

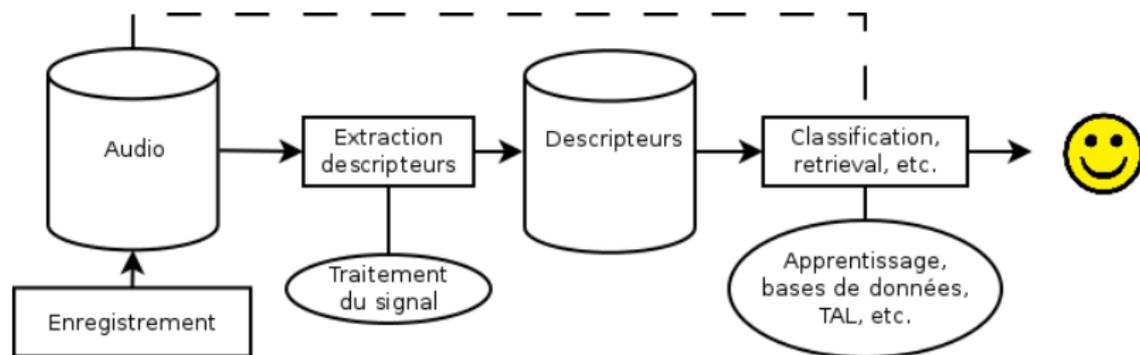
# Indexation audio

Recherche d'information et indexation multimedia

M2 RIM, Aix-Marseille Université  
Valentin Emiya (prenom.nom@lif.univ-mrs.fr)

27 novembre 2012

## Indexation audio : de quoi parle-t-on ?



- ▶ Objectif du cours : sensibilisation à l'indexation audio.
- ▶ Les données : audio.
- ▶ Motivation : les applications.

⇒ Comment manipuler l'information dans les données audio ?

NB : cette séance est orientée « musique » mais les principes se généralisent aux autres types de sons.

## Introduction

Aperçu

Les applications

Notions d'acoustique et d'audition

## Les descripteurs audio

Catégories de descripteurs

Descripteurs instantanés

Descripteurs globaux

Complément : descripteur de chroma

Références

## Présentation du TP

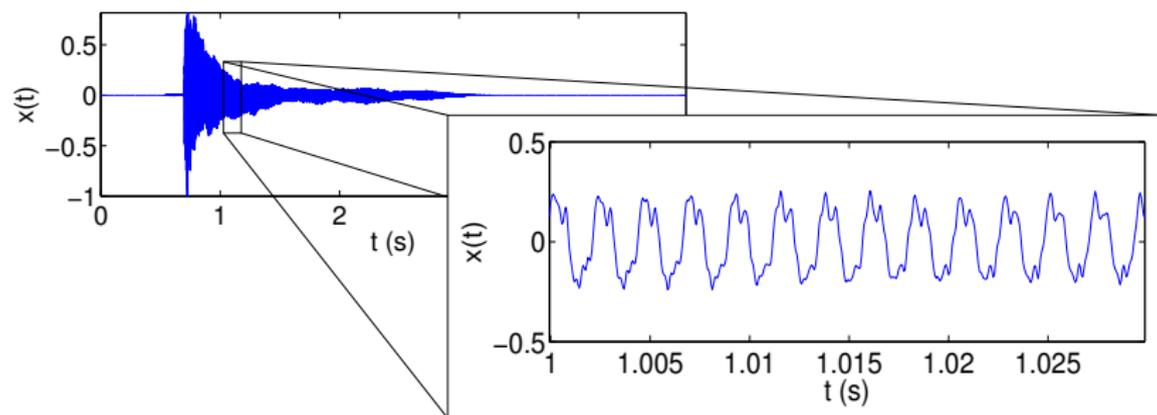
Objectif et principe

Détail des blocs

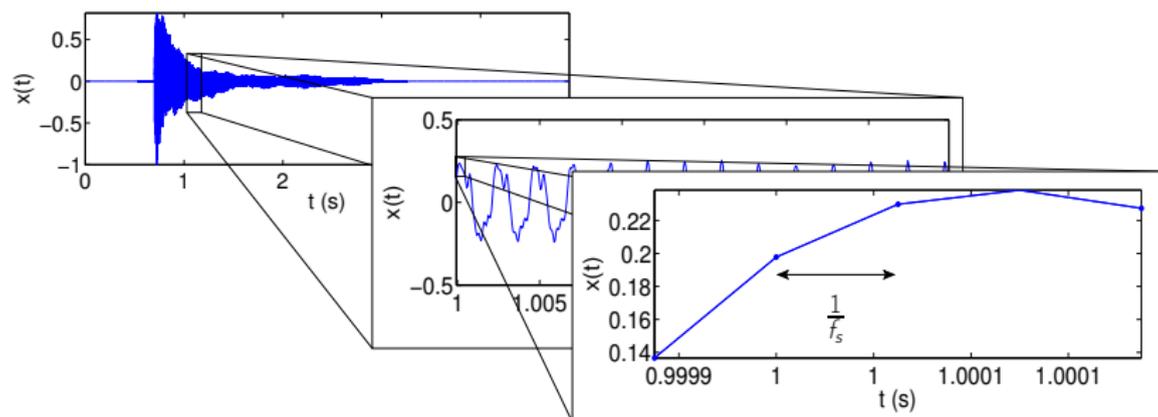
# Les données audio

- ▶ Nature : tout enregistrement sonore (numérique).
- ▶ Provenance :
  - ▶ production professionnelle (studio, concert, audiovisuel),
  - ▶ particuliers,
  - ▶ capteurs divers : téléphonie, surveillance, etc.
- ▶ Contenu :
  - ▶ voix parlée,
  - ▶ musique,
  - ▶ sons de l'environnement,
  - ▶ bruits,
  - ▶ etc.
- ▶ Autres media parfois associés : métadonnées, multimédia.

## Le signal audio



# Le signal audio



Signal audio lu à partir d'un fichier .wav :

- ▶ vecteur  $\mathbf{x} = (x(0), \dots, x(N_x - 1))^T \in \mathbb{R}^{N_x}$  de longueur  $N_x$ .
- ▶  $f_s$  : fréquence d'échantillonnage (nombre de coefficients par seconde)

## Pourquoi indexer ? Les applications.

- ▶ Détection d'événements
- ▶ Recommandation, génération de playlist
- ▶ Recherche par le contenu
- ▶ Recherche par similarité
- ▶ Identification par fredonnement
- ▶ Accompagnement automatique, interaction musicien/machine, synchronisation
- ▶ Extraction de partition, tablature, accords,

# La recherche : exemples de tâches applicatives

Le challenge Music Information Retrieval Evaluation eXchange

## Classification

- ▶ Audio Artist Identification
- ▶ Audio Genre Classification
- ▶ Audio Music Mood Classification
- ▶ Audio Classical Composer Identification
- ▶ Symbolic Genre Classification
- ▶ Audio Cover Song Identification
- ▶ Query by Singing/Humming
- ▶ Query by Tapping
- ▶ Audio Music Similarity and Retrieval

## Alignement

- ▶ Real-time Audio to Score Alignment
- ▶ Symbolic Melodic Similarity

## Extraction de descripteurs

- ▶ Multiple Fundamental Frequency Estimation and Tracking
- ▶ Audio Chord Estimation
- ▶ Audio Melody Extraction
- ▶ Audio Beat Tracking
- ▶ Audio Tempo Extraction
- ▶ Audio Tag Classification

## Segmentation

- ▶ Audio Onset Detection
- ▶ Audio Key Detection
- ▶ Symbolic Key Detection
- ▶ Structural Segmentation
- ▶ Audio Drum Detection ▶

# Autres champs utilisant de l'indexation audio

- ▶ Traitement de la parole, des langues
- ▶ Signal : séparation de sources, restauration
- ▶ Multimedia : fusion multimodale
- ▶ Audition : perception, cognition
- ▶ Robotique
- ▶ Sécurité/surveillance
- ▶ Cris des animaux
- ▶ etc.

# Notions d'acoustique et d'audition : pourquoi ?

Les données audio sont enregistrées à mi-chemin entre :

- ▶ en amont, la génération du son (acoustique)
- ▶ en aval, la perception du son (audition)

Buts de l'analyse computationnelle : perception par l'ordinateur, analyse de la production sonore.

# Notions d'acoustique



## Production

sources harmonique

sources de bruit

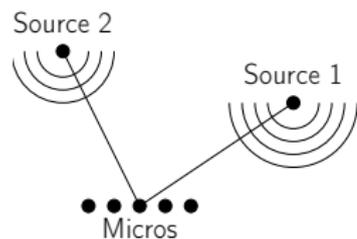
source-filtre : la voix, les instruments

## Propagation

Son direct : délai, atténuation

Reflexions, réverbération : convolution  
avec réponse impulsionnelle

# Notions d'acoustique



## Production

sources harmonique

sources de bruit

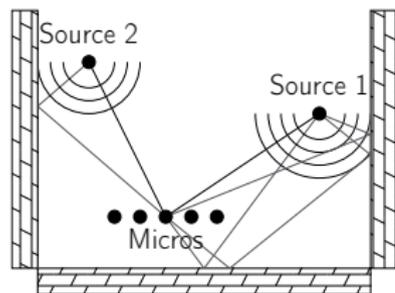
source-filtre : la voix, les instruments

## Propagation

Son direct : délai, atténuation

Reflexions, réverbération : convolution  
avec réponse impulsionnelle

# Notions d'acoustique



## Production

sources harmonique

sources de bruit

source-filtre : la voix, les instruments

## Propagation

Son direct : délai, atténuation

Reflexions, réverbération : convolution  
avec réponse impulsionnelle

# Notions d'audition

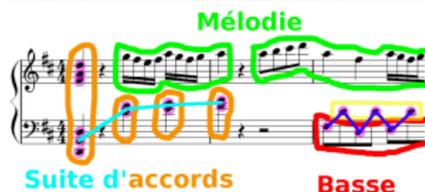


## Comment décrire un son perçu ?

- ▶ intensité : faible/fort (échelle non-linéaire)
- ▶ localisation : distance, angle, étendue
- ▶ hauteur : grave/aigu
- ▶ temporalité : durée, rythme, tempo
- ▶ identification : timbre, locuteur, etc.
- ▶ notion d'objet, de forme (fusion, perception active)
- ▶ rond, rugueux, clair, etc.

# Notions d'audition

## Comment décrire un son perçu ?



- ▶ intensité : faible/fort (échelle non-linéaire)
- ▶ localisation : distance, angle, étendue
- ▶ hauteur : grave/aigu
- ▶ temporalité : durée, rythme, tempo
- ▶ identification : timbre, locuteur, etc.
- ▶ notion d'objet, de forme (fusion, perception active)
- ▶ rond, rugueux, clair, etc.

# Notions d'audition

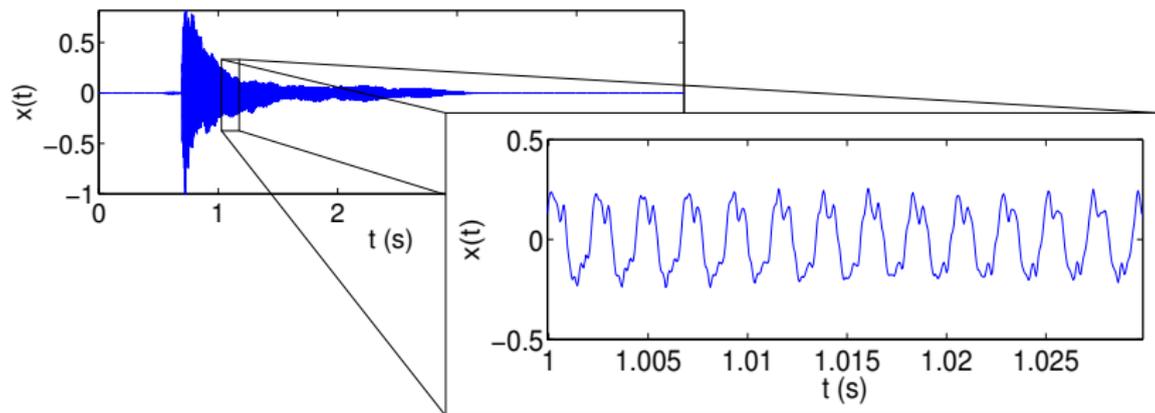
⇒ La description des sons est complexe

- ▶ fortement multidimensionnelle,
- ▶ subjective,
- ▶ souvent difficile à verbaliser.

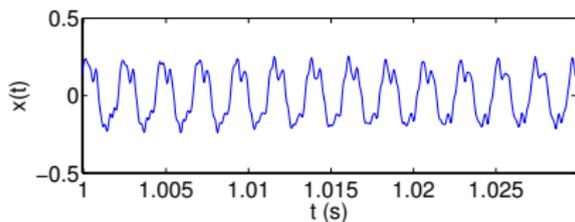
## Comment décrire un son perçu ?

- ▶ intensité : faible/fort (échelle non-linéaire)
- ▶ localisation : distance, angle, étendue
- ▶ hauteur : grave/aigu
- ▶ temporalité : durée, rythme, tempo
- ▶ identification : timbre, locuteur, etc.
- ▶ notion d'objet, de forme (fusion, perception active)
- ▶ rond, rugueux, clair, etc.

# Complément sur la hauteur d'un son périodique

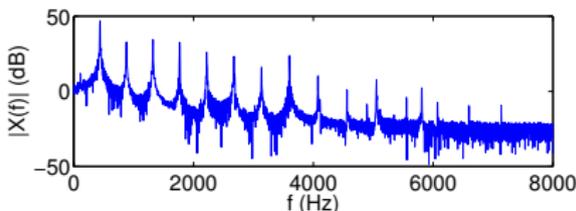


# Complément sur la hauteur d'un son périodique



Transformée de Fourier discrète  
(TFD)

$$\begin{aligned} X(f) &= \sum_n \mathbf{x}(n) e^{-2i\pi f \frac{n}{f_s}} \\ &= \langle \mathbf{x}, \text{sinus}_{\mathbb{C}}(f) \rangle \end{aligned}$$



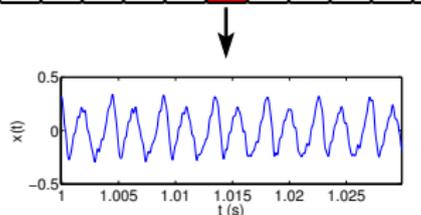
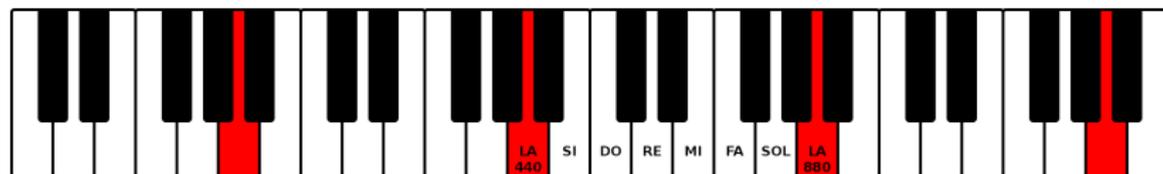
Hauteur caractérisée par la fréquence fondamentale  $f_0$ , inverse de la période.

## Dans le domaine fréquentiel

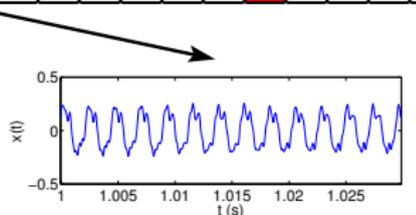
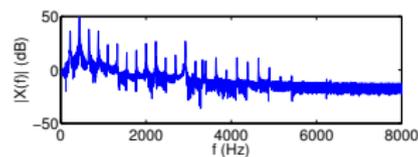
- ▶ TFD : énergie en fonction de la fréquence.
- ▶ *Peigne harmonique* : énergie aux fréquences

$$f_h = hf_0$$

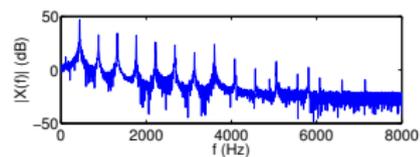
# Hauteur d'un son périodique : exemples



↓ Fourier



↓ Fourier



[jouer sons pianoteq]

## Introduction

### Les descripteurs audio

- Catégories de descripteurs

- Descripteurs instantanés

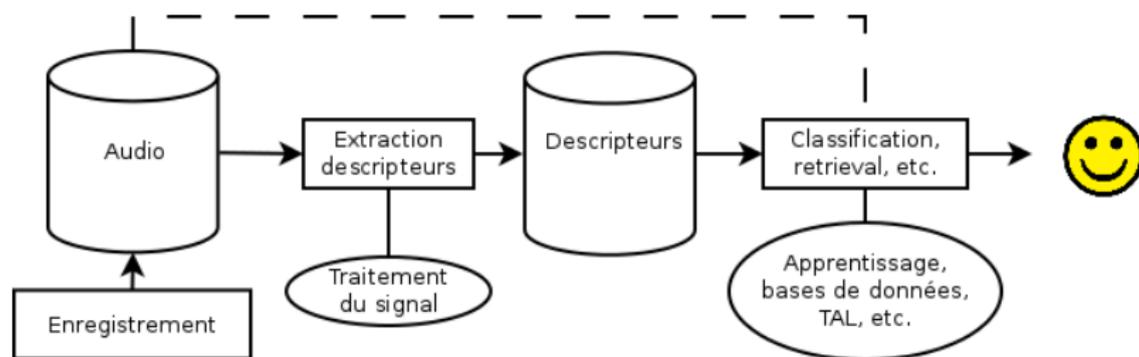
- Descripteurs globaux

- Complément : descripteur de chroma

- Références

## Présentation du TP

# La foule des descripteurs



Caractère multidimensionnel de la description des sons  
+  
Nombreuses applications  
=  
Grand nombre de descripteurs

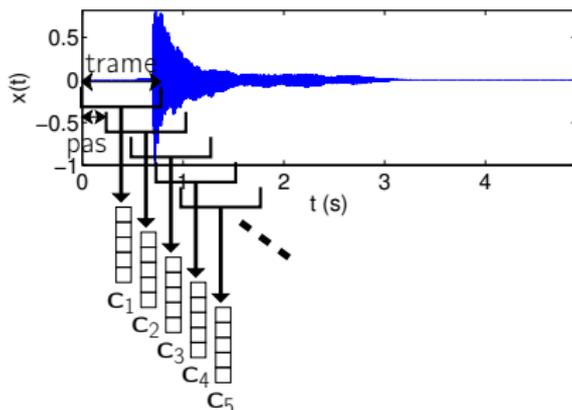
Il existe des toolboxes d'extraction de descripteurs audio, des méthodes de sélection de descripteurs, etc.  
Comment s'y retrouver ?

# Catégories de descripteurs

(sources : Peeters et al., 2003 ; Mathieu et al., 2010)

Selon l'objet décrit :

- ▶ descripteur global : décrit un son entier.
- ▶ descripteur instantané/de trame : décrit une trame de son ; une suite temporelle de descripteurs est associée au son.
- ▶ descripteurs de haut niveau/bas niveau



# Catégories de descripteurs

(sources : Peeters et al., 2003 ; Mathieu et al., 2010)

## Selon l'objet décrit :

- ▶ descripteur global : décrit un son entier.
- ▶ descripteur instantané/de trame : décrit une trame de son ; une suite temporelle de descripteurs est associée au son.
- ▶ descripteurs de haut niveau/bas niveau

## Selon la nature de l'information :

- ▶ temporelle,
- ▶ spectrale,
- ▶ énergétique,
- ▶ perceptive.

# Descripteurs instantanés

## Descripteurs temporels

Signal Auto-correlation function

**Zero-crossing rate**

## Descripteurs énergétiques

**Total energy**

Total harmonic energy

Total noise energy

## Descripteurs spectraux

**Spectral centroid**

Spectral spread

Spectral skewness

Spectral kurtosis

Spectral slope

Spectral decrease

Spectral rolloff

Spectral variation

**MFCC**

Delta MFCC

Delta Delta MFCC

## Descripteurs harmoniques

**Fundamental frequency**

Noisiness

**Inharmonicity**

Harmonic Spectral Deviation

**Odd to Even Harmonic Ratio**

Harmonic Tristimulus

**HarmonicSpectral centroid**

HarmonicSpectral spread

HarmonicSpectral skewness

HarmonicSpectral kurtosis

HarmonicSpectral slope

HarmonicSpectral decrease

HarmonicSpectral rolloff

HarmonicSpectral variation

**chroma**

**multif0**

# Descripteurs instantanés

## Descripteur perceptifs

### **Loudness**

Relative Specific Loudness

Sharpness

Spread

Perceptual Spectral centroid

Perceptual Spectral spread

Perceptual Spectral skewness

Perceptual Spectral kurtosis

Perceptual Spectral Slope

Perceptual Spectral Decrease

Perceptual Spectral Rolloff

Perceptual Spectral Variation

Odd to Even Band Ratio

Band Spectral Deviation

Band Tristimulus

# Descripteurs globaux

## Descripteurs temporels

**Log Attack Time**  
**Temporal increase**  
**Temporal Decrease**  
**Temporal Centroid**  
**Effective Duration**

## Descripteurs énergétiques

Total energy Modulation (frequency, amplitude)

## Descripteurs harmoniques

Fundamental fr. M. (frequency, amplitude)

## Descripteurs subjectifs

score subjectif  
j'aime/j'aime pas  
« Cool », « 80s »,

## Tags

Genre  
Sources : nature, identité  
Condition enregistrement (intérieur, extérieur, mix)  
Date, lieu enregistrement  
etc.

# Descripteurs globaux

## Descripteurs temporels

**Log Attack Time**  
**Temporal increase**  
**Temporal Decrease**  
**Temporal Centroid**  
**Effective Duration**

## Descripteurs énergétiques

Total energy Modulation (frequency, amplitude)

## Descripteurs harmoniques

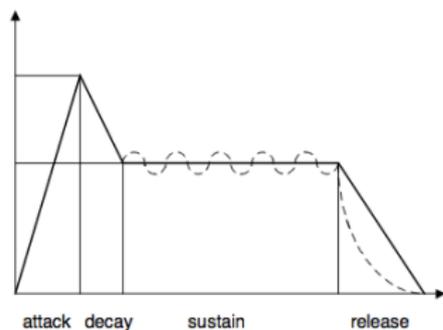
Fundamental fr. M. (frequency, amplitude)

## Descripteurs subjectifs

score subjectif  
j'aime/j'aime pas  
« Cool », « 80s »,

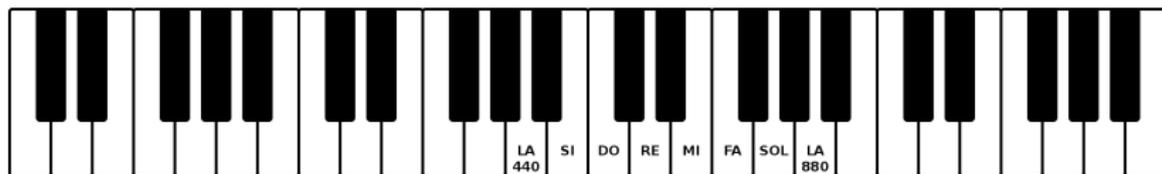
## Tags

Genre  
Sources : nature, identité  
Condition enregistrement (intérieur, extérieur, mix)  
Date, lieu enregistrement  
etc.



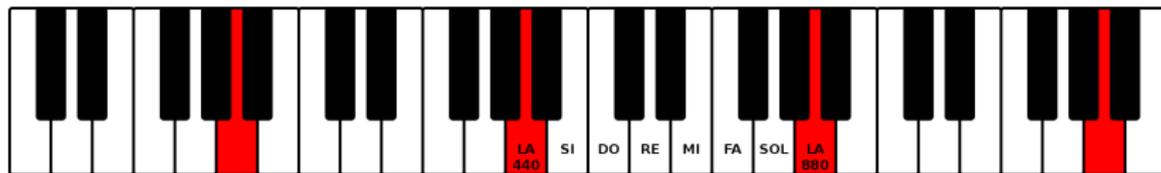
(source : Peeters et al., 2003)

## Descripteurs : vecteur de chroma



**Principe** : avoir une description synthétique des notes jouées.

## Descripteurs : vecteur de chroma

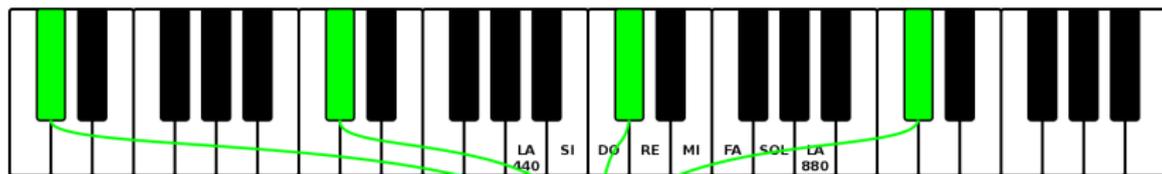


**Chroma** A horizontal row of 12 empty rectangular boxes. The first box on the left is filled with red, representing the chroma vector for the notes shown in the keyboard diagram above.

**Principe** : avoir une description synthétique des notes jouées.

**Idée** : invariance d'octave.

## Descripteurs : vecteur de chroma

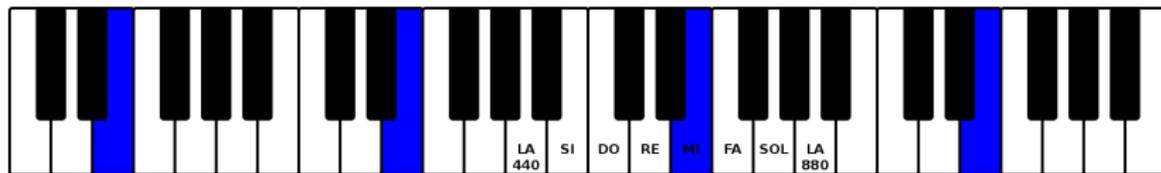


**Chroma** 

**Principe** : avoir une description synthétique des notes jouées.

**Idée** : invariance d'octave.

# Descripteurs : vecteur de chroma

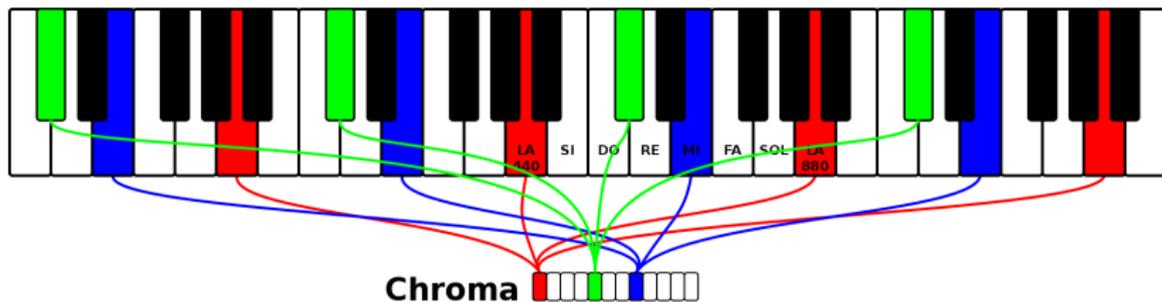


**Chroma**

**Principe** : avoir une description synthétique des notes jouées.

**Idée** : invariance d'octave.

## Descripteurs : vecteur de chroma

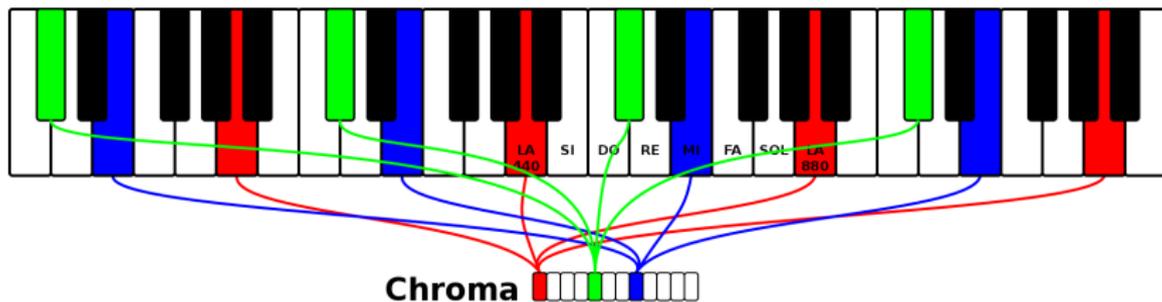


**Principe** : avoir une description synthétique des notes jouées.

**Idée** : invariance d'octave.

**Résultat** : description approximative du contenu harmonique.

# Descripteurs : vecteur de chroma



**Principe** : avoir une description synthétique des notes jouées.

**Idée** : invariance d'octave.

**Résultat** : description approximative du contenu harmonique.

Pour une trame  $m$ , le coefficient  $k$  est

$$\mathbf{c}_m(k) \triangleq \sum_{p=p_{\min}}^{p_{\max}} \left| \mathbf{x}_m \left( \left[ f_0^{(k,p)} \frac{N_{\text{fft}}}{f_s} \right] \right) \right|$$

avec

$p$  octave,  $N_c$  taille de  $\mathbf{c}_m$

$$f_0^{(k,p)} \triangleq 440 \times 2^{\frac{k}{N_c}} \times 2^p$$

# Références sur les descripteurs



B. Mathieu, S. Essid, T. Fillon, J. Prado, G. Richard, YAAFE, an Easy to Use and Efficient Audio Feature Extraction Software, proceedings of ISMIR, 2010.



G. Peeters, A large set of audio features for sound description (similarity and classification) in the CUIDADO project, Technical report, Ircam, 2004.



T. Bertin-Mahieux, D. P.W. Ellis, B. Whitman, P. Lamere, The Million Song Dataset, proceedings ISMIR, 2011.

Introduction

Les descripteurs audio

Présentation du TP

Objectif et principe

Détail des blocs

# Objectif : estimation de la structure musicale d'un morceau

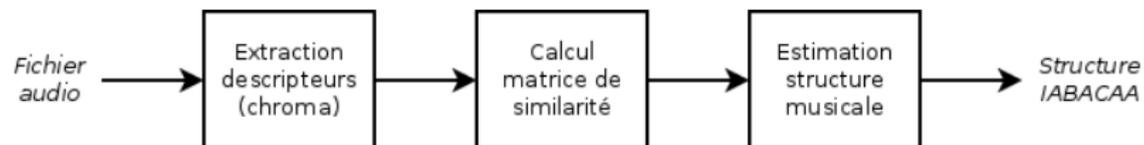
## Éléments de la structure d'un morceau

- ▶ Nature : Intro, refrain, couplets, break, etc.
- ▶ Propriété 1 : répétition de chaque élément
- ▶ Propriété 2 : homogénéité de chaque élément

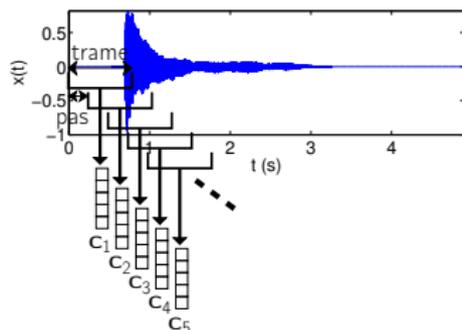
## Objectif

Segmenter le morceau selon sa structure d'auto-similarité.

# Principales étapes du système



# Lecture du son, calcul des descripteurs



Son  $\mathbf{x} = [x(0), \dots, x(N_x - 1)]^T \in \mathbb{R}^{N_x}$ , de fréquence d'échantillonnage  $f_s$ .  
Trames de longueur  $N$ , indexée par  $m \in \llbracket 0, M - 1 \rrbracket$  :

$$\mathbf{x}_m \triangleq [x(n_m), \dots, x(n_m + N - 1)]$$

avec indice de début de trame  $n_m \triangleq mh$  et pas  $h$  (*hop size*).

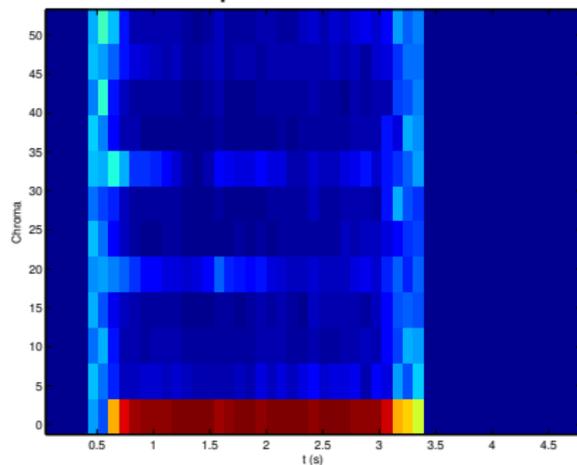
Instant milieu de trame  $t_m \triangleq \frac{n_m + N}{f_s}$ .

Calcul du descripteur  $\mathbf{c}_m$  pour chaque trame  $\mathbf{x}_m$ .

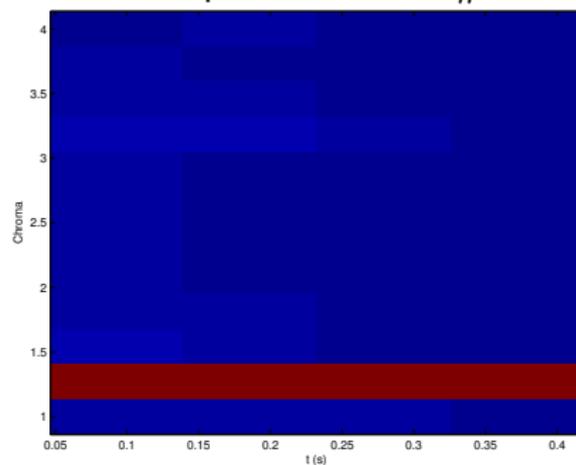
# Test de l'extraction des chromas

Affichage du résultat pour deux sons simples (notes isolées).

Exemple avec un La



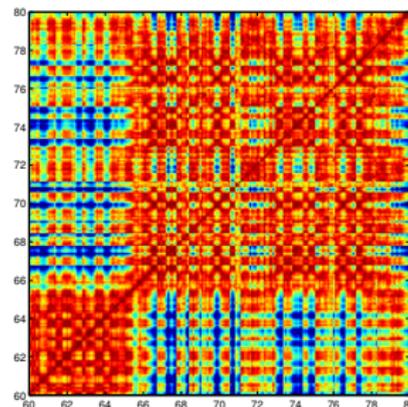
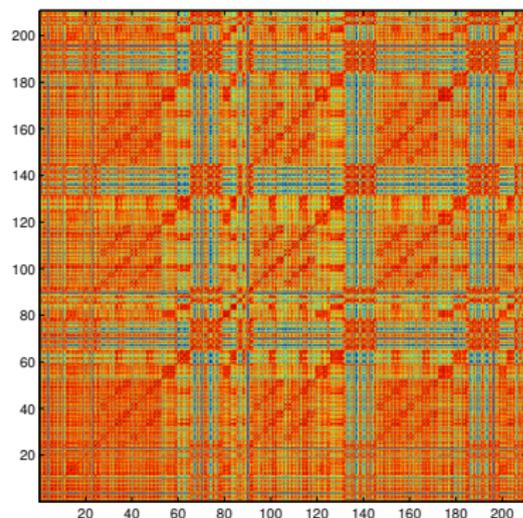
Exemple avec un La#



# Matrice d'autosimilarité : définition

Matrice de similarité  $\Gamma \in \mathbb{R}^{M \times M}$  :

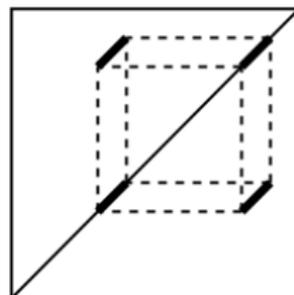
$$\Gamma(m_1, m_2) \triangleq \frac{\langle \mathbf{c}_{m_1}, \mathbf{c}_{m_2} \rangle}{\|\mathbf{c}_{m_1}\|_2 \|\mathbf{c}_{m_2}\|_2}$$



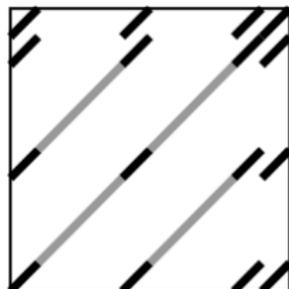
## Matrice d'autosimilarité : utilité

Une séquence répétée  
=  
Un segment de diagonale

$$\Gamma(m_1, m_2) \triangleq \frac{\langle \mathbf{c}_{m_1}, \mathbf{c}_{m_2} \rangle}{\|\mathbf{c}_{m_1}\|_2 \|\mathbf{c}_{m_2}\|_2}$$



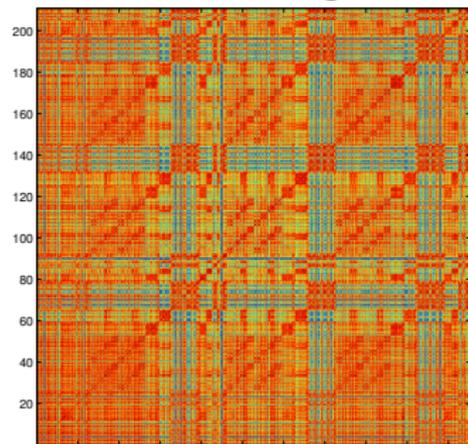
Répétition d'une  
séquence



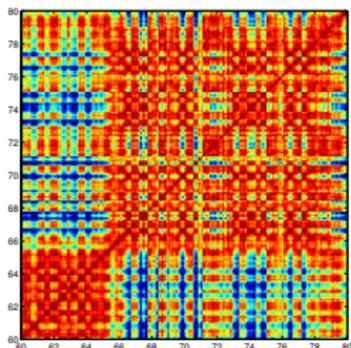
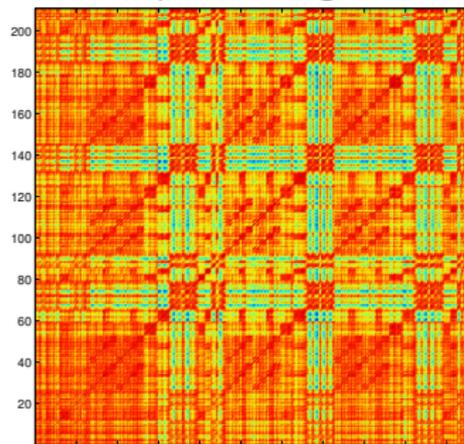
ABABAA

# Réhaussement des motifs diagonaux

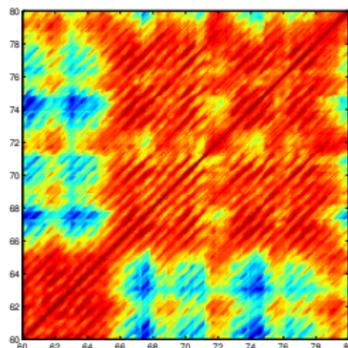
Avant filtrage



Après filtrage



Zoom :

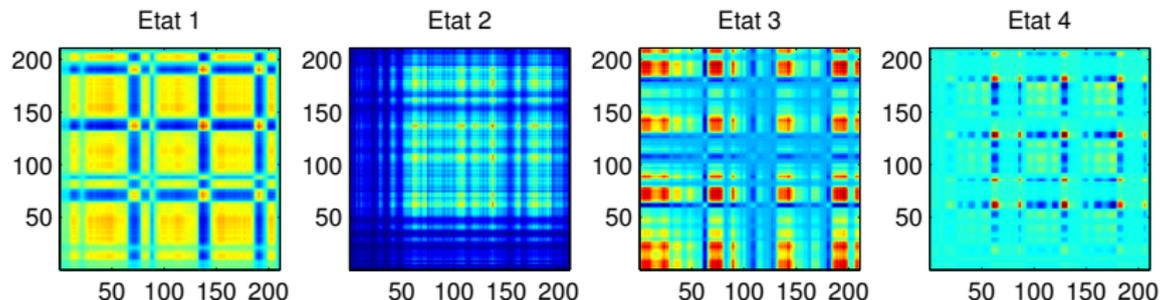


Zoom :

# Estimation des segments

**Principe** : approximation de la matrice d'autosimilarité comme une somme de matrices de rang 1.

**Méthode** : décomposition en valeurs singulières.



Questions?