


# Normes de codage audio

Slim ESSID

INT - Février 2006

e-mail : [slim.essid@enst.fr](mailto:slim.essid@enst.fr)


Page web: <http://www.enst.fr/~essid>



# Objectifs, applications




- Codage PCM (Pulse Coded Modulation), qualité CD
  - » Échantillonnage (44.1 kHz)
  - » Quantification (16 bits)
  - » Débit 1.41 Mbit/s ! (stéréo)
  
- Codage ↔ Compression
  - » Stockage (CD, MINI DISC, DVD, ...)
  - » Services de diffusion
    - TV numérique, radio numérique (DAB)
    - Réseau IP, téléchargement/streaming
  - » Communications interactives (sur réseau RTC, RNIS, IP, GSM)
    - Téléphonie
    - Visiophonie, télé-enseignement, ...



# Gammes de qualité




		Fe (kHz)	R (bits)	Débit nominal (kbit/s)	Débit usuel (kbit/s)	Taux de compression	
P A R O L E	Bande téléphonique	8	13	104	64-...-4-...	1.6-...-26-...	
	Bande élargie	16	14	224	64-...-16-...	3.5-...-14-...	
M U S I Q U E	Bande HiFi	Qualité "FM"	32	16	512 monovoie (1024 stéréo)	192-...-64-...	2.6-...-8-...
		Qualité "CD"	44.1	16	705.6 (1411 stéréo)	192-...-56-...	3.6-...-12-...
		Qualité "parfaite"	96	24	13824 en 5.1 canaux	...-1000-...	...-13.8-...



# Un "bon" codeur: résultat d'un compromis entre




- **Débit**
  - » Varie selon la qualité de restitution demandée (384 ... 2 kbit/s)
  - » Monodébit, multidébits/hiérarchique (imbriqué, à vol de bits, scalable)
  
- **Complexité**
  - » Impact sur coût et puissance consommée
  - » MIPS, RAM, ROM, ...
  
- **Retard de reconstruction**
  - » Paramètre critique pour applications conversationnelles
  - » < 150 ms, perte d'interactivité au-dessus de 400 ms
  
- **Tenue aux erreurs de reconstruction**
  - » Communication avec mobiles: codes correcteurs d'erreurs
  - » Communications sur IP : récupération de trames effacées
  
- **Qualité**
  - » Fonction du type de signal transmis (parole, bruit, musique, modems...)
  - » Déterminée par des tests subjectifs



# Evaluation de la qualité




- Tests subjectifs (écoutes) formels (protocoles complètement définis)
  - » Codeurs de parole : **qualité médiocre** ► tests d'intelligibilité ► méthodes de jugement :
    - par catégories absolues ACR (Absolute Category Rating)
    - par catégories de dégradation DCR (Degradation Category Rating), etc.
  - » Codeurs audio débits compris entre 20 et 64kbits/s : qualité "**acceptable**"
  - méthode MUSHRA (MUlti Stimulus test with Hidden Reference and Anchor)
  - » Codeurs audio de très bonne qualité : la "**transparence**" >> méthode dite "doublement aveugle à triple stimulus et référence dissimulée" :
- Recommandation UIT-R BS.1116
  - » Enregistrements courts (entre 5 et 10 secondes) répétés 3 fois
  - » Deux possibilités : ABA ou AAB (A= signal original, B=signal codé/reconstruit)
  - » Réponse réclamée
    - B en 2ème ou 3ème position ?
    - Opinion sur B (5: bruit totalement inaudible, 4: très légèrement gênant, 3: un peu gênant, 2: gênant, 1: mauvais, 0: très mauvais)
  - » Traitement statistique ► comparaison objective entre codeurs



# Nécessité de la normalisation


- Apparition de produits propriétaires avec nouvelles applications
- Exemples :
  - » Stockage : AC3, Dolby - ATRAC, Mini-Disc Sony
  - » Streaming : Real Audio, Real Networks - Microsoft, windows media
- Incompatibilités, décodeurs propriétaires
- Recours au transcodage
  - » Complexité supplémentaire
  - » Dégradation de qualité
- Normalisation
  - » Interopérabilité
  - » Consensus entre industriels



# Normalisation




- Identification d'un nombre suffisant d'applications potentielles
- Cahier des charges par participants au groupe de travail
- Appel à candidatures
- Sélection de la meilleure technologie
- Organismes
  - » Union Internationale des Télécommunications (UIT)
  - » European Telecommunications Standards Institute (ETSI)
  - » Organisation Internationale de normalisation (ISO)
    - Groupe WG 11 de la sous-commission 29 (ISO/IEC/JTC1/SC29/WG11) : MPEG (Moving Picture Expert Group)
    - Développement des normes multimédia (audio et vidéo numériques)



# Normes de codage audio de l'ISO : MPEG1



- MPEG1 (ISO/CEI 11172): "Technologie de l'information - Codage de l'image animée et du son associé pour les supports de stockage numérique jusqu'à environ 1.5 Mbit/s"
  - » Partie 1 : Systèmes
  - » Partie 2 : Vidéo
  - » Partie 3 : **Audio**
  - » Partie 4 : Tests de conformité
- Normalisation du décodeur + annexes informatives (1992)
  - » Fréquences d'échantillonnage : 44,1 kHz - 48 kHz - 32 kHz
  - » Modes
    - Stéréophonique, voies droites et gauche dans même train binaire
    - Stéréo combiné, exploitation de la redondance stéréo - corrélation entre voie gauche et droite
    - « Dual monophonique », 2 canaux mono contenant des programmes indépendants (exple. bilingues) dans même train binaire
    - Monophonique, 1 seul canal
  - » 3 couches ou layers offrant des taux de compression différents




# MPEG1 audio, couches



- **Couche I**
  - » Studio, diffusion par satellites,...
  - » Débits : 32, 64, 96, ..., **192**, ..., 384,416,448 kbit/s
  - » Retard min. théorique de codage/décodage : 19 ms
- **Couche II**
  - » DAB en Europe, ...
  - » Débits : 32, 48, 56, ..., **128**, ..., 256,320,384 kbit/s
  - » Retard min. théorique de codage/décodage : 35 ms
- **Couche III**
  - » mp3 = MPEG1 Layer 3
  - » Débits : 32,40,48, ..., **96**, ..., 224,256,320 kbit/s
  - » Retard min. théorique de codage/décodage : 59 ms






# MPEG2 (ISO/IEC 13818 et 13818-7)




- MPEG2 audio (1994)
  - » Extension de MPEG-1
    - à la configuration multi-canaux dont les 5.1 canaux (L,C,R,LS,RS,LFE)
    - au fonctionnement en mono et stéréo à  $f_e$  réduites 16, 22.05 et 24 kHz (MPEG-2 LSF, Low Sampling Frequencies)
  - » Diffusion : TVHD - Stockage : DVD, minidisque
- MPEG2 AAC (Advanced Audio Coding) (1997 - 1998)
  - » Codage multi-canaux à des débits raisonnables
  - » Transparence à 384 kbit/s - 5.1)
  - » 1 à 48 canaux, 8 à 96 kHz, 8 à 160 kbit/s
  - » Performances nettement supérieures
  - » Complexité ~ 100 MIPS (codeur), 10 MIPS (décodeur)
  - » 3 profils : "Main profile", "Low complexité profile", "Scalable Sampling Rate Profile"
  - » Etat de l'art en codage musical



# MPEG4



- Version 1, 1998 - version 2, 1999
- Représentation des sons (parole et musique) d'origine naturelle (issu d'un microphone) ou d'origine synthétique (fabriqués par une machine)
- Définition d'**objets sonores** susceptibles d'être manipulés de façon à former des **scènes sonores**



## MPEG4 (2/3)




- Sons d'origine naturelle

- » Définition d'une **famille de codeurs hiérarchiques** (de 2 à 64 kbit/s)

- » Existence d'une boîte à outils regroupant plusieurs algorithmes de compression


- de **6 à 24 kbit/s** : parole en bande téléphonique ou en bande élargie :  
codeur UIT-T G.729
- de **16 à 64 kbit/s** : musique en bande Hi-Fi
  - Codeurs **MPEG2-AAC**, **AAC-LD** (Low Delay) pour des communications interactives, **BSAC** (Bit Slice Arithmetic Coding) pour avoir une "granularité" très fine (1 kbit/s)
  - Codeur **TWIN-VQ** (Transform Weighted INterleave-Vector Quantization), meilleures performances à 16 kbit/s
- de **2 à 24 kbit/s** parole/musique ("streaming sur modem") : **codeurs paramétriques**
  - Codeur **HVXC** : Harmonic Vector eXcitation Coding
  - Codeur **HILN** : Harmonic and Individual Line plus Noise coding



# MPEG4 (3/3)



- Sons d'origine synthétique
  - » Algorithme de synthèse de la parole (synthèse "Text-To-Speech")
  - » Langage pour engendrer de la musique (langage SAOL : Structured Audio Orchestra Language)
  - » Exploitation du format MIDI
  
- Standardization de la façon de décrire une scène
  - » Définition de l'endroit dans un système de coordonnées où se trouve (se déplace) un objet sonore (navigation dans une scène)
  - » Façon dont est modifiée l'apparence de chaque objet
    - Modifications prosodiques pour de la parole
    - Réverbération, spatialisation pour de la musique



# MPEG7 & MPEG21




- MPEG7


- » Normalisation des descripteurs de contenus multimédia
- » Faciliter l'accès aux bases de données multimédia
- » Requête par fredonnement, ...

- MPEG21


- » Sécurité
- » Tatouage




# Quantification, principe



- $\underline{U} = (U_1, U_2, \dots, U_N) \in A^N$  ,  $I \in \{0, 1, \dots, M-1\}$  ,  $\underline{v} = (v_1, v_2, \dots, v_N) \in A^N$  ,  
 $A$  ensemble des valeurs prises par  $U_i$  ;  $\text{card}(A) = K$  (dans le cas discret)
- Quantificateur :  $Q(\underline{U}) = i \Leftrightarrow \underline{U} \in R_i$  ;  $i \in \{0, 1, \dots, M-1\}$ 
  - »  $R_0, R_1, \dots, R_{M-1}$  : **cellules de quantification**, forment une partition
- Déquantificateur :  $Q^{-1}(i) = \underline{v}_i$ 
  - »  $\{\underline{v}_0, \underline{v}_1, \dots, \underline{v}_{M-1}\}$  : **codebook** ou dictionnaire






# Quantification, caractérisation






- $N = 1$  : quantification scalaire ,  $N \neq 1$  : quantification vectorielle
- Taux de codage :  $R = \log_2(M)/N$  (bit/ech)
- Débit :  $B = R fe$  (bit/s)
- Facteur de compression :  $\tau = \log_2(K)/R$
- Erreur de quantification :  $q(n) = u(n) - v(n)$
- Mesure de distorsion :

$$\text{» } D = \frac{1}{N} E \left\{ \|\underline{U} - \underline{v}\|^2 \right\} = \frac{1}{N} \int_{IR_N} p(\underline{u}) \|\underline{u} - \underline{v}\|^2 d\underline{u} = \frac{1}{N} \sum_{i=0}^{M-1} \int_{R_i} p(\underline{u}) \|\underline{u} - \underline{v}_i\|^2 d\underline{u}$$


»  $D$  : puissance moyenne de l'erreur de quantification  $q(n)$  ,  $D = \sigma_Q^2$




# Un signal de musique : violon




Fenêtres d'analyse **recouvrantes** de 20ms ( $f_e=44.1\text{kHz}$ , 20ms :  $N=882$  échantillons)




# Codage perceptuel : principe







# Transformation temps-fréquence



## Codage en sous-bandes





# Equivalence banc de filtres et transformée





- Analyse  $\underline{y}(m) = \mathbf{H} \underline{x}(m)$

$$\mathbf{H} = \begin{bmatrix} h_0(N-1) & \cdots & h_0(0) \\ \vdots & & \vdots \\ h_{M-1}(N-1) & \cdots & h_{M-1}(0) \end{bmatrix} \quad \underline{x}(m) = \begin{bmatrix} x(mM - N - 1) \\ \vdots \\ x(mM) \end{bmatrix} \quad \underline{y}(m) = \begin{bmatrix} y_0(m) \\ y_1(m) \\ \vdots \\ y_{M-1}(m) \end{bmatrix}$$

- Synthèse par **addition et recouvrement** (Overlap add)

$$\mathbf{F} = \begin{bmatrix} f_0(0) & \cdots & f_0(N-1) \\ \vdots & & \vdots \\ f_{M-1}(0) & \cdots & f_{M-1}(N-1) \end{bmatrix}$$






# Transformée




- Transformée à reconstruction parfaite
  - » Importance du recouvrement :  $N > M$
  - » Banc de filtres modulés : filtre prototype et modulation
  
- Dimensionnement (N, M ??)
  - » Résolution fréquentielle
    - ▶ M grand : grand nbre de coef spectraux
    - ▶ N grand : filtres sélectifs
  - » Résolution temporelle
  - » Adaptation à diverses fréquences d'échantillonnage
  
- ▶ Réaliser un compromis



# Transformée optimale et allocation de bits




- Transformée optimale "théorique" : Transformée Karhunen-Loeve (KLT)
- En pratique MDCT : Modified Discrete Cosine Transform
- Allocation optimale
  - ▶ sous le contrôle d'un **modèle d'audition**



# Psychoacoustique



- Caractérisation de la perception auditive humaine
- Analyse temps-fréquence des capacités de l'oreille interne
- Relation entre grandeurs physiques et grandeurs perceptuelles
- Expériences/tests psychoacoustiques
- Jugement de l'individu testé




# Niveau de pression acoustique

- Sensation sonore : onde acoustique
- Vibrations du tympan
- $P(t) = H_0 + p(t)$ 
  - »  $P(t)$ , pression instantanée;
  - »  $H_0$ , pression atmosphérique (pression moyenne de l'air,  $10^5$  Pa ( $\text{N/m}^2$ ));
  - »  $p(t)$  : vibrations.
- $p/p_r$ ,  $p_r = 2 \cdot 10^{-5}$  Pa ;  $p_r$  : pression de référence  $\sim$  pression min. audible (auditeur moyen, 1kHz)
- Niveau de pression acoustique
  - »  $\text{SPL} = 20 \log_{10}(p/p_r)$  (Sound Pressure Level dB SPL)
  - » 0 dB SPL  $\sim$  silence,  $> 140$  dB SPL  $\sim$  douleur

# Structure de l'oreille

- Oreille externe : pavillon, conduit auditif, tympan
- Oreille moyenne : Osselets (marteau-enclume-étrier), fenêtre ovale
- Oreille interne : cavité en colimaçon, membrane basilaire





**Coupe longitudinale de l'appareil auditif humain.**

PA : pavillon ; Co : conque ; CAE : conduit auditif externe ;  
Cart : cartilage ; MT : membrane tympanique ; O.OM : osselets  
de l'oreille moyenne ; CSC : canaux semi-circulaires ; FO : fenêtrée  
ovale ; FR : fenêtrée ronde ; COM : cavité de l'oreille moyenne ;  
Vest : vestibule ; NV : nerf vestibulaire ; NF : nerf facial ;  
NCo : nerf cochléaire ; TE : trompe d'Eustache


# Membrane basilaire, pattern d'excitation


- Vibration le long de la membrane, fonction de la fréquence
- Cellules ciliées, spécialisées en fréquence
- Pattern d'excitation → masquage fréquentiel







# Seuil d'audition absolu








# Bandes critiques







# Courbe de masquage, seuil de masquage



# Codeur MPEG1 Layer 1: Transformation temps-fréq.





- Banc de  $M=32$  filtres modulés (exploitation d'un filtre prototype) :

$$H_k(f) = H\left(f - \frac{2k+1}{4M}\right) + H\left(f + \frac{2k+1}{4M}\right)$$


$$h_k(n) = 2 h(n) \cos\left(2\pi \frac{2k+1}{4M} n + \varphi_k\right) \quad n = 0 \dots N-1$$

- Longueur de la réponse impulsionnelle du filtre prototype :  $N = 512$
- Sous-échantillonnage "critique" : Facteur de sous-échantillonnage =  $M$
- Pas de reconstruction parfaite mais RSB > 90dB
- $M \ll N$  : bonne résolution temporelle ( $\propto M$ ) mais mauvaise résolution fréquentielle ( $\propto 1/M$ )
- Pas de problème de pré-écho avec ce codeur

# Codeur MPEG1 Layer 1




- Banc de  $M = 32$  filtres Pseudo-QMF
- Pour chaque sous-bande  $k \in \{0 \dots M - 1\}$ 
  - » Construction d'un vecteur :  $\underline{y}_k = [y_k(0) \dots y_k(11)]$  (trames de 384 échantillons)
  - » Détermination d'un "facteur d'échelle" :  $g_k = \max[y_k(0) \dots y_k(11)]$  (6 bits)
  - » Normalisation des composantes  $[y_k(0) \dots y_k(11)]/g_k$
  - » QS uniforme des composantes normalisées sur  $b_k$  bits (choix entre 15 quantificateurs)
- Détermination de  $b_0 \dots b_{M-1}$  : procédure "d'allocation de bits" sous le contrôle d'un modèle d'audition
- Complexité : essentiellement due au modèle d'audition (uniquement au codeur)



# Modèles psychoacoustiques




- 2 propositions de modèle psychoacoustique
  - » Modèle I - faible complexité, bonne précision pour débits élevés
  - » Modèle II - complexité supérieure, plus bas débits
  
- Fonctionnement
  - » Calcul périodogrammes du signal, domaine de Fourier
  - » Mapping vers bandes critiques
  - » Distinction composantes tonales/bruit
  - » Application des fonctions d'étalement aux composantes
  - » Calcul de la fonction de masquage
  - » Retour au domaine de Fourier en sous-bandes
  
- Mapping, paramètres de représentation donnés pour différentes fe



# Allocation des bits

- Modèle psychoacoustique >> SMR par sous-bande
- Algo. Allocation >> MNR (Mask to Noise Ratio)
  - »  $MNR = SMR - SNR$
  - » SNR fonction de l'allocation des bits, donnés par tables du standard
- Nombre de bits alloués à une trame
  - »  $\text{bits/trame} = (\text{bits/seconde}) / (\text{trames/seconde})$
  - »  $\text{trames/seconde} = (\text{échantillons/seconde}) / (\text{échantillons/trame})$
- Prendre en compte les bits d'entête et de donnés aux...
- Allouer les bits restant de façon à maximiser le MNR min de sous-bande






## Couche III

- Banc de filtre hybride, MDCT
- Fenêtres courtes / fenêtres longues
- Réduction des effets d'aliasing
- Quantification non-uniforme
- Bandes de facteurs d'échelle
- Codage entropique des données
- Utilisation de « réservoir de bits »







# Codeur MPEG2-AAC : Transformation temps-fréquences



- Connaissant le vecteur  $\underline{x}(m) = [x(mM) \cdots x(mM + N - 1)] \Rightarrow \underline{X}(m) = [X(0) \cdots X(M - 1)](m)$
- MDCT : Transformée en cosinus discrète modifiée ( $N=2048$  et  $M=1024$ )
- Transformée avec recouvrement







# Codeur MPEG2 AAC, fenêtrage dynamique



- Fenêtres longues ( $N=2048$  et  $M=1024$ )
- Fenêtres courtes ( $N=256$  et  $M=128$ )








# Quantification des coefficients $\underline{X} = [X(0) \cdots X(M - 1)]$



- Si on connaît le vecteur des "facteurs d'échelle"  $\underline{g} = [g(0) \cdots g(M - 1)]$
- A l'émetteur, calcul du vecteur d'entiers  $\underline{i} = \text{round}([X(0)/g(0) \cdots X(M - 1)/g(M - 1)])$
- Au récepteur, reconstruction de  $[\hat{X}(0) \cdots \hat{X}(M - 1)] = [g(0) \times i(0) \cdots g(M - 1) \times i(M - 1)]$  puis  $[\hat{x}(0) \cdots \hat{x}(M - 1)]$
- Erreur de reconstruction  $\underline{q} = [x(0) \cdots x(M - 1)] - [\hat{x}(0) \cdots \hat{x}(M - 1)]$







# Codage du vecteur $\underline{i} = [i(0) \cdots i(M - 1)]$




- 1ère solution :  $M = 512$  entiers vérifiant  $0 \leq i(k) \leq 8$  (dans cet exemple)
  - » nombre de bits nécessaires  $B = 512 \times 3 >$  nombre de bits disponibles ( $\sim 750$ )
- Autre solution plus économique : codage de Huffman  
Les valeurs les plus probables codées sur moins de 3 bits, les valeurs les moins probables sur plus de 3 bits
- En réalité : partition de l'axe des fréquences en 51 "bandes"  
Dans chaque bande : détermination de  $\max i(k)$  puis codage séparé
- Dans le "bitstream" : mots de code des  $i(k)$  + mots de code des  $\max i(k)$  + mots de code des  $g(k)$





## Détermination des facteurs d'échelle $\underline{g} = [g(0) \cdots g(M - 1)]$

- A priori simple problème d'optimisation : déterminer  $\underline{g}$  minimisant la puissance de l'erreur de reconstruction sous la contrainte que le nombre de bits nécessaire soit inférieur au nombre de bits disponibles
- Solution non réaliste car elle n'autorise que des taux de compression faibles (de l'ordre de 2) si on veut que le signal reconstruit soit "transparent"
- Pour obtenir des taux de compression élevé (de l'ordre de 10) : exploitation des résultats de psychoacoustique
- "Mise en forme spectrale" du bruit de reconstruction
- Problème d'optimisation sous 2 contraintes
  - » Contrainte de débit : nombre de bits nécessaire < nombre de bits disponible
  - » Contrainte "psychoacoustique" :  $S_Q(f) < \Phi(f) \quad \forall f$



# Codeur MPEG2 AAC : informations transmises



- Dans chaque fenêtre d'analyse (1024 échantillons i.e. 23 ms lorsque  $f_e = 44.1$  kHz)
  - » Partition de l'axe des fréquences en 51 "sous-bandes"
  - » Facteurs d'échelle
    - Codage du 1er directement sur 8 bits
    - Codage de  $\Delta(k) = g(k) - g(k-1)$  pour les 50 suivants
    - Utilisation d'une table de Huffman
  - » Coefficients de la MDCT
    - 4 composantes dans la 1ère sous-bande, 32 dans la dernière
    - Codage du signe à part
    - Détermination de la valeur max dans chaque sous-bande, choix d'une table de Huffman parmi 11 (information transmise dans la chaîne binaire)
    - Codage des  $i(k)$