

Informatique multimédia

- ✓ Compression des documents du multimédia
- Formats de diffusion



Benoît Piranda
Équipe SISAR
Université de Marne La Vallée
piranda@univ-mlv.fr
<http://www-igm.univ-mlv.fr/~piranda>

Les algorithmes de compression

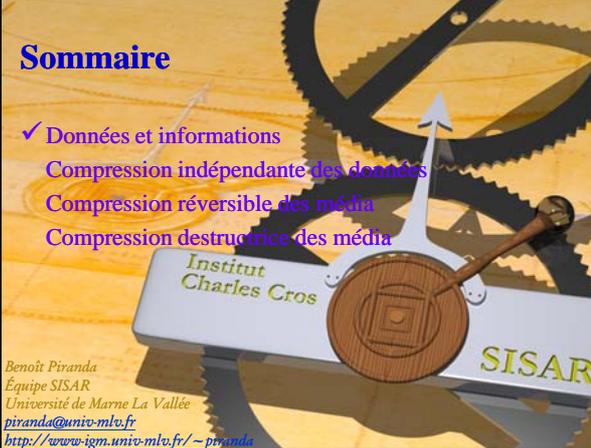
- Compression de données quelconques
 - indépendante du type de données
 - compression sans perte
 - codage des événements plutôt que des données
 - exploitation des corrélations dans les données
- Compression de média
 - exploitation de la cohérence dans les données
 - son : cohérence temporelle
 - image : cohérence spatiale
 - animation : cohérence spatio-temporelle
 - compression sans perte
 - méthodes de codage de la cohérence
 - compression avec perte
 - suppression des informations peu significatives

Principes de compression

- Compression de données sans perte
 - Réduire la taille des données en supprimant des redondances
 - ☑ Processus réversible,
 - ☑ Valable pour tout type de données,
 - ☒ Gain théoriquement assez faible.
- Compression dégradante
 - Suppression des informations « peu importantes »
 - ☒ Compression non réversible
 - ☑ Gain de compression très grand

Sommaire

- ✓ Données et informations
- Compression indépendante des données
- Compression réversible des média
- Compression destructrice des média



Benoît Piranda
Équipe SISAR
Université de Marne La Vallée
piranda@univ-mlv.fr
<http://www-igm.univ-mlv.fr/~piranda>

La compression de données

- Évaluation de la compression
 - quotient de compression Q

$$Q = \frac{\text{Taille initiale}}{\text{Taille compressée}}$$
 - taux de compression T (exprimé en pourcentage)

$$T = \frac{1}{Q}$$
 - gain de compression G

$$G = 1 - T$$

Information et signal

- Source ou signal
 - tout processus générant de l'information
 - séquence finie ou infinie d'événements
- Les événements
 - sont codés sur un alphabet (liste des valeurs possibles)
- Différents types de source
 - texte :
 - symbole = les lettres de l'alphabet latin, grec...
 - signal numérique
 - symbole = bits ou octets
 - son, image numérique
 - symbole = échantillons

Source Markovienne

- Source markovienne (théorique)
 - source aléatoire
 - pas de cohérences entre les symboles
 - ordre de la source markovienne : nombre de caractères minimum formant des symboles non corrélés.

abacbbabbbacab... Alphabet : {a,b,c}

14 caractères

abacbbabbbacab... Alphabet : {ab,bb,ac}

7 caractères

L'information dans les données

- L'information réside dans la succession des données
 - signal, chaîne ou séquence de symboles
- Quantité d'information
 - liée à l'entropie du signal
 - entropie : incertitude entre deux messages successifs
 - données constantes
 - entropie nulle
 - information très réduite

Un exemple : le scrabble

- Jeu consistant à écrire des mots qui rapportent des points en sommant les valeurs associées à chacune des lettres qui le compose.
- Plus une lettre est rare dans la langue considérée plus le nombre de points associé est grand
 - lettres rares de la langue française (K W X Y Z) : 10 points,
 - lettres courantes : 1 points

Probabilité et occurrence

- Considérons une source finie de type texte
 - Ecole nationale des ponts et chaussées
 - alphabet : 16 symboles
- Occurrence et probabilité de chacun des symboles

Lettre	occurrence	probabilité	Lettre	occurrence	probabilité
a	3	7,89%	o	3	7,89%
c	2	5,26%	p	1	2,63%
d	1	2,63%	s	5	13,16%
e	5	13,16%	t	3	7,89%
h	1	2,63%	u	1	2,63%
i	1	2,63%	é	1	2,63%
l	2	5,26%	–	5	13,16%
n	3	7,89%	È	1	2,63%

Sommaire

Données et informations

✓ Compression indépendante des données

Compression réversible des média

Compression destructrice des média

Benoît Piranda
Équipe SISAR
Université de Marne La Vallée
piranda@univ-mlv.fr
<http://www-igm.univ-mlv.fr/~piranda>

Compression indépendante des données

- Codage entropique ou Code à longueur variable (VLC)
- Idée : codage statistique à longueur variable
 - coder les données fréquentes par un codage plus court
- Compression réversible
- Utilisation courante en complément d'autres méthodes
 - PhotoCD,
 - JPEG,
 - MPEG Audio
 - MPEG

Codage entropique

- **Méthode**
 - codage de l'alphabet par des données de longueurs variables
 - décodage capable de retrouver la séparation entre les symboles de codage
 - caractère spécial entre les symboles
 - structure des codes permettant de retrouver leur début
- **Méthode de Shanon-Fano**
- **Méthode de Huffman**
- **Codage arithmétique**

Algorithme du codage de Huffman

- **Optimisation de la méthode de Shanon-Fano**
- **Etude statistique des données**
 - Ordonner dans une tables, les symboles par ordre d'occurrence
- **Construction de l'arbre**
 - Définir un arbre binaire contenant les symboles
 - Plus les symboles sont rares plus ils sont placés profondément dans l'arbre
- **Construction du code**
 - À chaque symbole on associe un code binaire dont la taille dépend de la profondeur
 - Code permettant le décodage des symboles (frontière entre les codes)

Algorithme de Huffman par l'exemple

- **Codage d'une chaîne ADN**
 - Alphabet $A=\{A,C,G,T\}$ codables sur 2 bits
 - Séquence à compresser : 48 lettres soit 96 bits

TTCATTGTACCTGTTATTAGATTAGTCTAGATTTAGTACTATATCTT

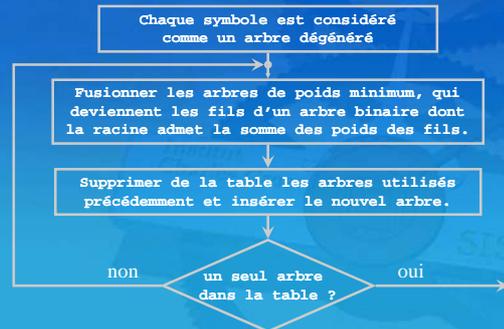
- **Etude des données**
 - Fréquence d'apparition de chaque lettre :

$$p_A = \frac{12}{48}, p_C = \frac{6}{48}, p_G = \frac{6}{48}, p_T = \frac{24}{48}$$
 - Table des symboles ordonnés (et nombre d'occurrences) :

C(6)	G(6)	A(12)	T(24)
------	------	-------	-------

Algorithme de Huffman par l'exemple

- **Construction de l'arbre**



Algorithme de Huffman par l'exemple

C(6)	G(6)	A(12)	T(24)
------	------	-------	-------



Algorithme de Huffman par l'exemple

- **Construction des codes**

- association des valeurs binaires
 - 0 aux brins de gauche
 - 1 aux brins de droite
- le code associé au symbole est obtenu en mémorisant les valeurs des brins parcourus pour aller de la racine de l'arbre à la feuille contenant le symbole.



T → 0
 A → 10
 C → 110
 G → 111

Décodage arithmétique

- **Symétrie au codage**

- Utilisation de la formule de codage du réel codant la séquence

$$V_{s_i, s_i} = \sum_{l=1}^{i-1} p(S_l) + p(S_i) \left(\sum_{m=1}^{i-1} p(S_m) + p(S_i) \sum_{n=1}^{i-1} p(S_n) \right)$$

- besoin de connaître la fréquence de chaque symbole

0 < 0,30615774 < 0.5 → A → (0,30615774 - 0) / 0.5
 0.5 < 0,61231548 < 0.75 → B → (0,61231548 - 0.5) / 0.25
 0 < 0,44926192 < 0.5 → A → (0,44926192 - 0) / 0.5
 0.75 < 0,89852384 < 1.0 → C → (0,89852384 - 0.75) / 0.25
 0.5 < 0,59409536 < 0.75 → B → (0,59409536 - 0.5) / 0.25
 0 < 0,37638144 < 0.5 → A → (0,37638144 - 0) / 0.5
 0.75 < 0,75276288 < 1.0 → C → (0,75276288 - 0.75) / 0.25
 – possibilité de définir un algorithme n'utilisant que des entiers

Méthodes à base de dictionnaires

- **Principe**

- Recherche des corrélations dans la source
- Codage des ensembles de symboles corrélés

- **Utilisation de dictionnaires**

- **statiques**
 - connaissance à priori des corrélations
 - statistique sur des sources du même type
- **dynamiques ou adaptatifs**
 - acquisition du dictionnaire au cours de la lecture de la source

Compression à base de dictionnaires

- **Codage par dictionnaires statiques**

- **Connaissances préalables**
 - ensemble des échantillons des données
 - statistique à priori sur les données

- **Exemple : compresser un texte en français**

- **statistique sur la fréquence d'apparition des lettres**
 - 'e' très probable
- **statistique sur la fréquence de succession des lettres**
 - 'q' suivit de 'u' très probable

Compression à base de dictionnaires

- **Codage par dictionnaire dynamique**

- **Méthode de Lempel-Ziv-Welch (LZ77, LZ78, LZW)**
 - dictionnaire dynamique construit au cours de la lecture du fichier
 - une seule lecture est nécessaire
- **utilisation**
 - compression de fichiers gzip, Pkzip, Arj...
 - sauvegarde MS Backup, Norton Backup...
 - compresseur temps réel : stacker, Dblspace,...
 - compression d'images : option du format TIFF

Méthode Lempel-Ziv 77

- **Principe**

- **utilisation d'une fenêtre sur les données**
 - zone des données utilisée pour rechercher des corrélations
 - visualisant N symboles, divisée en deux parties
 - ✓ B_R la partie recherche N_R (~4096)
 - ✓ B_E la partie encodage N_E (~128)
- **rechercher dans B_R la plus longue sous chaîne égale à la plus longue suite de symbole de B_E**
- **constitue le triplet <a,l,c>**
 - a = adresse du début
 - l = longueur de la séquence identique
 - c = nouveau caractère ajouté au dictionnaire
- **résultat : liste des triplets <a,l,c>**

Méthode Lempel-Ziv 77 par l'exemple

- **Exemple de compression d'une chaîne de caractères**

- S={ABADBADECBADECBADBECEBAEDB}
- avec N_R=8 et N_E=8

- **Quantité de données**

- **source : 1 octet par caractère**
- **triplet de compression : 14 bits**
 - adresse : 3bits
 - longueur : 3 bits
 - caractère suivant : 1 octet

Algorithme Lempel-Ziv 77

- Lecture du buffer B_E
- Trois situations
 - Pas de chaîne commune
 - par exemple à l'initialisation : buffer vide
 - caractère codé par le triplet $\langle 0,0,'A' \rangle$:
 - ✓ position à droite de $B_R(0)$,
 - ✓ longueur de la chaîne trouvée = 0
 - ✓ puis le caractère lui-même
 - Plusieurs chaînes de B_R correspondent à B_E
 - on choisit la plus longue placée la plus à gauche de B_R
 - La chaîne la plus longue déborde sur B_E
 - cas critique
- Décalage de la fenêtre de l+1

Méthode Lempel-Ziv 77 par l'exemple

Dictionnaire		Texte codé
B_R	B_E	
8 7 6 5 4 3 2 1	ABADDBADECEB	Situation 1 : ' A ' n'est Situation 1 : ' B ' n'est Chaîne trouvée : ' A ' position 2, longueur 1. Chaîne trouvée : ' BAD ' position 3, longueur 3. Situation 1 : ' C ' n'est Chaîne trouvée : position 6, longueur 1. Chaîne trouvée : position 6, longueur 1. Nouveau caractère : ' E ' fin
	ABADDBADECEB	

Méthode Lempel-Ziv 77

- Bilan de la compression précédente
 - 9 triplets de 14 bits soit 126 bits
 - source de 26 octets soit 208 bits
 - gain de 39,4 %
- Avantages et inconvénients
 - pas besoin de données supplémentaires
 - mémoire courte :
 - ce qui sort de la fenêtre de recherche est oublié
 - fenêtre de taille réduite, définie a priori
 - décodage simple et rapide

Décodage de Lempel-Ziv 77

- Le dictionnaire est reconstruit de gauche à droite à partir des triplets

ABADDBADECEB	$\langle 0,0,'C' \rangle$	$\langle 8,4,'E' \rangle$	$\langle 6,7,'B' \rangle$
ABADDBADECEB	$\langle 8,4,'E' \rangle$	$\langle 6,7,'B' \rangle$	
ABADDBADECEB	$\langle 8,4,'E' \rangle$	$\langle 6,7,'B' \rangle$	$\langle 6,1,'E' \rangle$
ABADDBADECEB	$\langle 6,1,'E' \rangle$	$\langle 7,1,'D' \rangle$	
ABADDBADECEB	$\langle 6,7,'B' \rangle$	$\langle 6,1,'E' \rangle$	$\langle 7,1,'D' \rangle$
ABADDBADECEB	$\langle 6,7,'B' \rangle$	$\langle 6,1,'E' \rangle$	$\langle 7,1,'D' \rangle$

Procéder en deux étapes :

ABADDBADECEB	ABADDBADECEB
ABADDBADECEB	ABADDBADECEB

Méthode Lempel-Ziv 78

- Principe
 - Ajout d'un dictionnaire explicite à LZ77
 - Le dictionnaire contient tous les motifs trouvés
- Algorithme
 - On construit les couples $\langle a,c \rangle$
 - a : adresse du plus grand motif du dictionnaire
 - c : nouveau caractère
 - plus besoin de coder la longueur
 - on ajoute le nouveau motif au dictionnaire
 - motif trouvé + nouveau caractère

Méthode Lempel-Ziv 78 par l'exemple

Exemple de compression d'une chaîne de caractères

ABADDBADECEB ADBE CBADEB CBADEB CBADEB C

Entrée		Dictionnaire		Sortie
motif	Car. suiv.	index	Motif	couple
	A	1	A	$\langle 0,'A' \rangle$
	B	2	B	$\langle 0,'B' \rangle$
A	D	3	AD	$\langle 1,'D' \rangle$
B	A	4	BA	$\langle 2,'A' \rangle$
	D	5	D	$\langle 0,'D' \rangle$
BA	D	6	BAD	$\langle 4,'D' \rangle$
	E	7	E	$\langle 0,'E' \rangle$
	C	8	C	$\langle 0,'C' \rangle$
BAD	B	9	BADB	$\langle 6,'B' \rangle$
E	C	10	EC	$\langle 7,'C' \rangle$
BADB	E	11	BADBE	$\langle 9,'E' \rangle$
C	B	12	CB	$\langle 8,'B' \rangle$
AD	B	13	ADB	$\langle 3,'B' \rangle$
EC	D	14	ECD	$\langle 10,'D' \rangle$

Décodage Lempel-Ziv 78

- **Décodage symétrique au codage**
 - données
 - Couples
 - dictionnaire

Couple	Dictionnaire	Sortie
<0, 'A'>	1 A	A
<0, 'B'>	2 B	B
<1, 'D'>	3 AD	A D
<2, 'A'>	4 BA	B A
<0, 'D'>	5 D	D
<4, 'D'>	6 BAD	BA D
<0, 'E'>	7 E	E
<0, 'C'>	8 C	C
<6, 'B'>	9 BADB	BAD B
<7, 'C'>	10 EC	E C
<9, 'E'>	11 BADBE	BADB E
<8, 'B'>	12 CB	C B
<3, 'B'>	13 ADB	AD B
<10, 'D'>	14 ECD	EC D

Méthode de Lempel-Ziv-Welch

- **Variante de LZ78**
 - Dictionnaire prédéfini initialisé avec tous les symboles de l'alphabet
 - partie statique
 - nouveau symbole = index du dictionnaire
 - résultat : liste d'adresses dans le dictionnaire
- **Fait l'objet d'un brevet**

Méthode LZW par l'exemple

- **Exemple de compression d'une chaîne de caractères**

A B B A D B A D B C B A D B E C B A D B E C B D

Entrée		Dictionnaire		Sortie
motif	Car. suiv.	Index	Motif	adresse
∅	A	6	AB	1
A	B	7	BA	2
B	A	8	AD	1
A	D	9	DB	4
D	B			
B	A			
BA	D	10	BAD	7
D	E	11	DE	4
E	C	12	EC	5
C	B	13	CB	2
:	:	:	:	:

Sommaire

- Données et informations
- Compression indépendante des données
- ✓ Compression réversible des média
- Compression destructrice des média

Institut Charles Cros
SISAR

Benoît Piranda
Équipe SISAR
Université de Marne La Vallée
piranda@univ-mlv.fr
<http://www-igm.univ-mlv.fr/~piranda>

Compression de média

- **Compression sans perte du son**
- **Méthode des différences**
 - Exploitation de la cohérence temporelle
 - Perte liée à cette méthode

Sons de synthèse

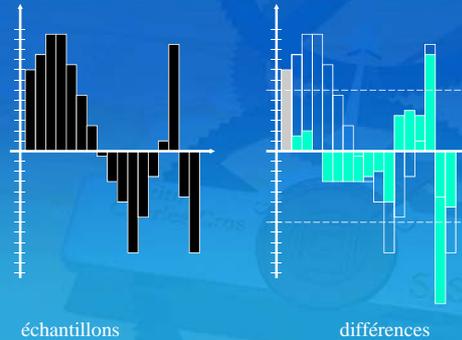
0,441 kHz

44,1 kHz

Méthodes différentielles

- Codage de la différence entre deux échantillons successifs
 - grande probabilité de valeurs proches de 0
 - échantillons sur n octets sont codés sur $n/2$ octets
 - gain théorique 50%
 - perte des signaux hautes fréquences
 - propagation d'une erreur
 - besoin d'échantillons de référence placés régulièrement dans le fichier compressé.
- Couplé à un codage VLC

Méthode différentielle



Perte d'informations dans la méthode

- Différences codée sur $n/2$ octets
 - perte des variations très fortes de l'amplitude
 - correspond à des hautes fréquences
- Décalage du signal lors de la décompression
 - besoin d'échantillons « clés » pour recalibrer

Compression de média

- Compression sans perte de l'image
- Méthode Run Length Encoding (RLE ou RLC)
 - choix d'une direction de parcours de l'image
 - exploitation de la cohérence spatiale le long de ce parcours

Codage par répétition

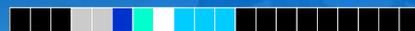
- Run Length Encoding (RLE ou RLC)
 - n octets successifs identiques de valeur V codés par nV
 - Performances moyennes mais implémentation très simple
 - bien adapté aux images sur fond uniforme (dessins)
 - utilisation
 - formats PCX, BMP (option RLE)



3 ■ 2 ■ 1 ■ 1 ■ 1 ■ 4 ■ 9 ■ = 14 octets = 112 bits

Optimisation de la méthode RLE

- Codage du nombre d'octets successifs sur 7 bits
 - valeurs de 2 à 129 (stocke $n-2$)
- Premier bit indique un pixel de couleur différent



3 ■ 2 ■ 1 ■ 1 ■ 1 ■ 4 ■ 9 ■ = 14 octets = 112 bits

00000001 ■ 00000000 1 ■ 1 ■ 1 ■ 00000010 ■ 00001111 ■ = 91 bits

Exemple de compression

Dessin du clown 400x390 pixels en couleurs indexées sur une palette de 256 couleurs (1 octet), soit environ 152 Ko.
Taille du fichier compressé : 21 Ko. (Gain de 86%)



Sur les aplats, on code jusqu'à 128 pixels consécutifs identiques par 2 octets.

Inconvénient de la méthode

- **Cas défavorable :**
 - fichier « compressé » plus lourd que le fichier brut

= 20 octets = 160 bits
 = 180 bits

Sommaire

- Données et informations
- Compression indépendante des données
- Compression réversible des média
- ✓ Compression destructrice des média

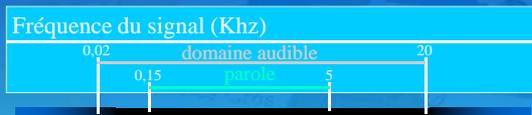
Benoît Piranda
Équipe SISAR
Université de Marne La Vallée
piranda@univ-mlv.fr
<http://www-igm.univ-mlv.fr/~piranda>

Compression du son avec perte

- **Méthode**
 - suppression des données peu significatives
- **Constataion**
 - oreille sensible à une fenêtre de fréquences réduites
- **Compression**
 - suppression des fréquences inaudibles
- **La méthode MPEG-Audio ou MP3**

Codage informatique du son

- **Fréquences audibles**

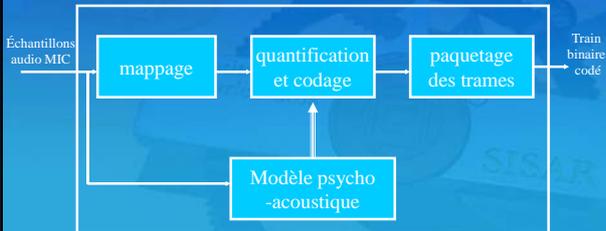


Compression du son

- **Principe**
 - conserver **uniquement** les données pertinentes du son : les fréquences audibles
 - étapes
 - numérisation
 - ✓ échantillons sur 16 bits à 32, 44.1 ou 48 kHz
 - calcul du spectre fréquentiel (FFT)
 - conservation des fréquences audibles
 - ✓ entre 20 Hz et 20 kHz
 - codage
- **Utilisation**
 - MPEG Audio,
 - MUSICAM,
 - DOLBY AC3

Algorithme MPEG Audio (MP3)

- **Algorithme Musicam** (Masking pattern adapted Universal Subband Integrated Coding And Multiplexing)
 - **algorithme non normalisé**
 - **prise en compte de la perception de l'oreille humaine**

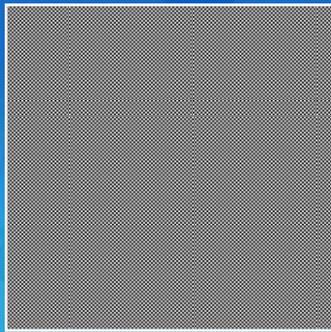


Compression d'image avec perte

- **Notion de fréquence dans une image**
 - **information codée : amplitude de luminance en fonction de la position le long de deux axes**
 - **fréquence des variations de l'amplitude suivant une direction**
- **Image discrétisée en pixels**
 - **variation de l'amplitude = différence entre deux échantillons successifs**
 - **utilisation : recherche de contours,**
 - **fréquence maximum : succession de deux pixels de valeurs extremum**
- **Passage au mode fréquentielle**
 - **Transformée en cosinus**

Illustration sur les fréquences

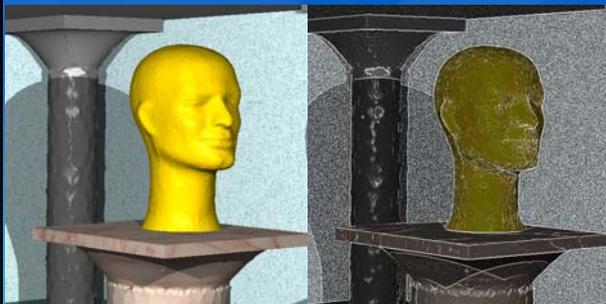
L'œil est un filtre passe bas



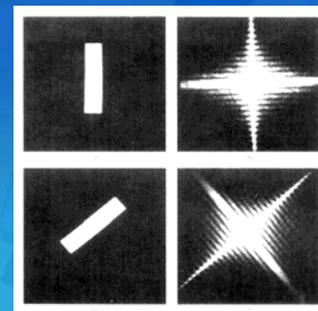
Hautes fréquences dans une image



Hautes fréquences dans une image



Exemple d'analyse spectrale d'une image



Transformée de Fourier