longueur du plus long chemin partant de la racine.
- 6 **Arbre binaire complet de profondeur  $n$**  : tous les nœuds sauf les feuilles ont exactement 2 fils.
- 7 **Arbre binaire incomplet** : tous les nœuds ont 2 ou 0 fils.

# Arbres binaires

- 1 Un arbre binaire est un graphe orienté  $(N, R)$  où  $N$  est un ensemble de nœuds et  $R \subset N \times N$  est un ensemble d'arcs.
- 2 Chaque nœud a au plus deux fils et chaque nœud sauf la racine a exactement un père.
- 3 Les nœuds qui n'ont pas de fils s'appellent feuilles de l'arbre.
- 4 On dit qu'un nœud est de **niveau**  $n$  si le chemin qui le relie à la racine est de longueur  $n$ .
- 5 On appelle **profondeur** d'un arbre la longueur du plus long chemin partant de la racine.
- 6 **Arbre binaire complet de profondeur  $n$**  : tous les nœuds sauf les feuilles ont exactement 2 fils.
- 7 **Arbre binaire incomplet** : tous les nœuds ont 2 ou 0 fils.

# Arbres binaires

- 1 Un arbre binaire est un graphe orienté  $(N, R)$  où  $N$  est un ensemble de nœuds et  $R \subset N \times N$  est un ensemble d'arcs.
- 2 Chaque nœud a au plus deux fils et chaque nœud sauf la racine a exactement un père.
- 3 Les nœuds qui n'ont pas de fils s'appellent feuilles de l'arbre.
- 4 On dit qu'un nœud est de **niveau**  $n$  si le chemin qui le relie à la racine est de longueur  $n$ .
- 5 On appelle **profondeur** d'un arbre la longueur du plus long chemin partant de la racine.
- 6 **Arbre binaire complet de profondeur  $n$**  : tous les nœuds sauf les feuilles ont **exactement** 2 fils.
- 7 **Arbre binaire incomplet** : tous les nœuds ont 2 ou 0 fils.

# Arbres binaires

- 1 Un arbre binaire est un graphe orienté  $(N, R)$  où  $N$  est un ensemble de nœuds et  $R \subset N \times N$  est un ensemble d'arcs.
- 2 Chaque nœud a au plus deux fils et chaque nœud sauf la racine a exactement un père.
- 3 Les nœuds qui n'ont pas de fils s'appellent feuilles de l'arbre.
- 4 On dit qu'un nœud est de **niveau**  $n$  si le chemin qui le relie à la racine est de longueur  $n$ .
- 5 On appelle **profondeur** d'un arbre la longueur du plus long chemin partant de la racine.
- 6 **Arbre binaire complet de profondeur**  $n$  : tous les nœuds sauf les feuilles ont **exactement** 2 fils.
- 7 **Arbre binaire incomplet** : tous les nœuds ont 2 ou 0 fils.

# Arbres binaires

- 1 Un arbre binaire est un graphe orienté  $(N, R)$  où  $N$  est un ensemble de nœuds et  $R \subset N \times N$  est un ensemble d'arcs.
- 2 Chaque nœud a au plus deux fils et chaque nœud sauf la racine a exactement un père.
- 3 Les nœuds qui n'ont pas de fils s'appellent feuilles de l'arbre.
- 4 On dit qu'un nœud est de **niveau**  $n$  si le chemin qui le relie à la racine est de longueur  $n$ .
- 5 On appelle **profondeur** d'un arbre la longueur du plus long chemin partant de la racine.
- 6 Arbre binaire complet de **profondeur**  $n$  : tous les nœuds sauf les feuilles ont **exactement** 2 fils.
- 7 Arbre binaire incomplet : tous les nœuds ont 2 ou 0 fils.

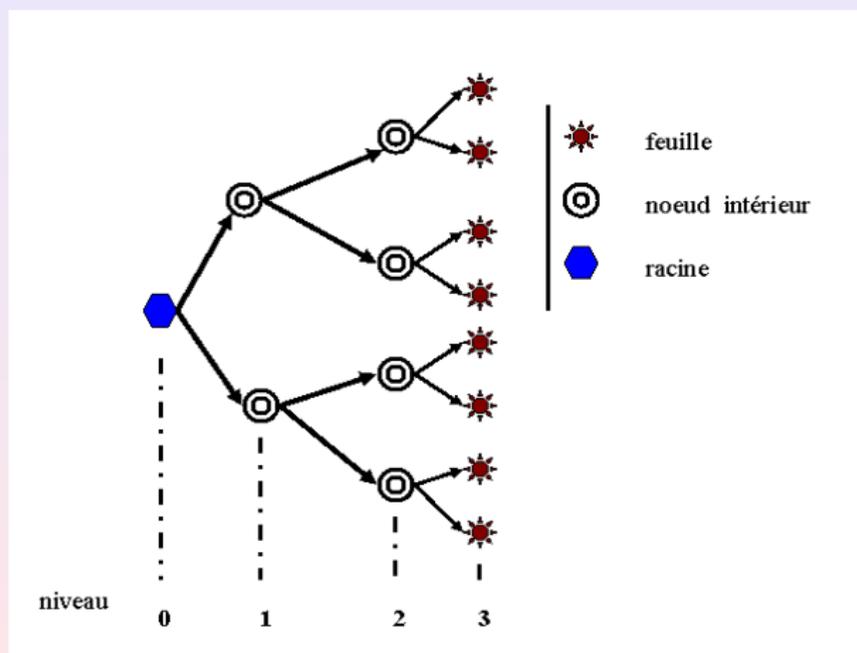
# Arbres binaires

- 1 Un arbre binaire est un graphe orienté  $(N, R)$  où  $N$  est un ensemble de nœuds et  $R \subset N \times N$  est un ensemble d'arcs.
- 2 Chaque nœud a au plus deux fils et chaque nœud sauf la racine a exactement un père.
- 3 Les nœuds qui n'ont pas de fils s'appellent feuilles de l'arbre.
- 4 On dit qu'un nœud est de **niveau**  $n$  si le chemin qui le relie à la racine est de longueur  $n$ .
- 5 On appelle **profondeur** d'un arbre la longueur du plus long chemin partant de la racine.
- 6 **Arbre binaire complet de profondeur**  $n$  : tous les nœuds sauf les feuilles ont **exactement** 2 fils.
- 7 **Arbre binaire incomplet** : tous les nœuds ont 2 ou 0 fils.

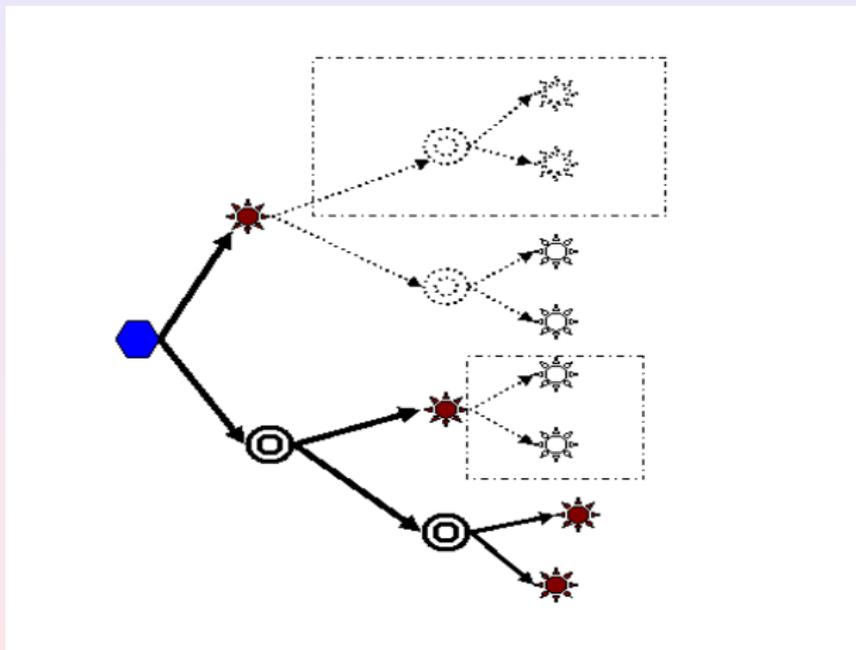
# Arbres binaires

- 1 Un arbre binaire est un graphe orienté  $(N, R)$  où  $N$  est un ensemble de nœuds et  $R \subset N \times N$  est un ensemble d'arcs.
- 2 Chaque nœud a au plus deux fils et chaque nœud sauf la racine a exactement un père.
- 3 Les nœuds qui n'ont pas de fils s'appellent feuilles de l'arbre.
- 4 On dit qu'un nœud est de **niveau**  $n$  si le chemin qui le relie à la racine est de longueur  $n$ .
- 5 On appelle **profondeur** d'un arbre la longueur du plus long chemin partant de la racine.
- 6 **Arbre binaire complet de profondeur**  $n$  : tous les nœuds sauf les feuilles ont **exactement** 2 fils.
- 7 **Arbre binaire incomplet** : tous les nœuds ont 2 ou 0 fils.

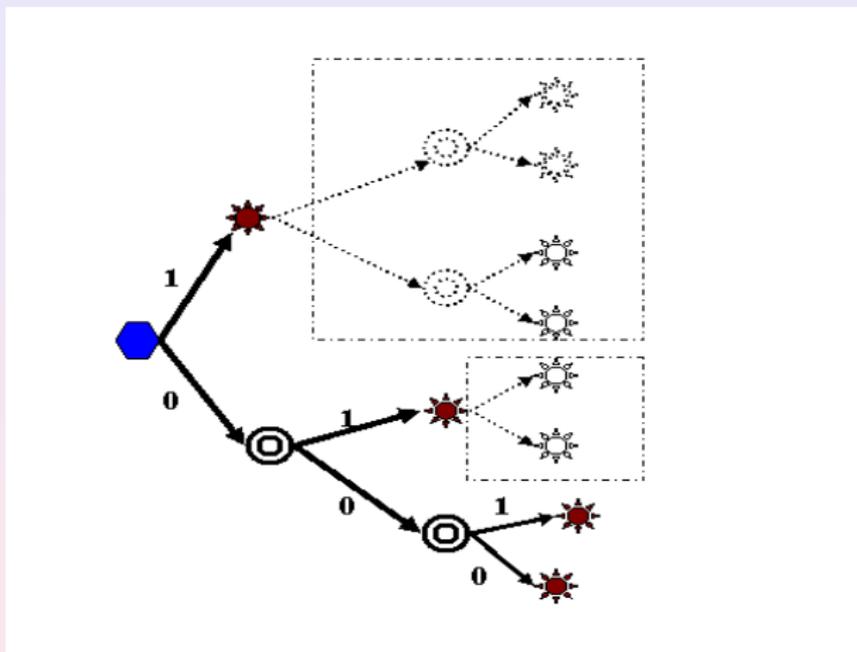
# Exemple : arbre complet



# Exemple : arbre incomplet



## Exemple : associer un code à un arbre incomplet



Le code associé est  $\{1, 01, 001, 000\}$ .