

1. Introduction

1.1 Applications des techniques d'indexation audio pour la musique

2. Théorie : Traitement du signal

2.1 Transformée de Fourier (temps et fréquences continus)

2.2 Transformée de Fourier (temps et fréquences discrets)

2.3 Transformée de Fourier (à Court Terme) : TFCT

2.4 Transformée à Q-Constant (CQT)

3. Descripteurs Audio

3.1 Mel Frequency Cepstral Coefficients (MFCCs)

3.2 Chroma - Pitch Class Profile (PCP)

4. Applications

4.1 Identification audio

4.2 Estimation du tempo

4.3 Estimation de la structure musicale

5. Séparation de sources

5.1 Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

5.2 Factorisation (décomposition) en matrices non-négatives

6. Transformation du signal

6.1 Application : dilatation/ contraction du temps par vocodeur de phase

6.2 Transformation du signal par la méthode P-SOLA

1- Introduction

Applications des techniques d'indexation audio pour la musique



Enter a keyword, record a query or drag an example clip.



[Steve Jobs interview](#)
7 min 14 sec
Speech



[Metric - Raw Sugar](#)
3 min 47 sec
Music - Indie Pop



[Grenade explosion](#)
23 sec
Sound effect

[similarly random recordings »](#)

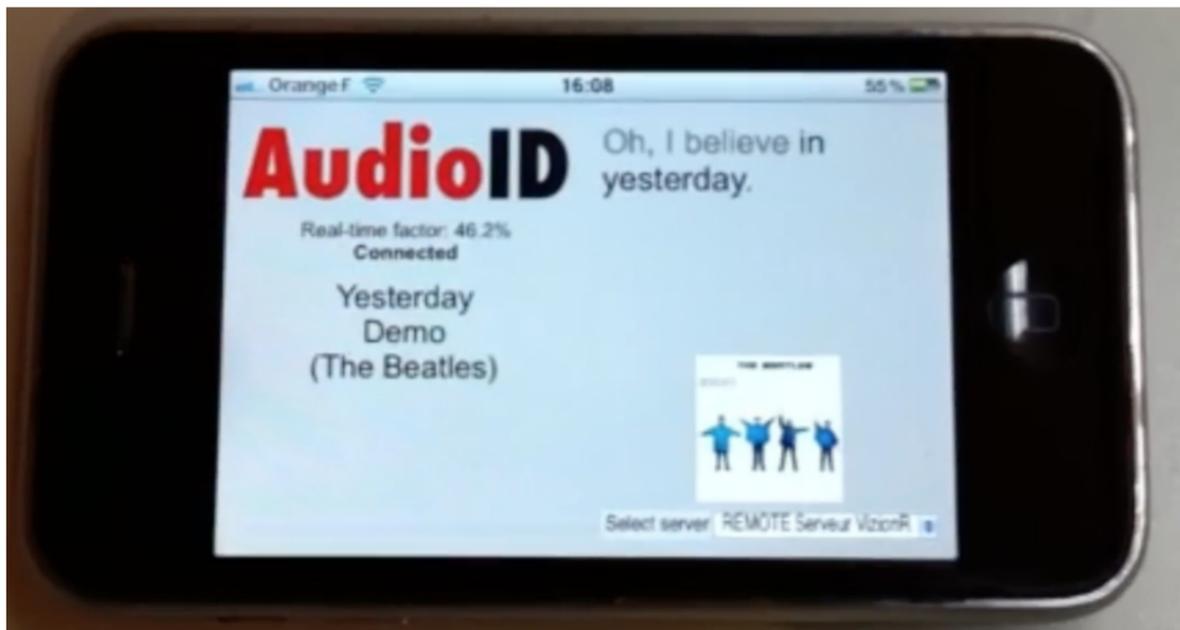
[Google Labs](#) - [Discuss](#) - [Terms of use](#) - [About Google Audio](#) - [Submit your recording](#)

source : Gaël Richard

1- Introduction

Applications des techniques d'indexation audio pour la musique

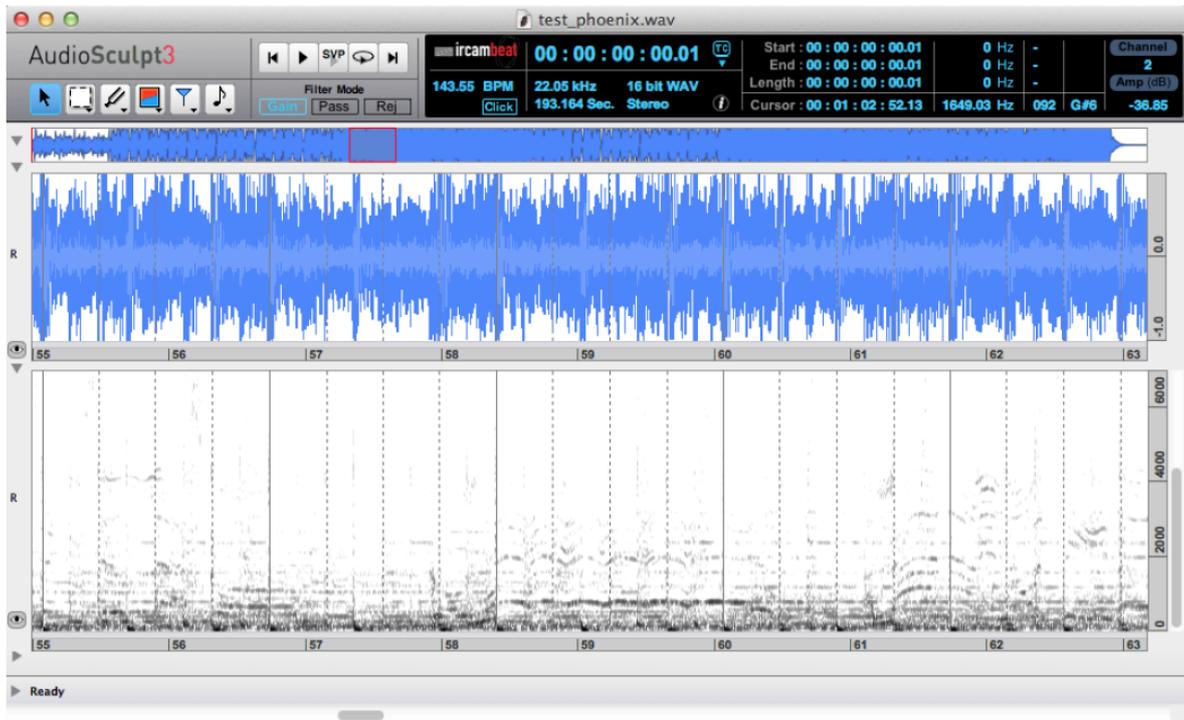
- Identification audio
 - recherche de doublons, gestion de copyright, attacher des méta données à une instance d'un morceau



1- Introduction

Applications des techniques d'indexation audio pour la musique

- Estimation du tempo, de la position des temps/ premier-temps
 - DJing, mainpulation du contenu (add swing ...)



1- Introduction

Applications des techniques d'indexation audio pour la musique

- Nouveaux modes de recherche :
 - par chantonement/ sifflement

Query by Humming v0.51b

IIS

Query by Humming

1.7 3.3 5.0 6.6 8.3 sec

Mic-Gain

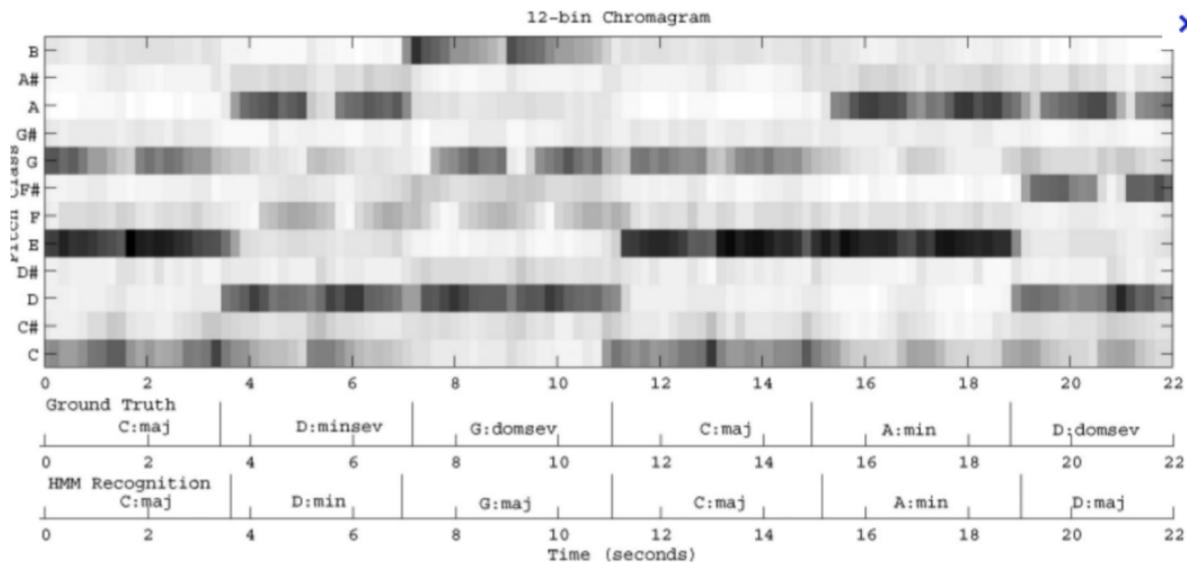
Playing...

good Find ster Top10

1- Introduction

Applications des techniques d'indexation audio pour la musique

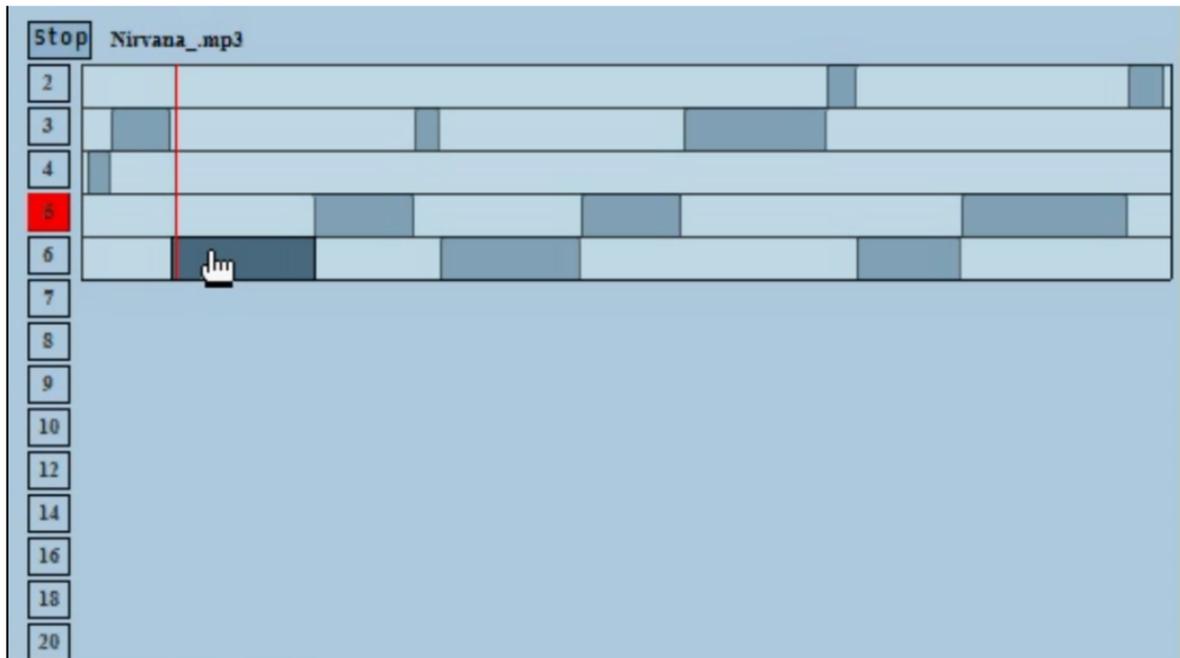
- Estimation des accords
 - obtenir des guitar-tab automatiquement



1- Introduction

Applications des techniques d'indexation audio pour la musique

- Navigation à l'intérieur d'un morceau de musique par couplet/refrain
 - Génération automatique de résumé audio
- Dé-linéarisation d'un flux audio :
 - segmentation de flux radio, télé et étiquetage des parties



1- Introduction

Applications des techniques d'indexation audio pour la musique

- Détection des cover, reprises ou ... des plagias

Titre	Artiste	Album	D.	Pop.	
Let It Be	∨ The Beatles Recovered Band	30 Beatles Top Hits	03:50		<input type="checkbox"/>
Let It Be	∨ The Hit Co., The Tribute Co.	A Tribute to the Beatles: The Lat...	03:42		<input type="checkbox"/>
Let It Be	∨ Labrinth	Let It Be	03:05		<input type="checkbox"/>
Let It Be Me	∨ Ray LaMontagne	Gossip in The Grain	04:41		<input type="checkbox"/>
Let It Be – The Beatles Tribute	Let It Be	Let It Be – The Beatles Tribute	03:49		<input type="checkbox"/>
Let It Be	Lois	Let It Be – The Voice 2	03:15		<input type="checkbox"/>
Let It Be	The Yesteryears	A Tribute to #1 Beatles Hits – T...	03:48		<input type="checkbox"/>
Let It Be	∨ Aretha Franklin	This Girl's In Love With You	03:33		<input type="checkbox"/>
Let It Be Sung	∨ Jack Johnson, Matt Costa, Zach Gill,...	If I Had Eyes	04:09		<input type="checkbox"/>
Let It Be	Vox Angeli	Gloria	03:26		<input type="checkbox"/>
Let It Be	∨ Paul McCartney	Good Evening New York City	03:54		<input type="checkbox"/>
Hey Jude	Let It Be	Hey Jude	03:55		<input type="checkbox"/>
Let It Be	Joan Baez	Greatest Hits And Others	03:51		<input type="checkbox"/>

1- Introduction

Applications des techniques d'indexation audio pour la musique

- Recherche d'un contenu audio dans une base de données
 - autrement que par "artistes", "titres" (Google musical)

The screenshot shows a music search interface. At the top, there is a search bar with the text 'maceo parker' and a 'Rechercher' button. Below the search bar, there are search results for 'maceo parker (8)' and 'all the king s men/maceo parker (3)'. The main content area displays a large preview for the track 'Got to get you' by Maceo Parker, including a play button, a progress bar, and a 'Get Similar Tracks' button. Below the preview, there is a table of search results.

Titre	Artiste	Album	Durée
Got to get you	Maceo Parker	Life on Planet Groove	07:10
Pass the pass	Maceo Parker	Life on Planet Groove	11:28
Addictive Love	Maceo Parker	Life on Planet Groove	09:00
Shake everything you've got	Maceo Parker	Life on Planet Groove	16:41
Soul Power 92	Maceo Parker	Life on Planet Groove	14:13
Georgia on my mind	Maceo Parker	Life on Planet Groove	07:25
I got you (I Feel Good)	Maceo Parker	Life on Planet Groove	03:47
Children's World	Maceo Parker	Life on Planet Groove	06:23

On the right side of the interface, there are several filters and categories:

- HUMEURS**: JOYEUX, CALME (1), DYNAMIQUE (5), ROMANTIQUE, TRISTE
- GENRES**: POPIROCK, BLUES (2), ELECTRONIQUE, METAL/PUNK, REGGAE, CLASSIQUE, JAZZ, RAP, SOUL/FUNK (7), LATIN, RNB
- INSTRUMENTATIONS**: GUITARE ELECTRIQUE (6), GUITARE ACOUSTIQUE, ELECTRONIQUE, BATTERIE (8), CUIVRES (2), ORCHESTRE A CORDES, PIANO, ACOUSTIQUE
- ENREGISTREMENTS**: STUDIO (1), LIVE (7)
- MES PLAYLISTS**: 1 - Ismir (2), + nouvelle playlist

2- Théorie : Traitement du signal

2.1- Transformée de Fourier (temps et fréquences continus)

2- Théorie : Traitement du signal

Transformée de Fourier (temps et fréquences continus)

Transformée de Fourier (temps et fréquences continus)

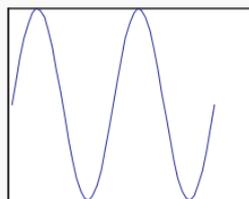
$$X(\omega) = \int_{t=-\text{inf}}^{+\text{inf}} x(t) e^{-j\omega t} dt \quad X(f) = \int_{t=-\text{inf}}^{+\text{inf}} \exp(-j2\pi ft) dt$$

- Variables :

- t est le **temps**
- $\omega = 2\pi f$ les **fréquences continues** exprimées en radian,
- $\exp(j2\pi ft) = \cos(2\pi ft) + j \cdot \sin(2\pi ft)$.

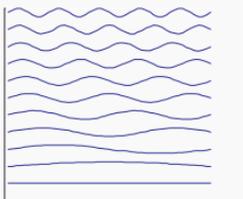
- Pourquoi la Transformée de Fourier ?

- Difficile d'extraire des observations directement à partir de la forme d'onde $x(t)$
- Reproduire la décomposition en fréquences de l'oreille humaine

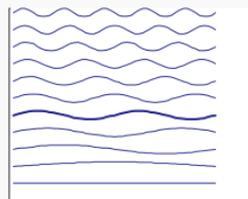


$x(t)$

X



$\sin(2 \pi f t)$



2- Théorie : Traitement du signal

Transformée de Fourier (temps et fréquences continus)

Propriété de la Transformée de Fourier (temps et fréquences continus)

Propriétés	$x(t)$	$X(f)$
Similitude	$x(at)$	$\frac{1}{ a } X\left(\frac{f}{ a }\right)$
Linéarité	$ax(t) + by(t)$	$aX(f) + bY(f)$
Translation	$x(t - t_0)$	$X(f) \exp(-j2\pi ft_0)$
Modulation	$x(t) \exp(j2\pi f_0 t)$	$X(f - f_0)$
Convolution	$x(t) \otimes y(t)$	$X(f) Y(f)$
Produit	$x(t)y(t)$	$X(f) \otimes Y(f)$
Parité	réelle paire réelle impaire imaginaire paire imaginaire impaire complexe paire complexe impaire réelle $x^*(t)$	réelle paire imaginaire paire imaginaire paire réelle impaire complexe paire complexe impaire $X(f) = X^*(-f)$ $\Re(X(f))$ est paire $\Im(X(f))$ est impaire $X^*(f)$

2- Théorie : Traitement du signal

Transformée de Fourier (temps et fréquences discrets)

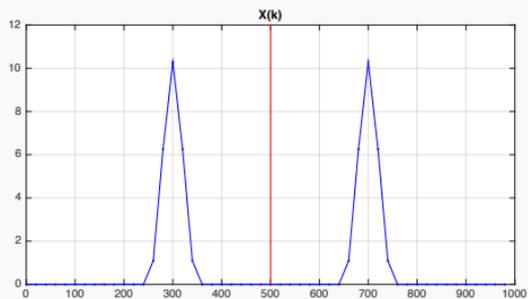
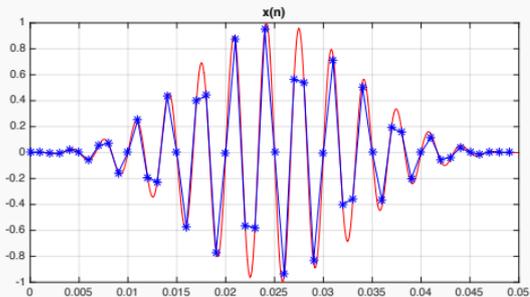
$$X(k) = \sum_{m=0}^{N-1} x(m) e^{-j2\pi \frac{k}{N} m} \quad \forall k \in [0, N]$$

- Variables :
 - m le numéro d'**échantillon**
 - k les **fréquences discrètes**
- Fréquence d'échantillonnage (sampling rate) sr
 - sr définit à quelle fréquence le signal temporel va être échantillonné
 - Exemple :
 - Compact Disc $sr = 44100$ Hz
 - La distance temporelle entre deux échantillons (le pas d'échantillonnage) est de $\Delta t = \frac{1}{44100} = 0.000023$ s.
- sr doit être $>$ à deux fois la f_{\max} présente dans le signal
 - Sinon : repliement spectral
 - exemple : captation d'une roue d'une voiture accélérant dans les films
 - **Fréquence de Nyquist** : $f_{Nyquist} = \frac{sr}{2} > f_{\max}$

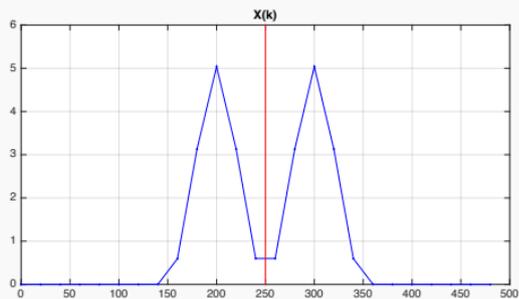
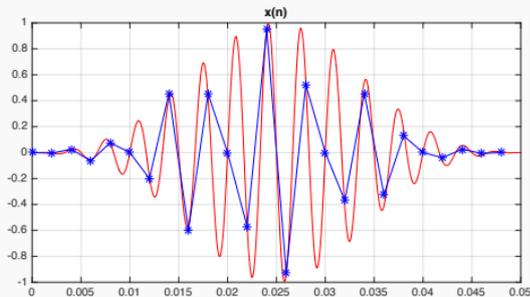
2- Théorie : Traitement du signal

Transformée de Fourier (temps et fréquences discrets)

$$f_{\max} = 300, sr = 1000$$



$$f_{\max} = 300, sr = 500$$



2- Théorie : Traitement du signal

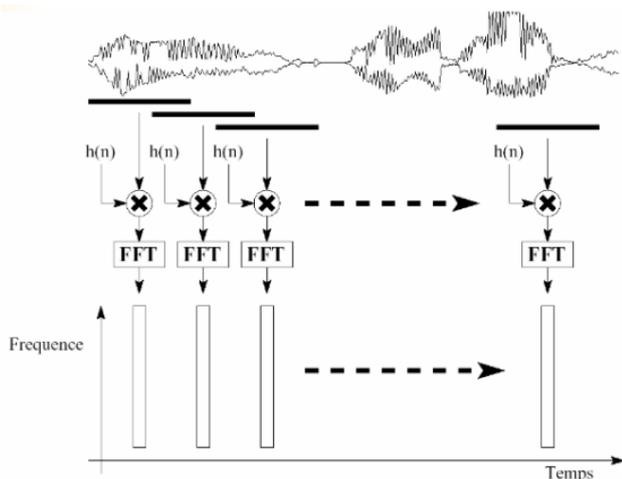
Transformée de Fourier (à Court Terme) : TFCT

$$X(k, n) = \sum_{m=0}^{N-1} x(m)w(n-m)e^{-j2\pi\frac{k}{N}m} \quad \forall k \in [0, N]$$

- Application de la TFD à une portion du signal centrée autour de l'échantillon n

Pourquoi la TFCT ?

- Signal audio = non-stationnaire
 - ses propriétés varient au cours du temps
- **Stationnaires "localement"** (en temps)
 - sur une durée de ± 40 ms
- TFCT = suite d'analyses de Fourier sur des durées de ± 40 ms
 - = analyse à Court Terme ("trames/frames" en vidéo)



source : Jean Laroche

2- Théorie : Traitement du signal

Transformée de Fourier (à Court Terme) : TFCT

$$X(k, n) = \sum_{m=0}^{N-1} x(m)w(n - m)e^{-j2\pi\frac{k}{N}m} \quad \forall k \in [0, N]$$

Fenêtre de pondération $w(t)$

- $x(t) \cdot w(t) \Rightarrow X(f) \circledast W(f)$
 - $w(t)$ est appelé "**fenêtre de pondération**"
 - $w(t)$ différents **types** de fenêtre
 - $w(t)$ définie sur un horizon fini (**longueur temporelle**) $[0, L]$.
 - Choix du type et de la longueur détermine les caractéristiques spectrales
 - Largeur de bande fréquentielle (à $-6dB_{20}$) : $Bw = \frac{Cw}{L}$
 - Hauteur des lobes secondaires

2- Théorie : Traitement du signal

Transformée de Fourier (à Court Terme) : TFCT

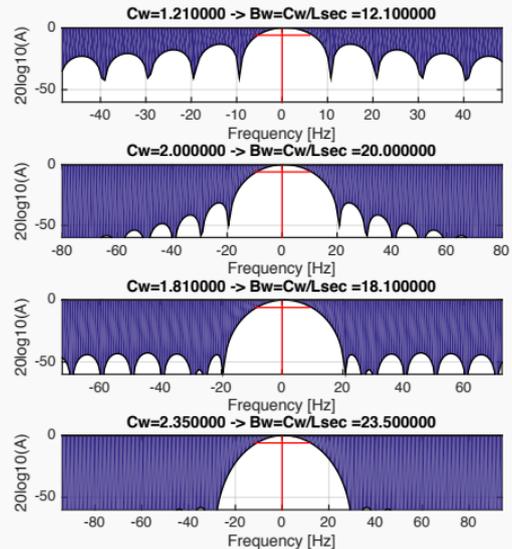
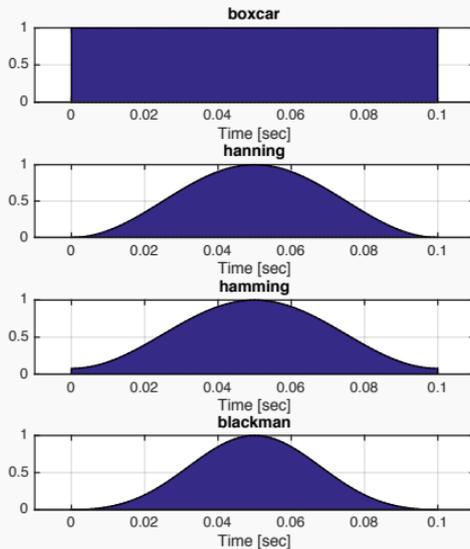
Choix du **type** de la fonction :

- rectangulaire
 - $w(n) = 1$
 - $BW = 1.21$
- hanning
 - $w(n) = 0.5(1 - \cos(\frac{2\pi n}{N-1}))$
 - $BW = 2$
- hamming
 - $w(n) = 0.54 - 0.46 \cos(\frac{2\pi n}{N-1})$
 - $BW = 1.81$
- blackman
 - $w(n) = a_0 - a_1 \cos(\frac{2\pi n}{N-1}) + a_2 \cos(\frac{2\pi n}{N-1})$
 - $BW = 2.35$

2- Théorie : Traitement du signal

Transformée de Fourier (à Court Terme) : TFCT

Influence du **type** de la fonction



2- Théorie : Traitement du signal

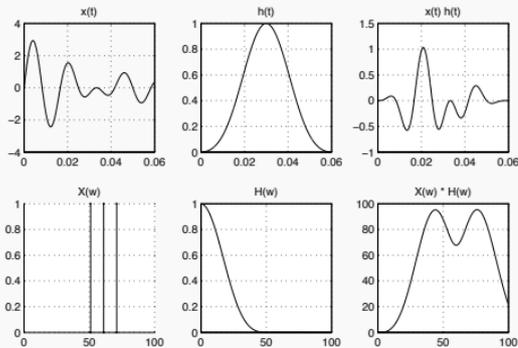
Transformée de Fourier (à Court Terme) : TFCT

Choix de la longueur temporelle L :

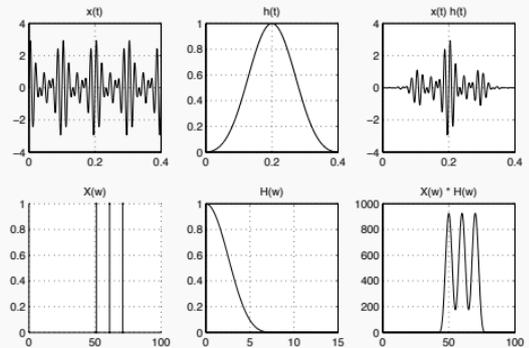
- Au plus la fenêtre est courte,
 - au plus on observe précisément les temps.
- Au plus la fenêtre est longue,
 - au plus on observe précisément les fréquences.

2- Théorie : Traitement du signal Transformée de Fourier (à Court Terme) : TFCT

Influence de la **longueur temporelle L**
($L = 0.06s.$)

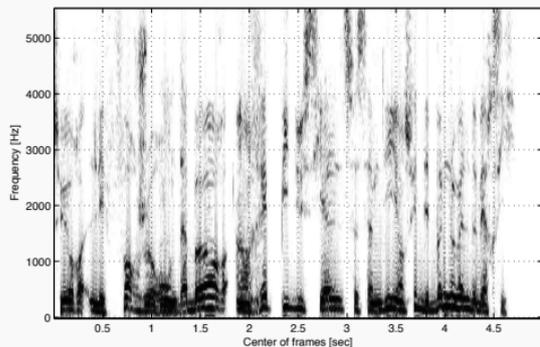


Influence de la **longueur temporelle L**
($L = 0.4s.$)

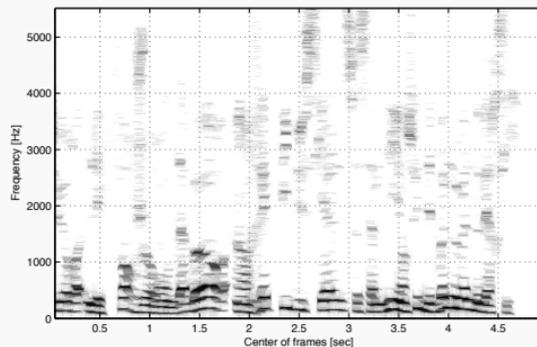


2- Théorie : Traitement du signal Transformée de Fourier (à Court Terme) : TFCT

Influence de la **longueur temporelle** L
($L = 0.01s.$)



Influence de la **longueur temporelle** L
($L = 0.1s.$)

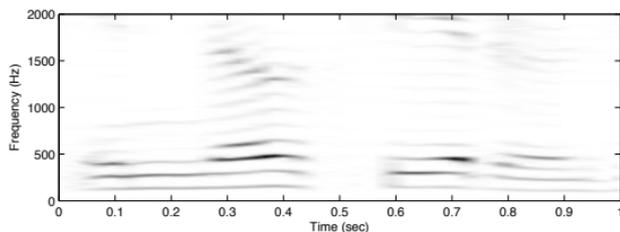
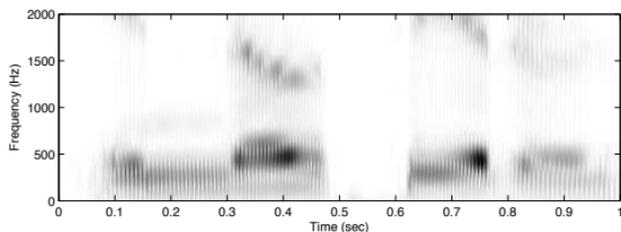
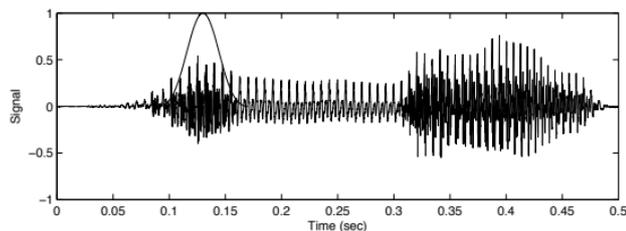
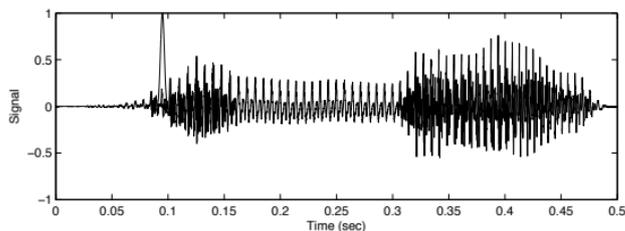


2- Théorie : Traitement du signal

Transformée de Fourier (à Court Terme) : TFCT

Paradoxe temps/ fréquence

- Pas possible d'avoir simultanément une bonne localisation en temps et en fréquence !



- Comme résoudre ce problème ?
 - Utiliser d'autres transformées que celle de Fourier

2- Théorie : Traitement du signal

2.4- Transformée à Q-Constant (CQT)

2- Théorie : Traitement du signal

Transformée à Q-Constant (CQT)

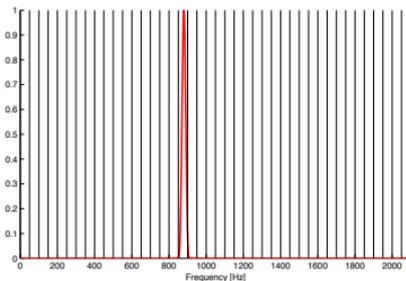
Transformée à Q-Constant (CQT)

- La DFT
 - Définition : **La précision fréquentielle** : $\Delta f = \frac{sr}{N}$
 - c'est le pas d'échantillonnage du spectre
 - elle dépend de la taille de la DFT : N
 - on peut l'augmenter en augmentant N
 - Définition : **La résolution fréquentielle** : $B_w = \frac{C_w}{L}$
 - c'est le pouvoir de séparation entre deux fréquences présentes simultanément dans le spectre, le pouvoir de résoudre spectralement
 - Attention :
 - même si on augmente N (zero-padding) en gardant L constant on n'améliore pas la résolution !
- Dans la DFT, la précision et la résolution fréquentielle sont constantes à travers les fréquences

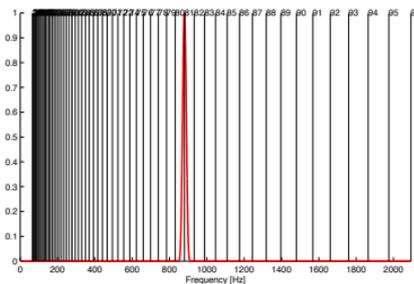
2- Théorie : Traitement du signal Transformée à Q-Constant (CQT)

Transformée à Q-Constant (CQT)

- En audio musical
 - les fréquences sont logarithmiquement espacées
 - pour passer des fréquences aux hauteurs de notes :
$$m_k = 12 \cdot \log_2 \frac{f_k}{440} + 69$$
 - pour passer des hauteurs de notes aux fréquences : $f = 440 \cdot 2^{\frac{m-69}{12}}$
 - les hauteurs de notes sont plus rapprochées en basses fréquences, plus espacées en hautes fréquences
- La **résolution fréquentielle** de la DFT
 - n'est pas suffisante pour résoudre les hauteurs de notes adjacentes en basses fréquences,
 - est trop importante en hautes fréquences



Espacement linéaire de la DFT



Espacement logarithmique des hauteurs de notes

2- Théorie : Traitement du signal Transformée à Q-Constant (CQT)

Transformée à Q-Constant

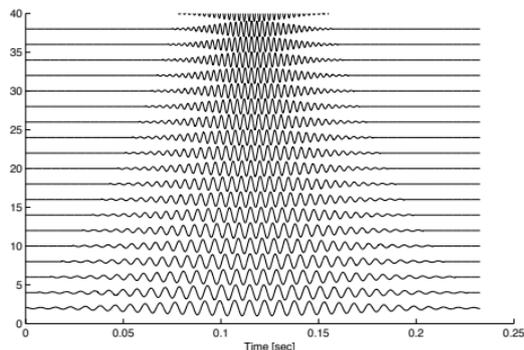
[J. Brown and M. Puckette. An efficient algorithm for the calculation of a constant q transform. JASA, 1992.]

- Solution ?
 - Changer la **résolution fréquentielle** en fonction des fréquences considérées
- Comment ?
 - En changeant la longueur temporelle de la fenêtre pour chaque fréquence considérée
 - Le facteur $Q = \frac{f_k}{f_{k+1} - f_k}$ doit rester constant en fréquence

$$Q = \frac{f_k}{BW} = \frac{f_k}{Cw/L} = \frac{f_k \cdot L}{Cw}$$

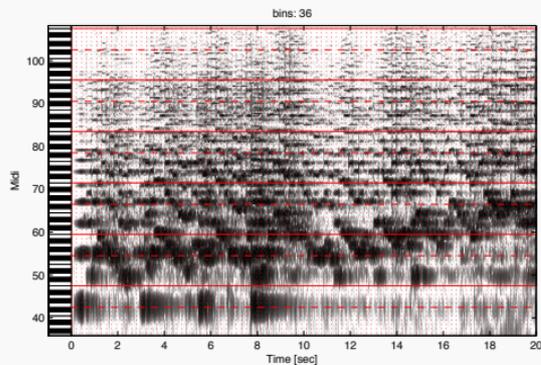
- on choisit un L pour chaque fréquence f_k

- $L_k = \frac{Q \cdot Cw}{f_k}$

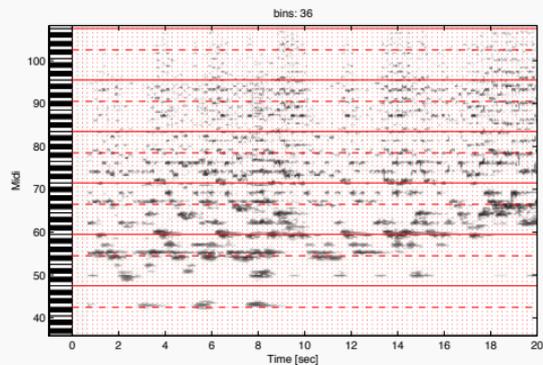


2- Théorie : Traitement du signal Transformée à Q-Constant (CQT)

Exemples (en utilisant la DFT)



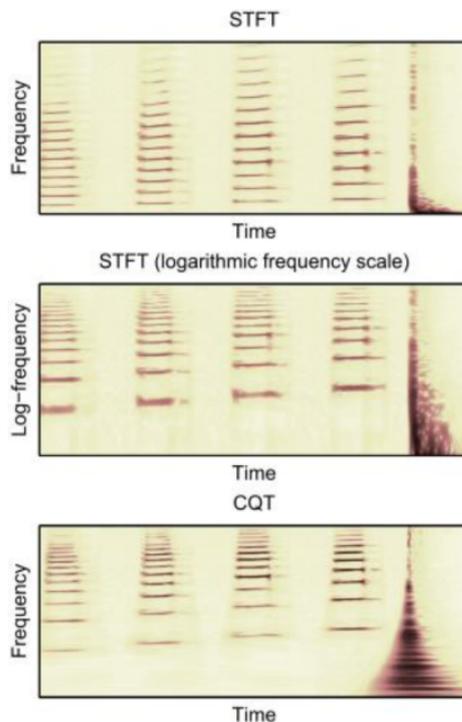
Exemples (en utilisant la CQT)



2- Théorie : Traitement du signal Transformée à Q-Constant (CQT)

Transformée à Q-Constant (CQT)

- Sur une transformée à Q constant :
 - Une différence de pitch correspond à une translation sur l'axe des fréquences



4- Applications

4.1- Identification audio

Identification audio

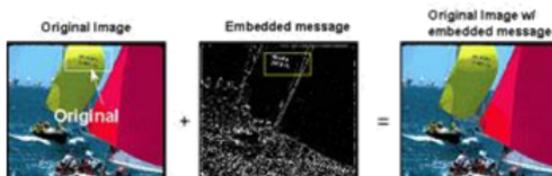
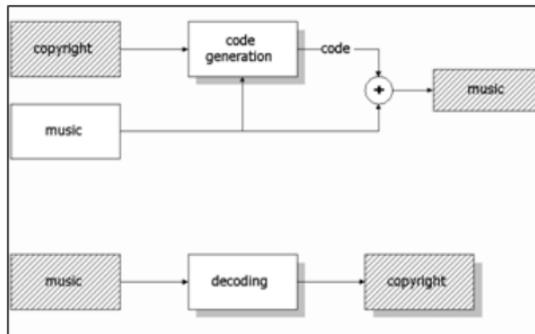
- Objectif :
 - Reconnaître un morceau diffusées sur radio, télé, Internet, bar, discothèque, ...
 - Identifier l'enregistrement (ISRC), pas l'oeuvre (ISWC)

4- Applications

Identification audio

Méthode du Watermarking

- Codage :
 - introduction d'un code identifiant robuste mais inaudible dans le signal sonore
- Décodage :
 - pour un nouveau signal : extraction du code (si il est présent) et recherche de ce code dans une base de données

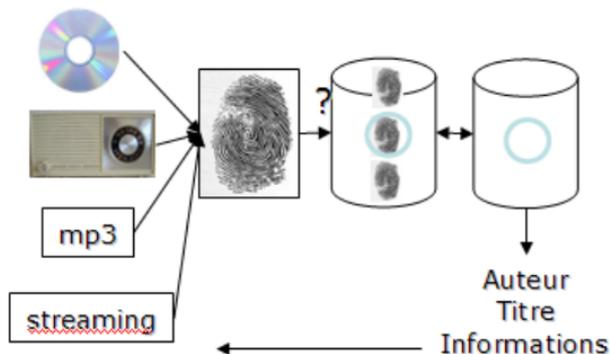


4- Applications

Identification audio

Méthode du Fingerprint

- Shazam, Midomi, Philips, ...
- Codage :
 - prise d'empreinte du signal, stockage dans une base de données
- Décodage :
 - pour un nouveau signal, prise d'empreinte, comparaison avec les empreintes de la base de données
- Challenge :
 - déterminer un ensemble réduit de descripteurs audio extraits du signal sonore permettant d'identifier de manière unique un extrait musical



4- Applications

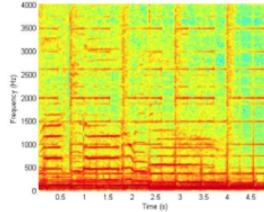
Identification audio

Algorithme de Fingerprint de Shazam

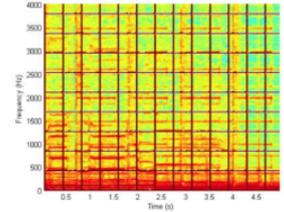
[A. L.-C. Wang. An industrial strength audio search algorithm. In Proc. of ISMIR, 2003.]

[S. Fenet. Empreintes Audio et Stratégies d'Indexation Associées pour l'Identification Audio à Grande Echelle. PhD thesis, Télécom Paris-Tech, 2013.]

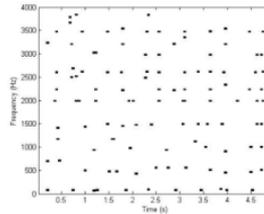
- Extraction de points saillants dans le plan temps/fréquence
 - Calcul du spectrogramme
 - fenêtre de Hamming, $L=64$ ms,
 $S=32$ ms
 - Dans chaque pavé du spectrogramme ($\Delta t=0.4$ s, Δf) :
 - détection du maximum \rightarrow valeur = 1
 - = "constellation points"



(a)



(b)



(c)

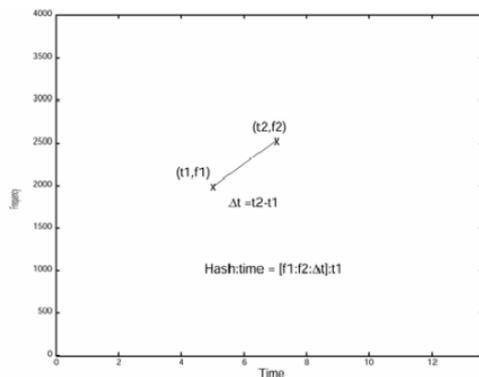
source : Sébastien Fenet

4- Applications

Identification audio

A) Partie stockage de signature

- Représentation des "constellation points" :
 - chaque point est pris comme un "anchor point" ayant une "target zone"
 - $[f_1, f_2, t_2 - t_1]$
 - + le temps de l'anchor t_1
- Méthode de "pruning" des points
 - on ne garde que les pairs de points pour lesquels
 - $f_2 - f_1 < \Delta f_{\max} = 350\text{Hz}$
 - $t_2 - t_1 < \Delta T_{\max} = 3\text{s}$
- Stockage des triplets
 - $[f_1, f_2, t_2 - t_1]$ stocké sur 32 bits

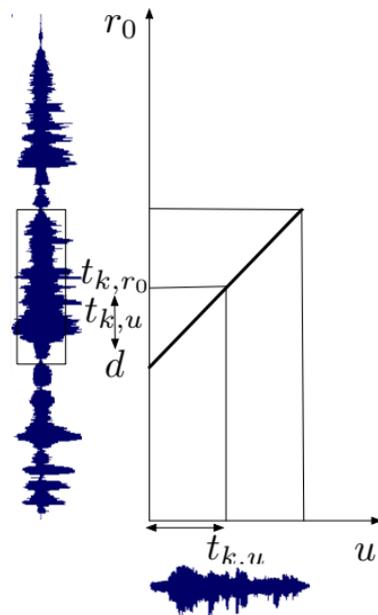


4- Applications

Identification audio

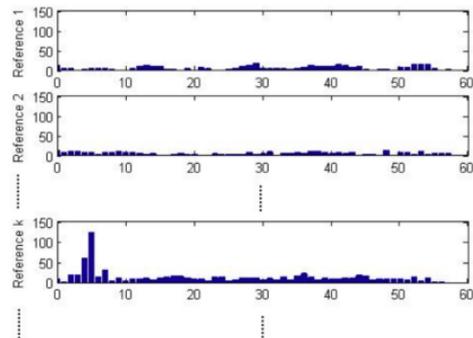
B) Partie matching de signature

- si le signal inconnu u est un extrait de r_0 démarrant au temps d
 - alors toutes les clefs apparaissant dans u doivent être trouvées dans r_0
 - une clef k de u au temps $t_{k,u}$ doit être trouvé dans r_0 au temps $t_{k,r_0} = d + t_{k,u}$
 - si on étudie l'ensemble des valeurs $\{t_{k,r_0} - t_{k,u}\}$ pour toutes les clefs k de u , on doit avoir un maximum d'accumulation en d



B) Partie matching de signature

- Méthode :
 - pour toutes les clefs k de u , pour chaque référence r_i , on stocke toutes les valeurs $\{t_{k,r_i} - t_{k,u}\}$ dans un histogramme
 - l'histogramme avec le plus grand maximum donne la référence du signal inconnu
 - la position du maximum dans cet histogramme donne le point de démarrage d dans le signal de référence



source : Sebastien Fenet

4- Applications

Identification audio



4- Applications

4.2- Estimation du tempo

4- Applications

Estimation du tempo

Rythme ?

- Tempo (beat)
 - indiquer sur une partition
 - "vitesse moyenne à laquelle les gens tapent du pied en écoutant la musique"
- Subdivision du rythme
 - mesure
 - entre deux barres, le groupement des noires
 - tactus
 - généralement la noire → le tempo
 - tatum
 - la vitesse la plus rapide
 - la subdivision de la noire en croches, triple-croches, double-croches

Andante grazioso (♩ = 120)

p

The score shows two measures of music in 6/8 time. The first measure contains a piano (*p*) dynamic marking. The music features eighth notes and quarter notes with various groupings: a pair of eighth notes beamed together, a quarter note, and a pair of eighth notes beamed together. The second measure continues with similar rhythmic patterns. The tempo is marked as 'Andante grazioso' with a metronome marking of 120 quarter notes per minute.

The diagram illustrates the subdivision of a beat into three parts across four different time signatures:

- 3/4 time:** Shows a single beat (1) divided into three eighth notes (2, 3) and then subdivided into sixteenth notes.
- 3/8 time:** Shows a single beat (1) divided into three eighth notes (2, 3) and then subdivided into sixteenth notes.
- 4/4 time:** Shows a single beat (1) divided into four quarter notes (2, 3, 4) and then subdivided into eighth notes.
- 4/8 time:** Shows a single beat (1) divided into four quarter notes (2, 3, 4) and then subdivided into eighth notes.

4- Applications

Estimation du tempo

Estimation du tempo ?

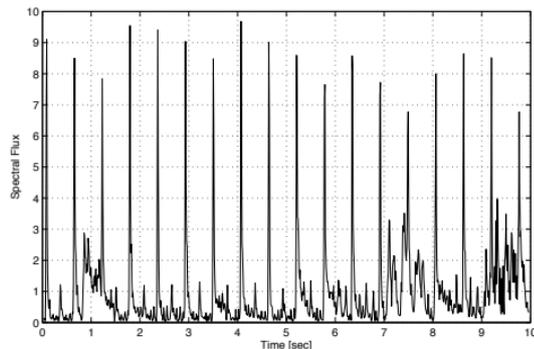
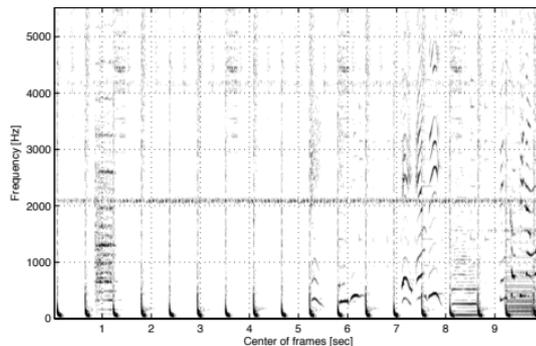
- Détecter la périodicité des évènements dans le signal audio

Détection des évènements ?

- Début des évènements = onsets
- Méthode 1
 - détecter les maxima locaux de la fonction d'énergie du signal
 - $ener(m) = \sum_k X(k, m)^2$
- Méthode 2

- détecter les maxima locaux du flux spectral :

- $flux(m) = \sum_k \text{HWR}[X(k, m) - X(k, m - 1)]$
- $\text{HWR}(x) = x \quad \text{si } x > 1$
- $\text{HWR}(x) = 0 \quad \text{sinon}$



4- Applications

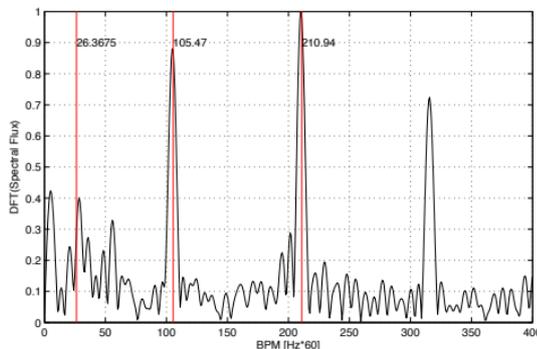
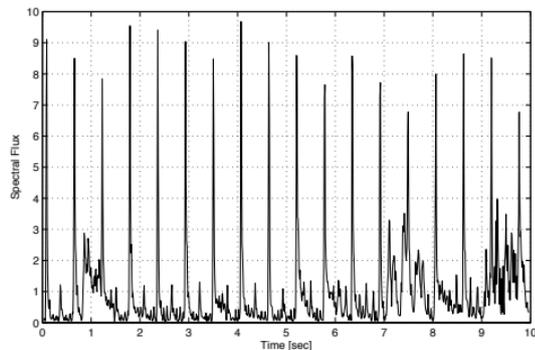
Estimation du tempo

Périodicité des évènements ?

- Calcul de la transformée de Fourier (DFT) du flux spectral :
 - $FLUX(k) = \sum_{n=0}^{N-1} flux(n) \cdot \exp(j2\pi \frac{k}{N} n), \forall k$
- Calcul de la fonction d'auto-corrélation du flux spectral

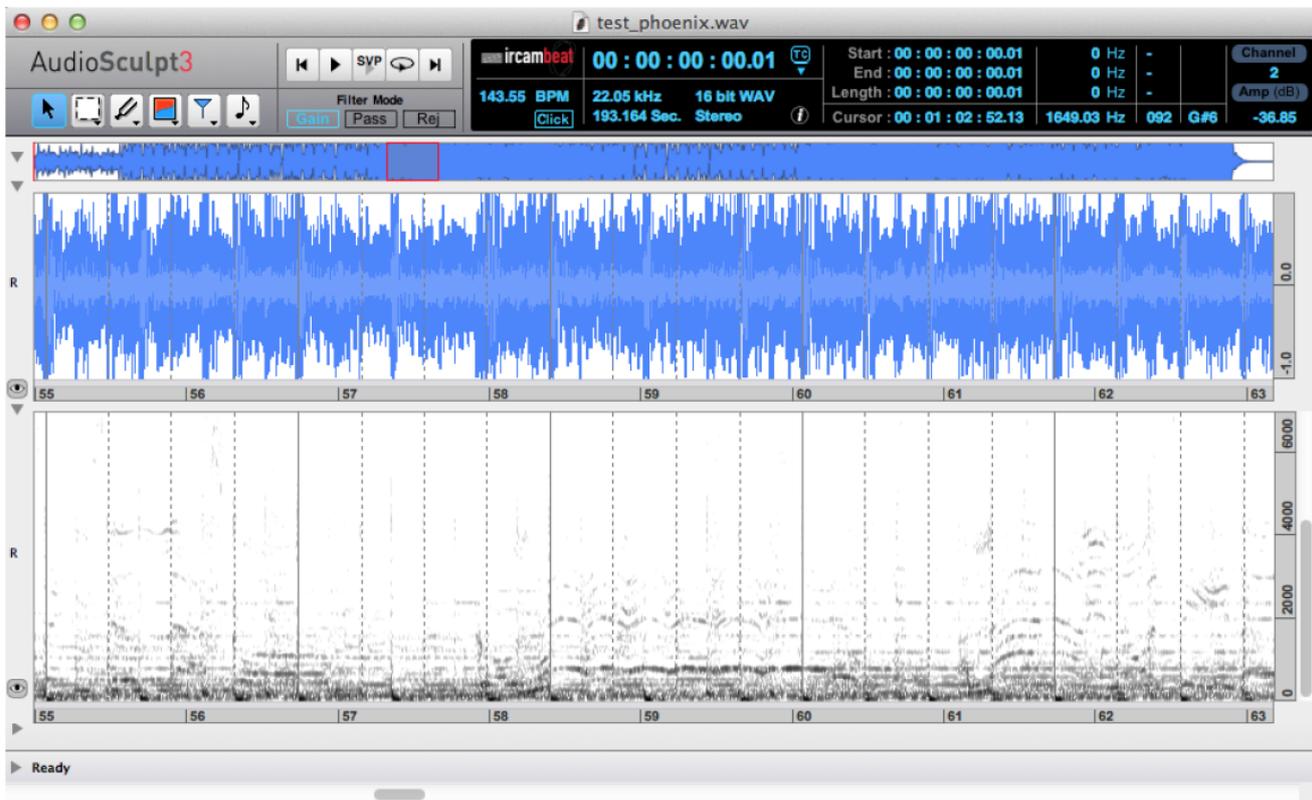
Estimation du tempo ?

- Détecter le peak (fréquence f_k de la DFT) correspondant au tempo
 - Tempo = $60f_k$ (BPM : Battement par Minute)
 - Peaks correspondant à la mesure, au tactus, au tatum



4- Applications

Estimation du tempo



4- Applications

4.3- Estimation de la structure musicale

4- Applications

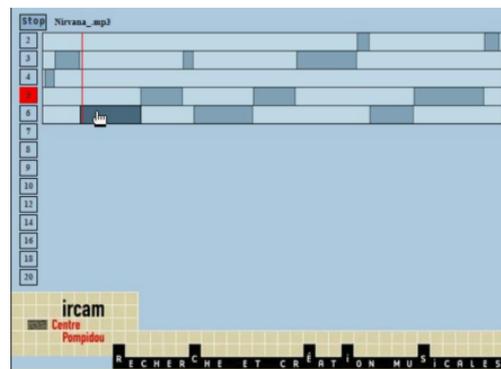
Estimation de la structure musicale

Structure musicale ?

- représentation du morceau comme une suite de parties (introduction, couplet, refrain, ...)

Estimation de la structure musicale ?

- recherche de parties temporelles homogènes et/ou répétées



4- Applications

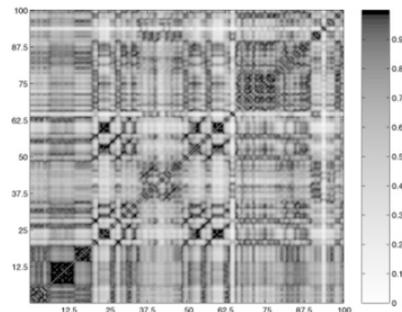
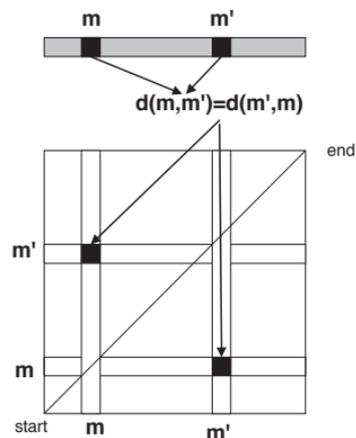
Estimation de la structure musicale

Matrice d'auto-similarité

- représente la similarité entre les différents instants d'un même morceau

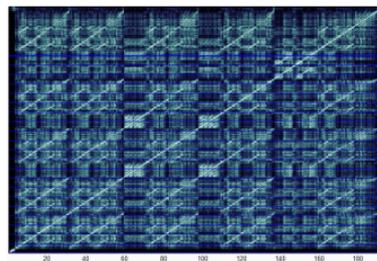
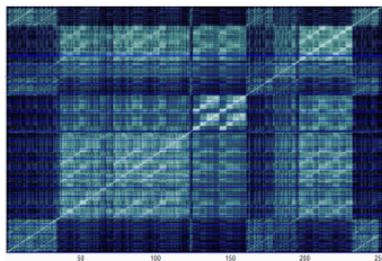
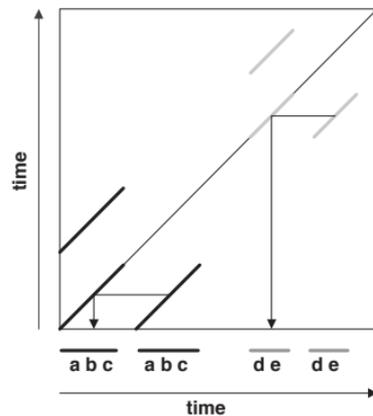
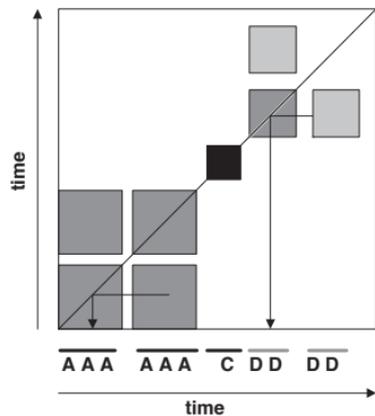
Méthode

- On calcul la distance (euclidienne, cosinusoidale) entre les différents instants t d'un même morceau
- $d(t_1, t_2) = d(C(n, m_1), C(n, m_2)) \quad \forall t_1, t_2$
- On représente $d(t_1, t_2)$ sous forme d'une matrice (de similarité/ distance ou encore de co-occurrences)
- Utilisation :
 - localisation des couplets, refrain



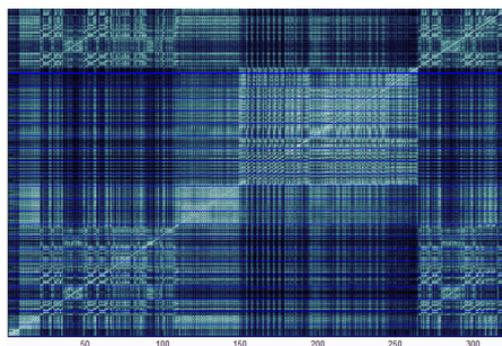
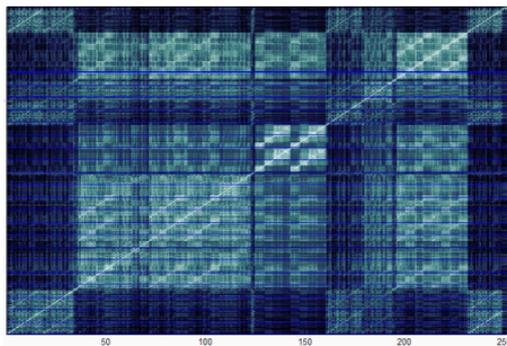
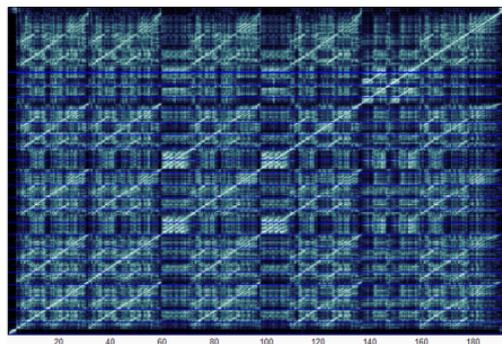
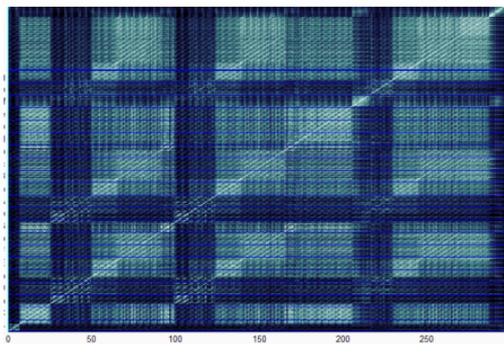
4- Applications

Estimation de la structure musicale



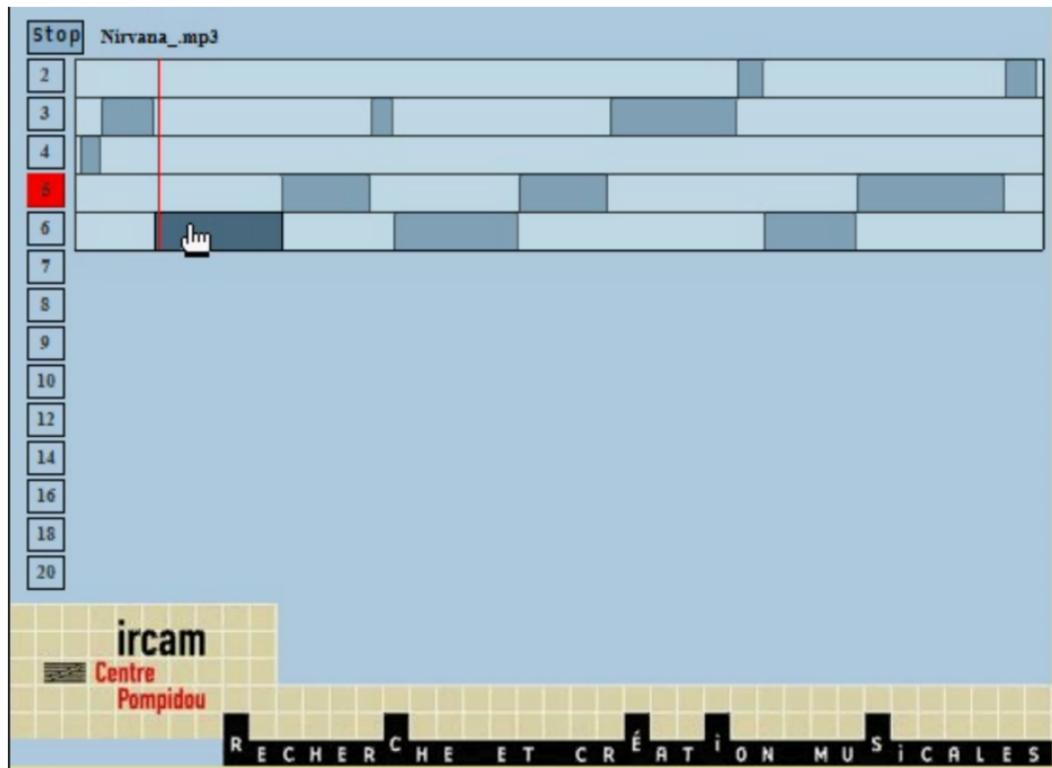
4- Applications

Estimation de la structure musicale



4- Applications

Estimation de la structure musicale



5- Séparation de sources

5.1- Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

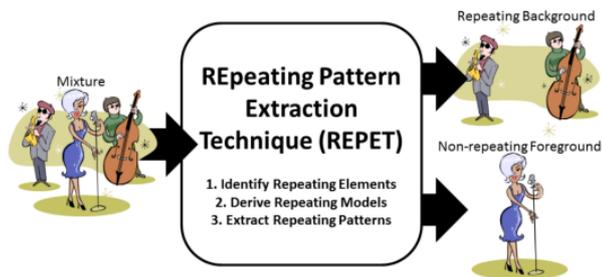
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Introduction

[Zafar Rafii, Antoine Liutkus, and Bryan Pardo. "REPET for Background/Foreground Separation in Audio," Blind Source Separation, Springer, Berlin, Heidelberg, 2014]

- **REPET** : REpeating Pattern Extraction Technique (REPET)
- En musique, une pièce est souvent caractérisée par une structure sous-jacente répétitive par dessus laquelle des éléments non-répétés sont superposés
 - Il existe donc des patterns plus ou moins répétés en temps et en fréquence
 - Ces patterns répétés peuvent être identifiés en utilisant un masque temps-fréquence
 - Le masque T/F peut ensuite être appliqué pour extraire les patterns répétés



source : Rafii

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Repeating Pattern Extraction Technique (REPET)

- Identifier les éléments répétés
- Dérivé un modèle de répétition
- Extraite la structure répétée

Méthode simple de séparation musique - voix

- $X_{mix} = X_{background} + X_{foreground}$
- $X_{mix} = X_{repeat} + X_{non-repeat}$
- $X_{mix} = X_{dense, low-rank} + X_{sparse}$
- Structure répétée = accompagnement musical
- Structure non-répétée = voix

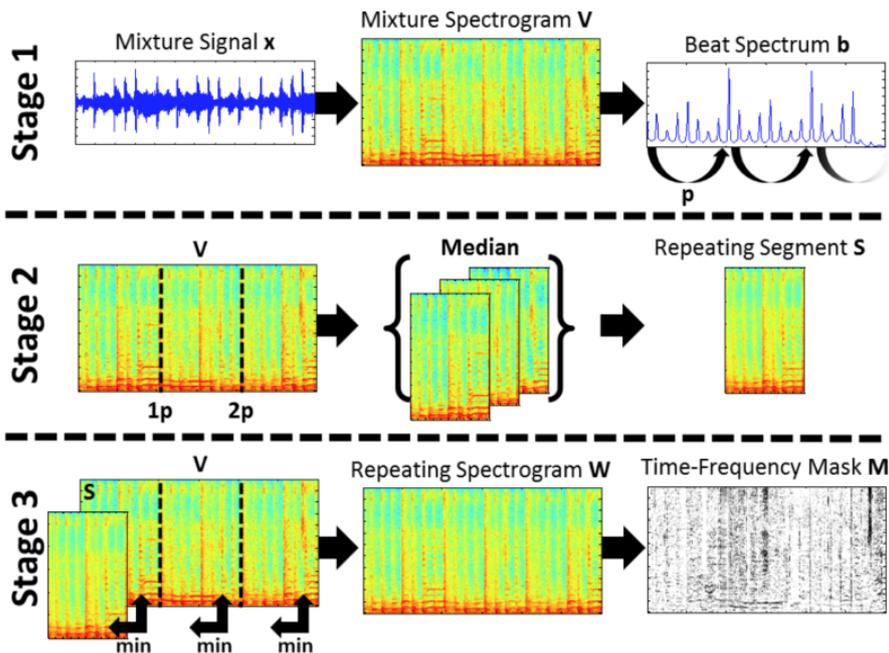
Hypothèses

- L'arrière plan répété est dense et de rang-faible
 - Souvent vrai pour la voix dans un mélange musique + voix

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET



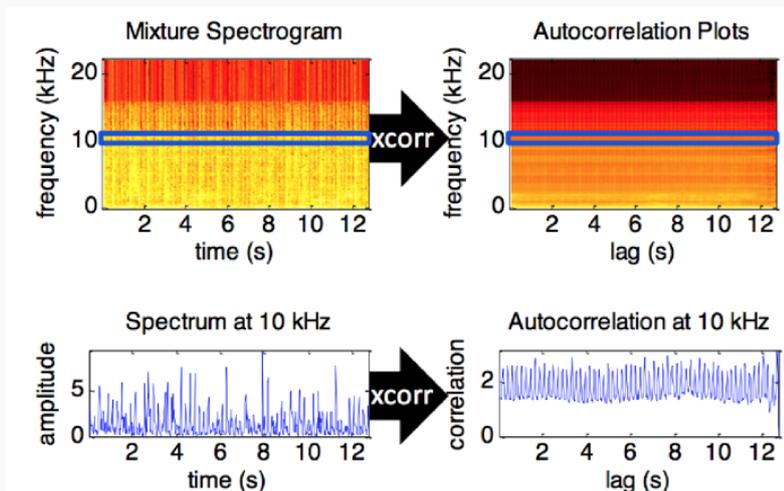
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 1. Détecter la période de répétition

- On calcule l'auto-corrélation de chaque ligne du spectrogramme X_{mix}



source : Rafii

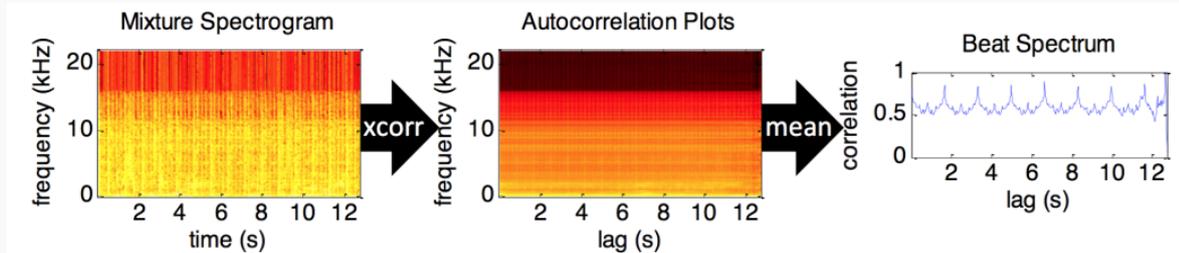
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 1. Détecter la période de répétition

- On prend la moyenne des fonctions d'auto-corrélation pour obtenir le "beat spectrum"



source : Rafii

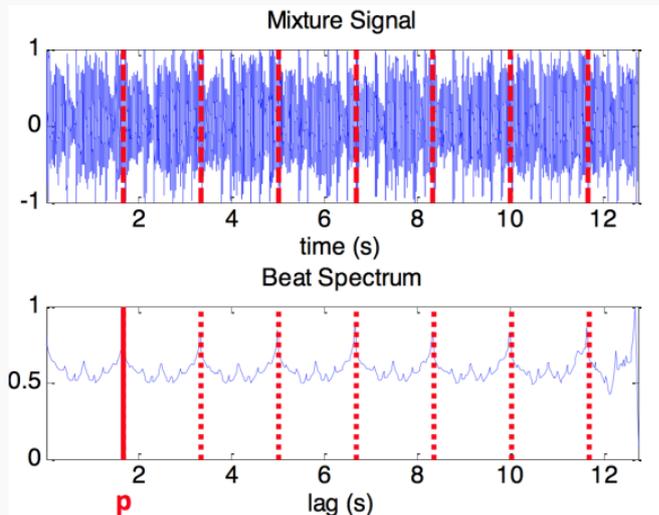
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 1. Détecter la période de répétition

- Le "beat spectrum" révèle la période de répétition p de la structure sous-jacente répétée
- On suppose ici que l'arrière-plan (accompagnement) est plus dense et de rang plus faible que l'avant-plan



source : Rafii

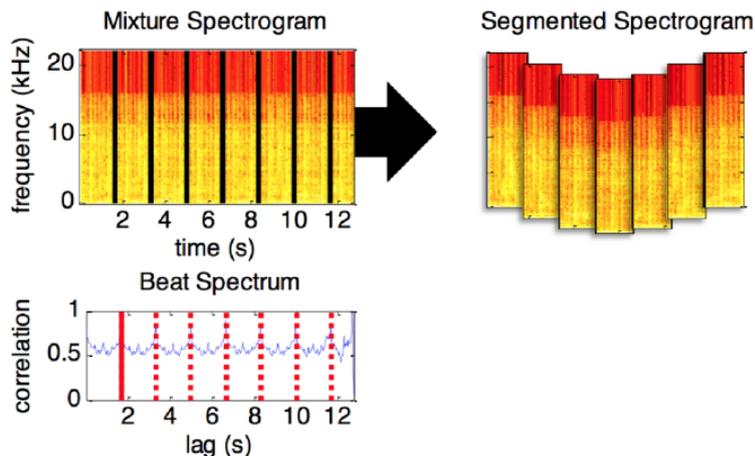
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

- **2. Segment répété**

- La période de répétition est alors utilisée pour segmenter le spectrogramme du mélange à la vitesse de la période



source : Rafii

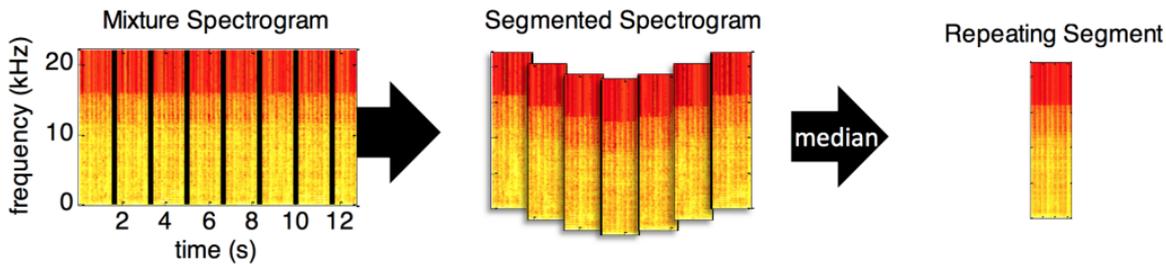
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

- **2. Segment répété**

- Le segment répété est calculé comme la valeur médiane élément-à-élément des segments



source : Rafii

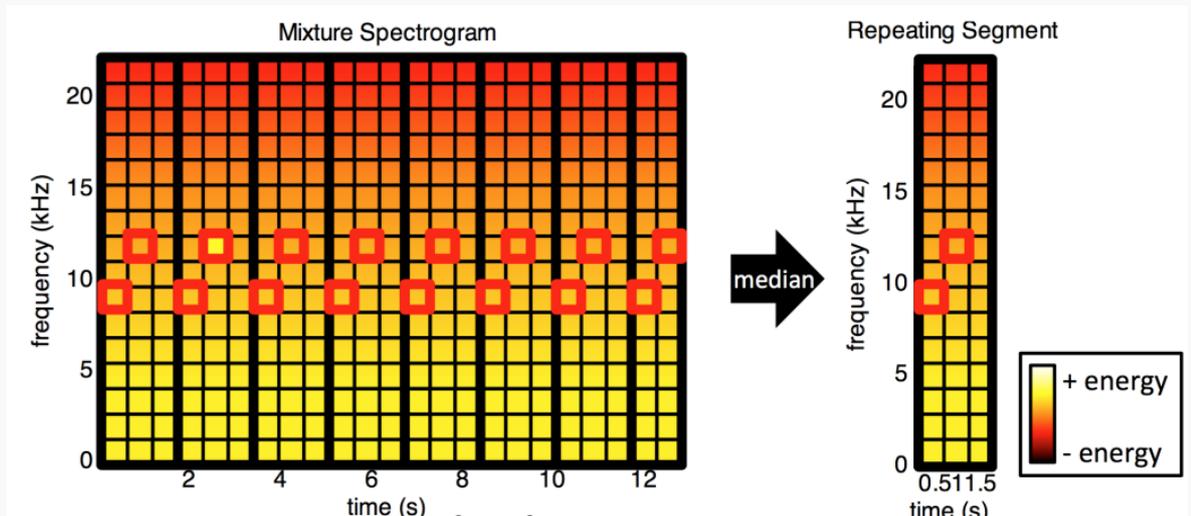
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 2. Segment répété

- La médiane aide à dériver un segment répété propre, en retirant les valeurs aberrantes non répétées
- Nous supposons que l'avant-plan est plus "sparse" et varié que l'arrière plan



source : Rafii

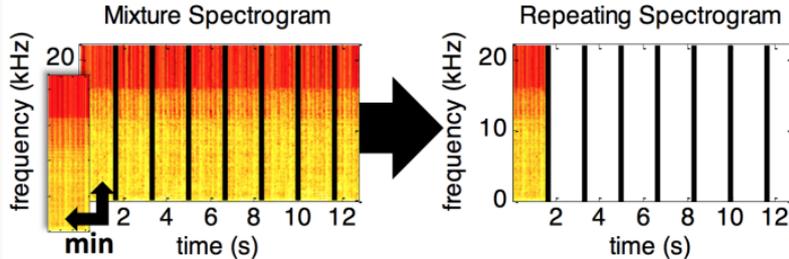
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

- **3. Structure répétée**

- On prend la valeur minimum élément-à-élément entre le segment répété et les segments



source : Rafii

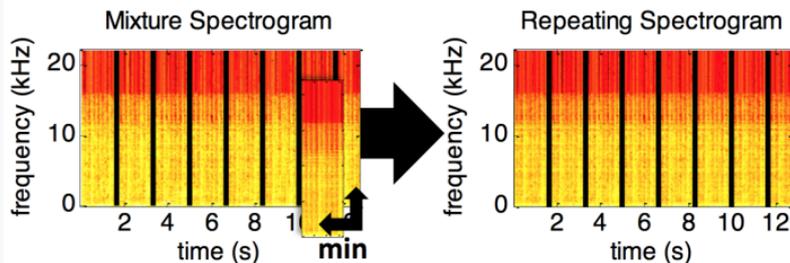
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

- **3. Structure répétée**

- On obtient le modèle du spectrogramme répété pour l'arrière-plan répété



source : Rafii

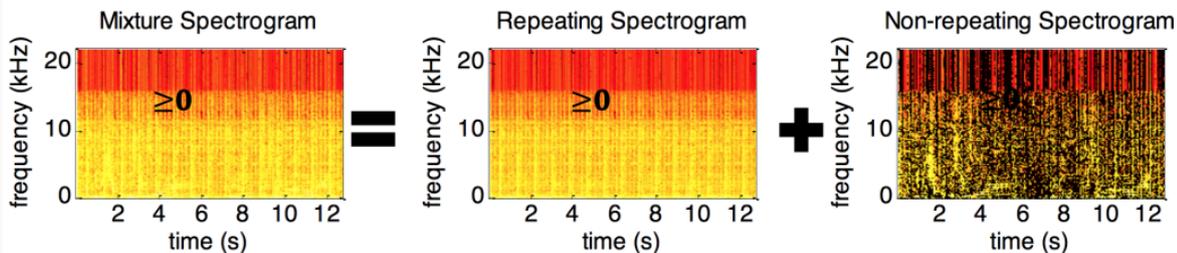
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 3. Structure répétée

- le spectrogramme répété ne peut avoir des valeurs plus grandes que le spectrogramme mélangé



source : Rafii

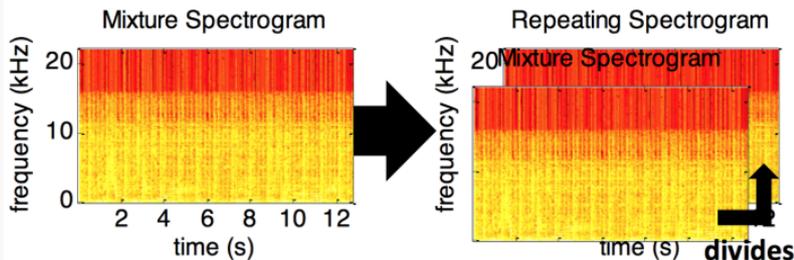
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

- **3. Structure répétée**

- On divise élément-à-élément le spectrogramme répété par le spectrogramme mélangé



source : Rafii

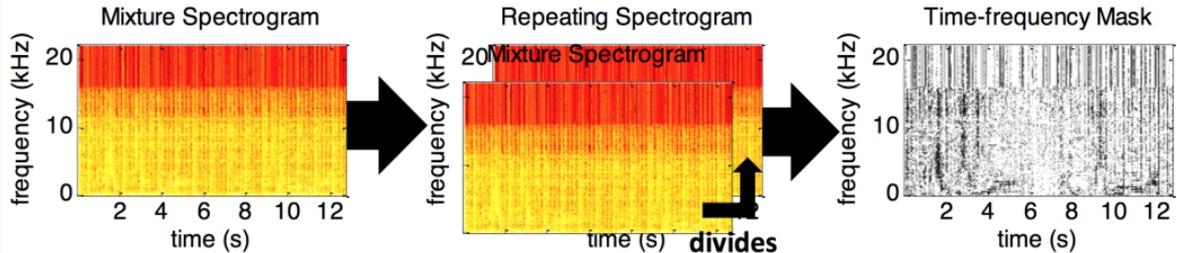
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 3. Structure répétée

- On obtient un "soft mask" (valeur dans $[0,1]$)



source : Rafii

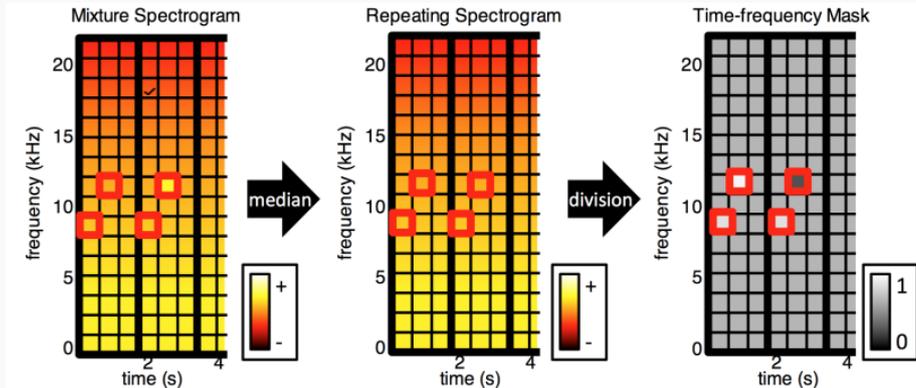
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 3. Structure répétée

- Dans le "soft mask",
 - au moins un bin T/F est répété au plus il tend vers 0
 - au plus un bin T/F est répété au plus il tend vers 1



source : Rafii

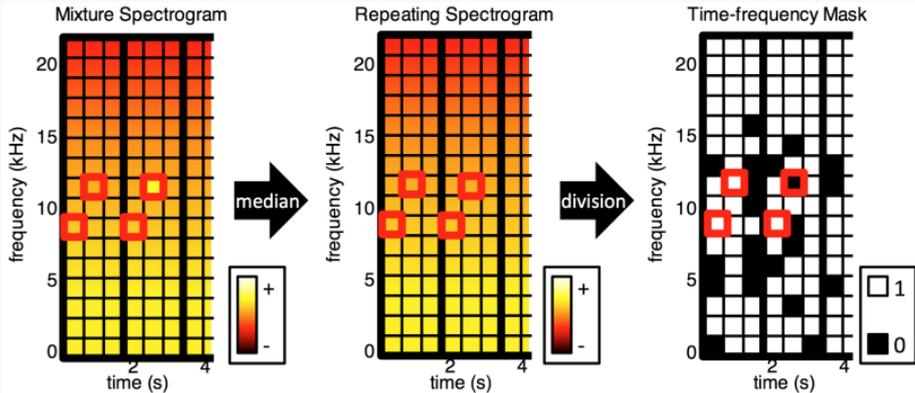
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 3. Structure répétée

- un "binary mask" peut également être dérivé en appliquant un seuil entre 0 et 1



source : Rafi

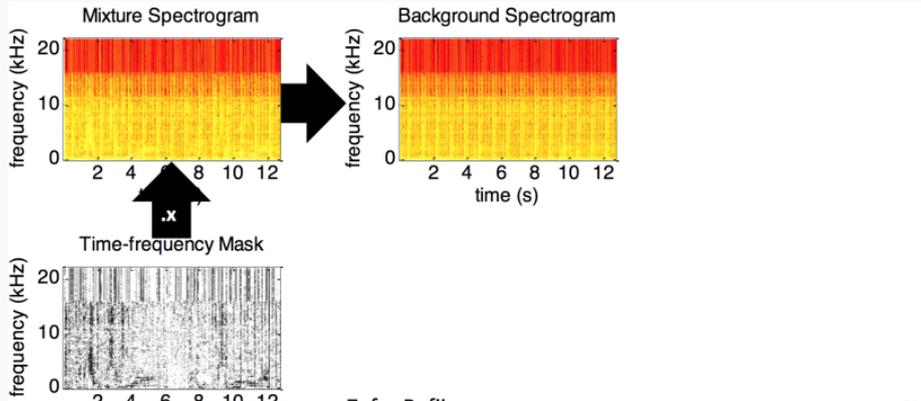
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 3. Structure répétée

- On multiplie le T/F mask avec la STFT du mélange pour extraire l'arrière-plan répété de la TFCT



source : Rafii

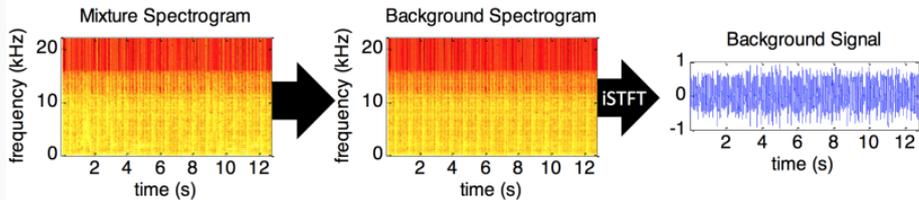
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

- **3. Structure répétée**

- L'accompagnement répété est obtenu en inversant la TFCT dans le domaine temporel



source : Rafii

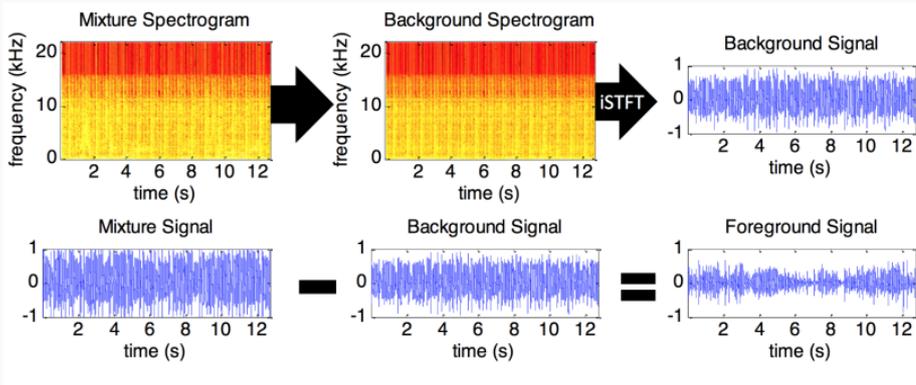
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 3. Structure répétée

- L'arrière-plan non répété est obtenu en soustrayant l'arrière-plan du mélange



source : Rafii

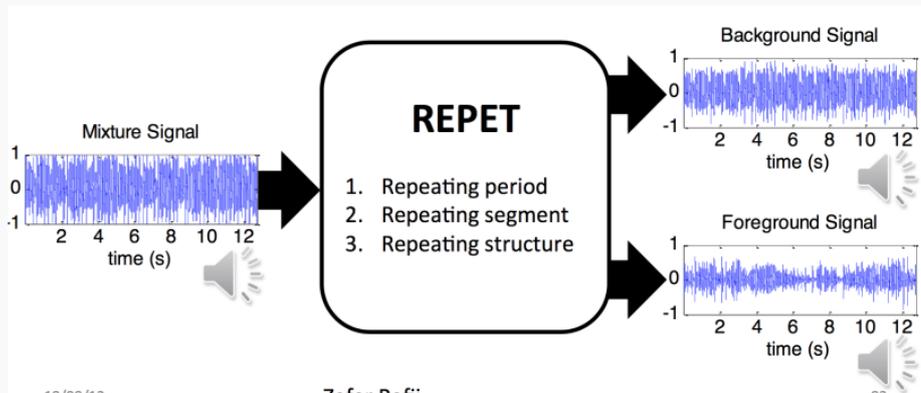
5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 1) Estimer globalement le tempo et les battements du morceau : REPET

• 3. Structure répétée

- Arrière-plan répété = accompagnement musical
- Avant-plan non-répété = voix



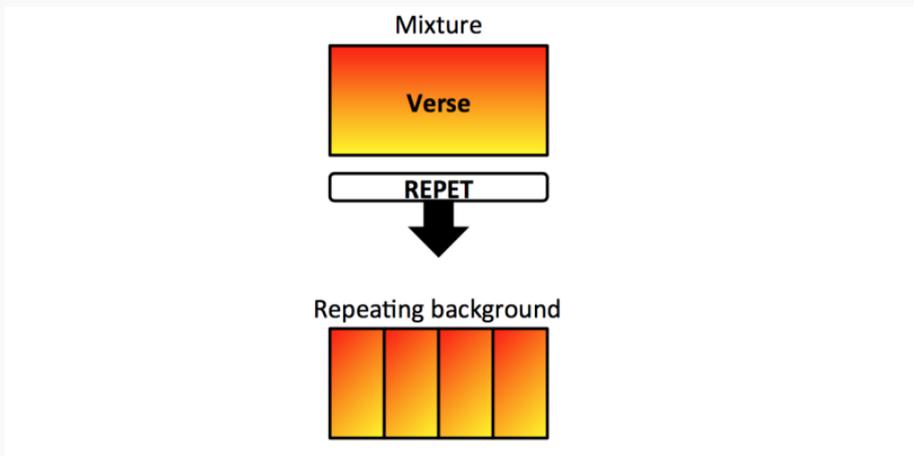
source : Rafii

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 2) Estimer localement le tempo et les battements du morceau : Adaptive REPET

- REPET fonctionne bien sur des extraits qui ont un arrière-plan relativement stable (10 s du couplet)



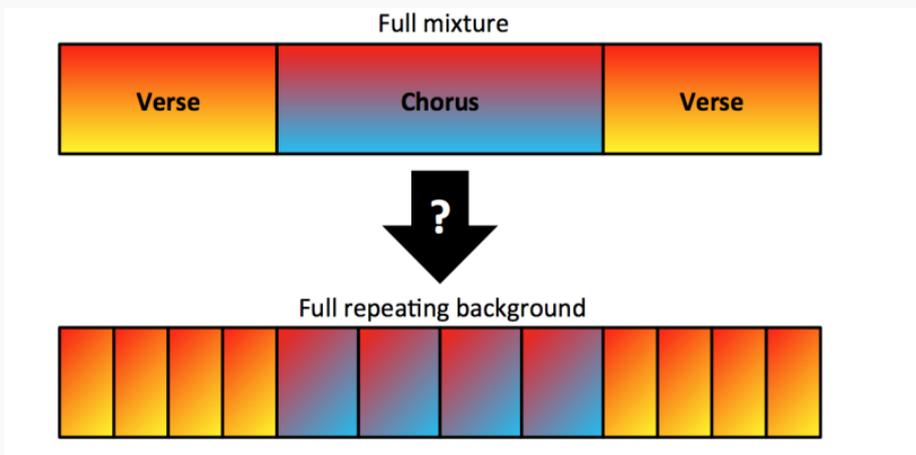
source : Rafii

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 2) Estimer localement le tempo et les battements du morceau : Adaptive REPET

- Pour des morceaux entiers, l'arrière-plan répété est susceptible de changer au cours du temps (couplet/ chorus)



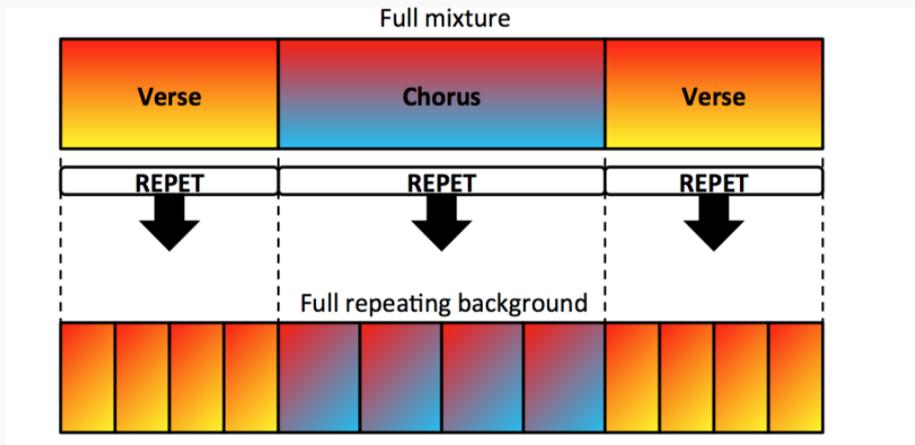
source : Rafii

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 2) Estimer localement le tempo et les battements du morceau : Adaptive REPET

- On pourrait appliquer une segmentation du morceau et appliquer REPET sur chaque segment individuel



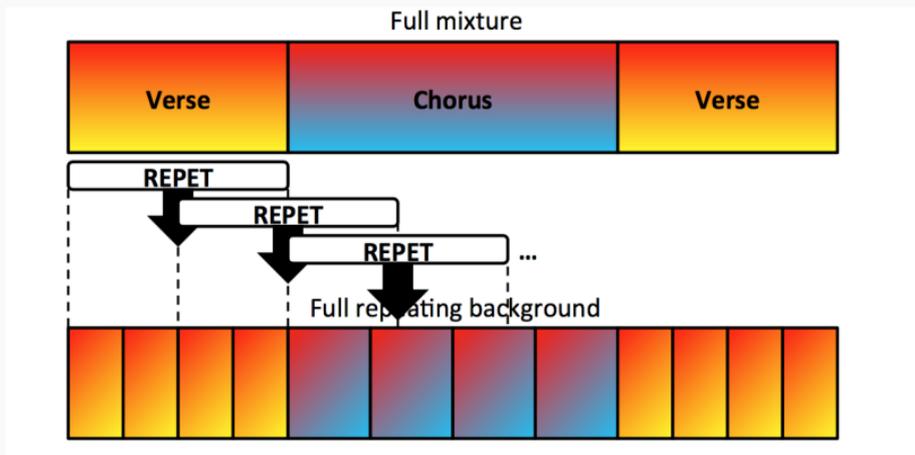
source : Rafii

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 2) Estimer localement le tempo et les battements du morceau : Adaptive REPET

- On pourrait appliquer REPET aux segments locaux du morceau par utilisation d'une fenêtre glissante



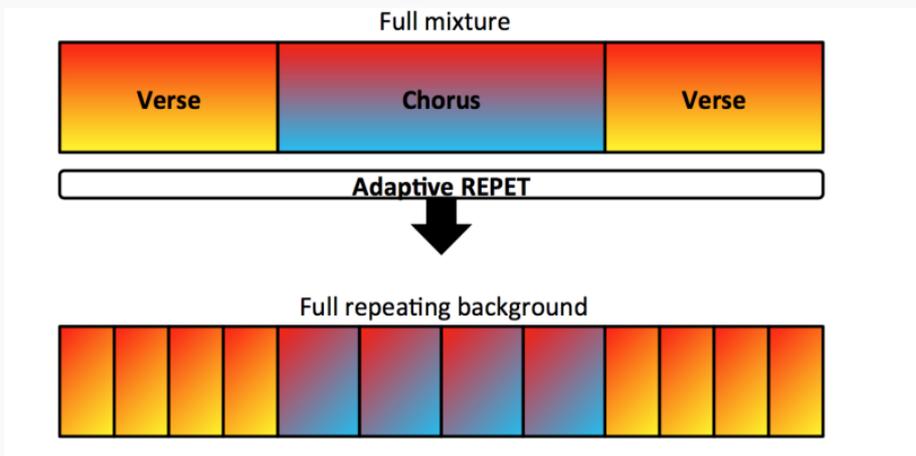
source : Rafii

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 2) Estimer localement le tempo et les battements du morceau : Adaptive REPET

- On pourrait adapter REPET au cours du temps en modélisant l'arrière plan répété

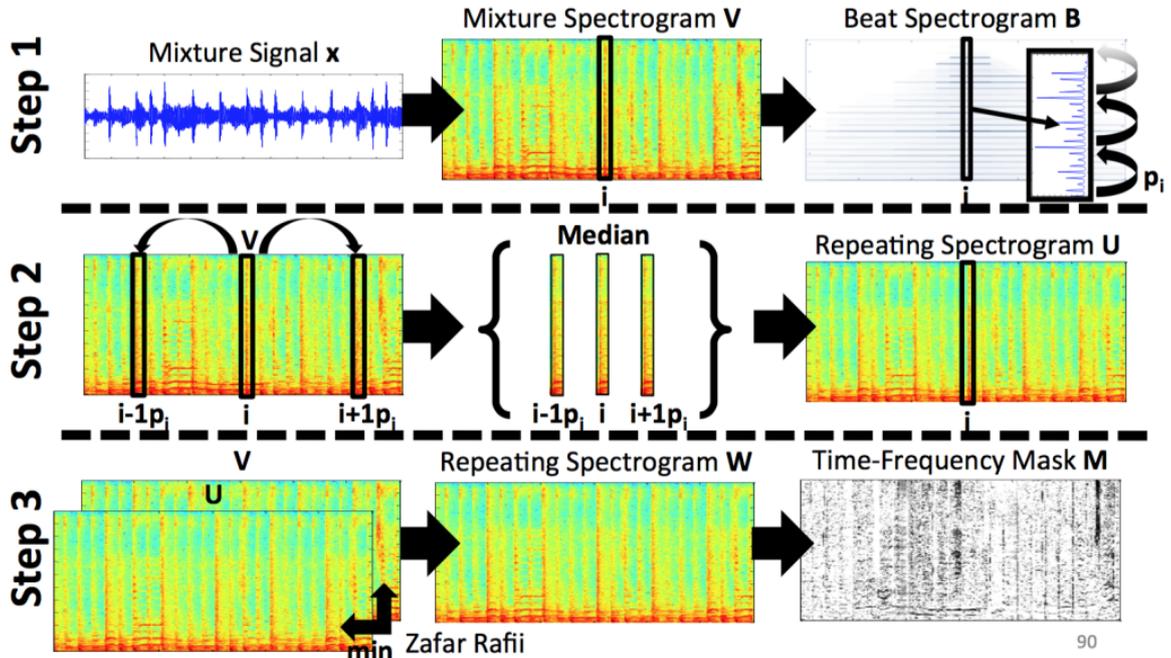


source : Rafi

5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

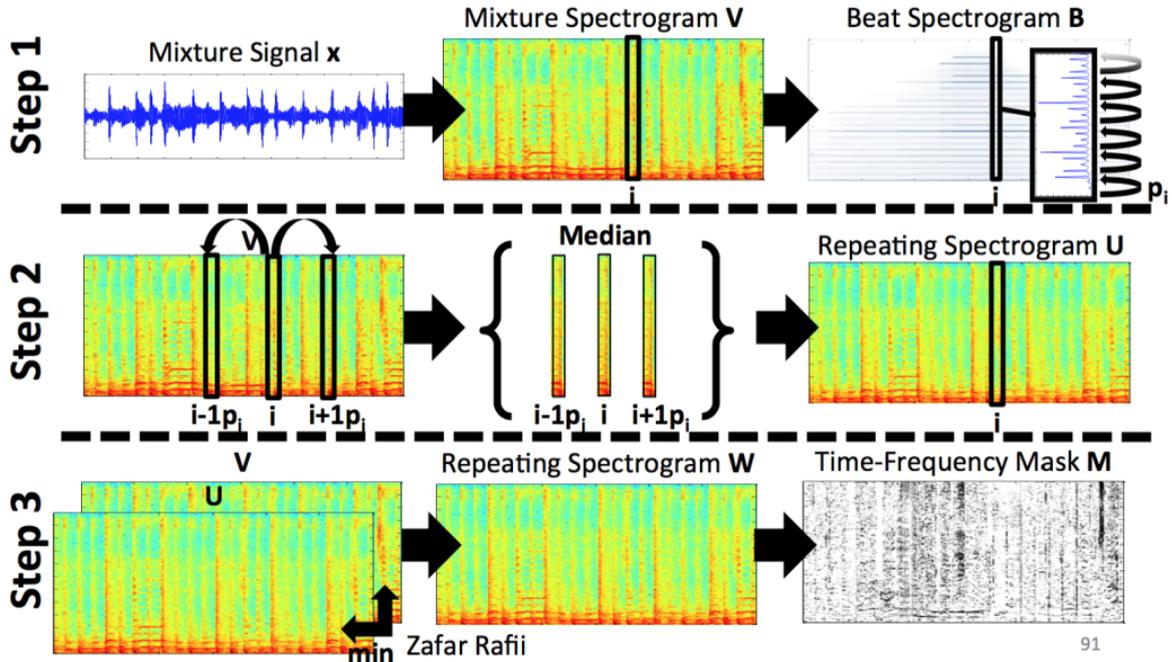
Comment identifier les répétitions ? 2) Estimer localement le tempo et les battements du morceau : Adaptive REPET



5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

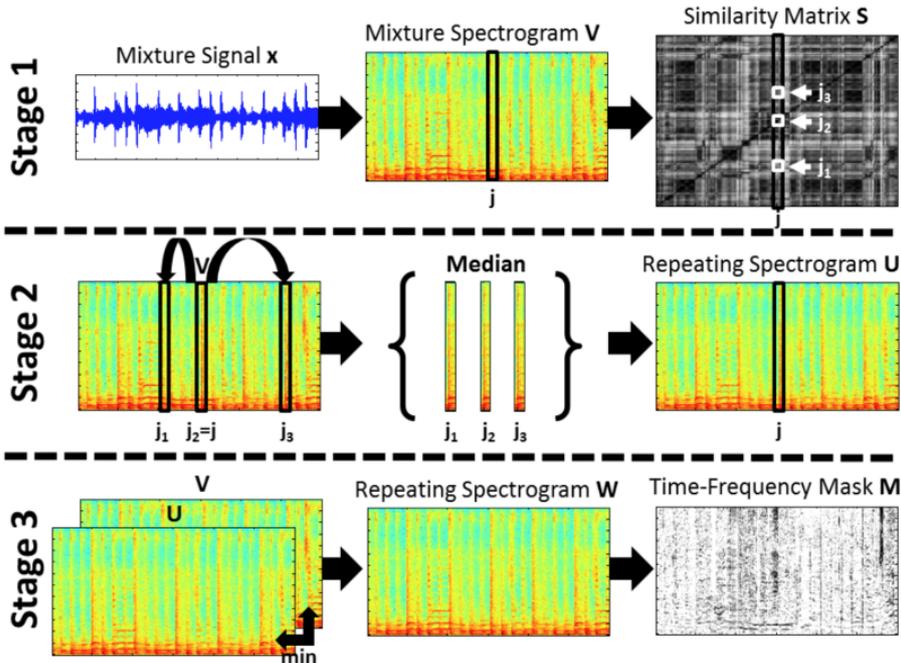
Comment identifier les répétitions ? 2) Estimer localement le tempo et les battements du morceau : Adaptive REPET



5- Séparation de sources

Séparation de source par décomposition en partie répétée (rang faible) / partie sparse

Comment identifier les répétitions ? 3) Estimer l'auto-similarité (matrice d'auto-similarité) du morceau : REPET-SIM



5- Séparation de sources

5.2- Factorisation (décomposition) en matrices non-négatives

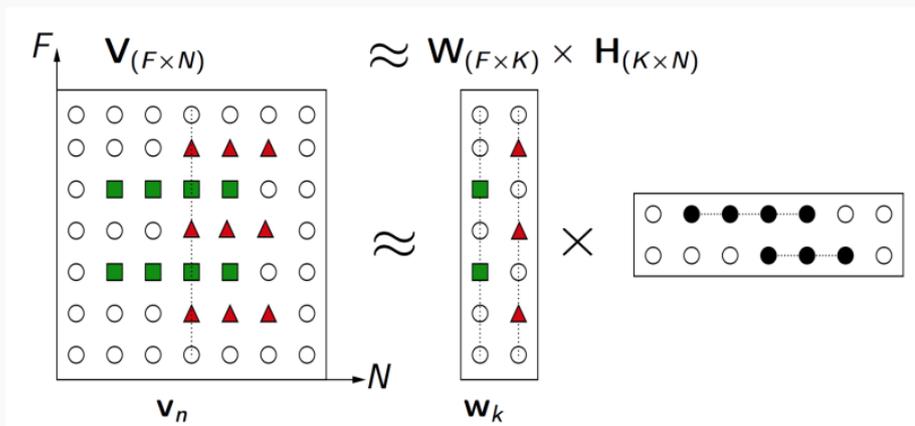
5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Introduction

[D. D. Lee and H. S. Seung. Learning the parts of objects by non-negative matrix factorization. Nature, 1999.]

- **NMF** : Non-Negative Matrix Factorization



source : Cédric Févotte

- $V_{(F,N)} \simeq W_{(F,K)} H_{(K,N)}$
 - $V_{(F,N)}$: matrice de **données**, observée (spectrogramme d'énergie), définie positive : $V_{fn} \geq 0$
 - $W_{(F,K)}$: matrice de **bases**, dictionnaires, définie positive : $W_{fk} \geq 0$
 - $H_{(K,N)}$: matrice d'**activation**, définie positive : $H_{fn} \geq 0$
 - K : le nombre de bases du dictionnaire

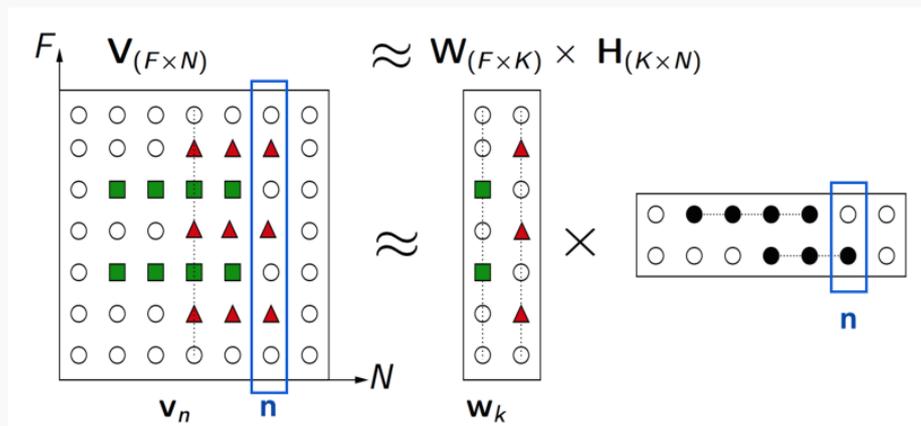
5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Introduction

- Chaque trame \mathbf{n} est reconstituée comme l'**activation** H d'un certain nombre de **bases** W

- $V_{(1:F,\mathbf{n})} \approx \sum_{k=1}^K W_{(1:F,k)} H_{(k,\mathbf{n})}$



source : Cédric Févotte

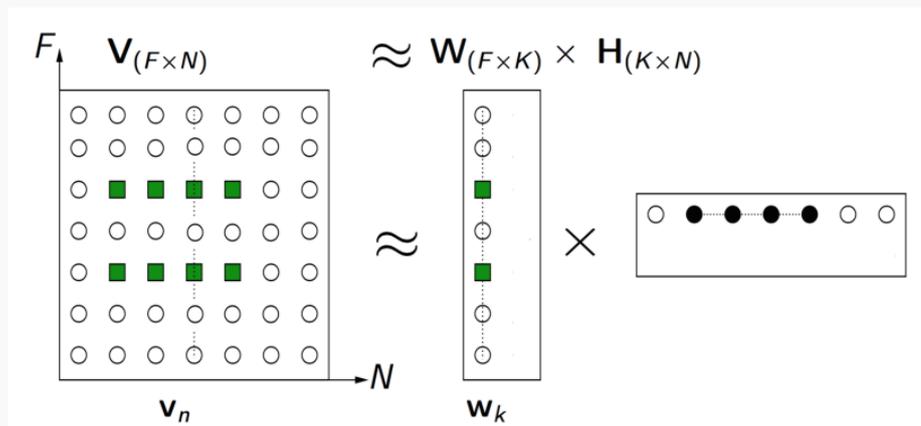
5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Introduction

- Le signal d'une **source** k est reconstitué comme

- $V_{(1:F,1:N)}^k = W_{(1:F,k=1)} H_{(k=1,1:N)}$



source : Cédric Févotte

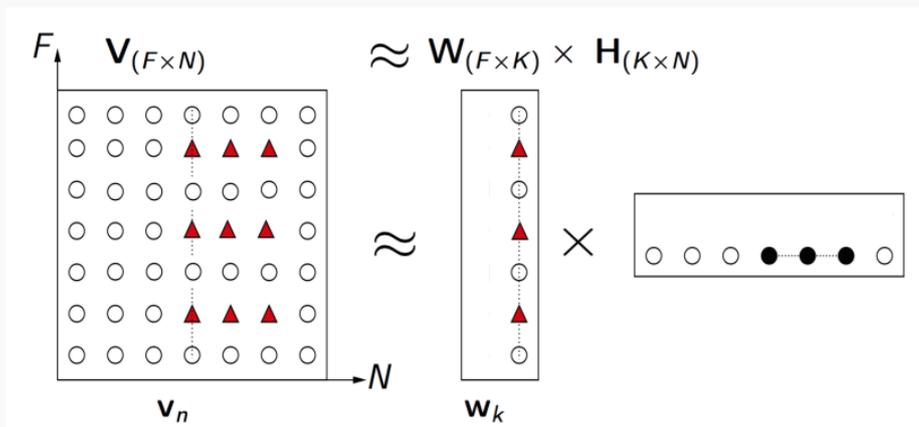
5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Introduction

- Le signal d'une **source** k est reconstitué comme

- $V_{(1:F,1:N)}^k = W_{(1:F,k=2)} H_{(k=2,1:N)}$



source : Cédric Févotte

5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Estimation des paramètres de la NMF

- $V_{(F,N)} \simeq W_{(F,K)} H_{(K,N)}$
- **Minimisation** de
 - $\min_{W, H \geq 0} D(\underline{V} | \underline{WH})$
 - $\min_{\theta} C(\theta) \stackrel{\text{def}}{=} D(\underline{V} | \underline{WH})$ avec $\theta = \{W, H\}$
- D/d est une **divergence séparable**
 - $D(\underline{V} | \hat{\underline{V}}) = \sum_{f=1}^F \sum_{n=1}^N d(v_{fn} | \hat{v}_{fn})$
- Choix de D/d :

- Distance Euclidienne :

$$d_{EUC}(x, y) = (x - y)^2$$

- Divergence de Kullback-Leibler :

$$d_{KL}(x, y) = x \log \frac{x}{y} - x + y$$

- Divergence d'Itakura-Saito :

$$d_{IS}(x, y) = \frac{x}{y} - \log \frac{x}{y} - 1$$

5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Dérivation du critère pour la distance Euclidienne

- Non Negative Matrix Factorization

$$\underset{(f,n)}{V} \simeq \underset{(f,k)}{W} \underset{(k,n)}{H}$$

- Erreur de reconstruction : $e = V - WH$
- Minimisation de la SSE (Sum of Squared Error) ou de la norme de Frobenius de $SSE = \|V - WH\|_F^2$
- Norme de Frobenius : $\|A\|_F = \sqrt{\sum_i \sum_j a_{ij}^2}$

5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Dérivation du critère pour la distance Euclidienne

$$SSE = \|V - WH\|_F^2$$

$$SSE = (V - WH)^T (V - WH)$$

$$= (V^T - H^T W^T)(V - WH)$$

$$= V^T V - V^T WH - H^T W^T V + H^T W^T WH$$

$$= V^T V - 2V^T WH + H^T W^T WH$$

$$\frac{\partial sse}{\partial H} = -2W^T V + 2W^T WH$$

$$= 2W^T (WH - V)$$

$$\frac{\partial sse}{\partial W} = -2VH^T + 2WHH^T$$

$$= -2(V - WH)H^T$$

Propriétés utilisées (Matrix Cookbook)

- $\frac{\partial a^T x}{\partial x} = a$
- $\frac{\partial a^T X b}{\partial X} = ab^T$
- $\frac{\partial x^T B x}{\partial x} = (B + B^T)x$
- $\frac{\partial b^T X^T X c}{\partial X} = X(bc^T + cb^T)$

5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Algorithme de descente de gradient

- Descente de gradient ?
 - déplacement dans la direction opposée au gradient, de manière à faire décroître la fonction

- Le gradient : $\frac{\partial sse}{\partial H} = \underbrace{2W^T WH}_{\nabla_+} - \underbrace{2W^T V}_{\nabla_-}$

- Mise à jour de H

$$H \leftarrow H + \eta \cdot [-\text{gradient}]$$

$$H \leftarrow H + \eta \cdot \left[\underbrace{W^T V}_{\nabla_-} - \underbrace{W^T WH}_{\nabla_+} \right]$$

- si on choisit $\eta = \frac{H}{W^T WH}$

$$H \leftarrow H + \frac{H}{W^T WH} (W^T V - W^T WH)$$

$$H \leftarrow H + \frac{HW^T V}{W^T WH} - H$$

$$H \leftarrow H \cdot \frac{\underbrace{W^T V}_{\nabla_-}}{\underbrace{W^T WH}_{\nabla_+}}$$

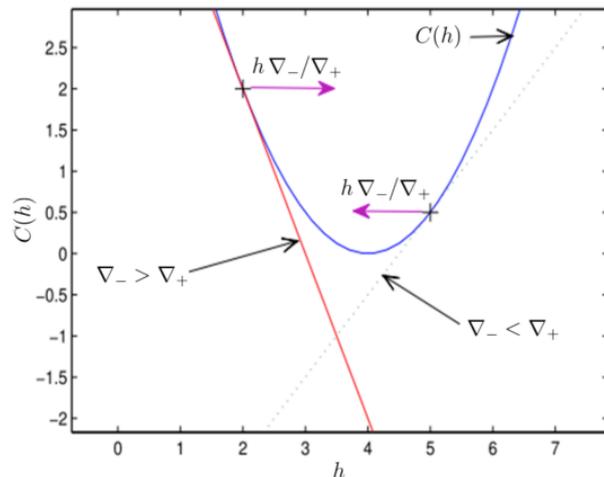
5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Mise à jour multiplicative

- permet de garantir que les valeurs restent positives !!!
- Séparation du gradient en contribution **positive** et **négative**

$$\nabla_h C(h) = \nabla_+ - \nabla_-$$



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Algorithme complet de NMF dans le cas Euclidéen : $V_{(f,n)} \simeq W_{(f,k)} H_{(k,n)}$

- Calcul de la TFCT : $V(f, n) = |X(f, n)|$
- Choix du nombre de bases K du dictionnaire W
- Initialisation de W et H : valeurs aléatoires positives
- Itérations
 - Mise à jour des bases W étant donné les activations H

$$W \leftarrow W \cdot \frac{VH^T}{WHH^T}$$

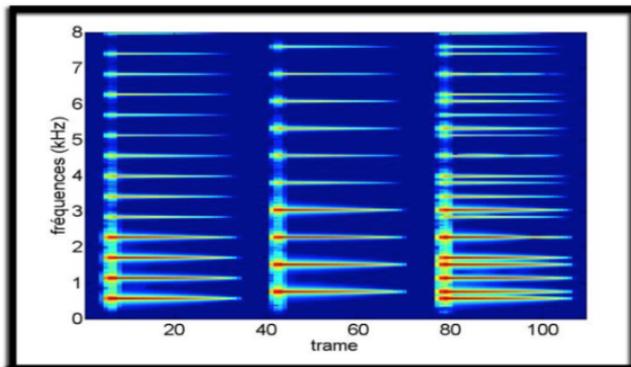
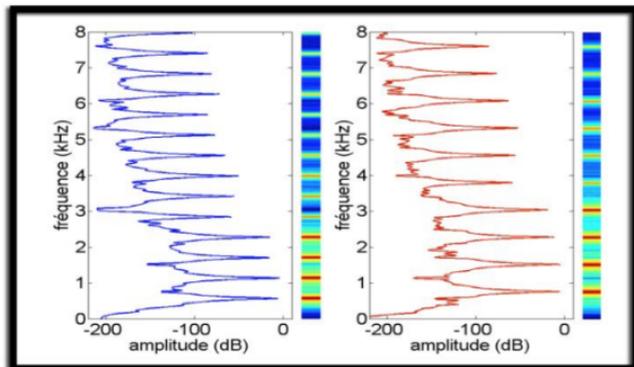
- Mise à jour des activations H étant donné les bases W

$$H \leftarrow H \cdot \frac{W^T V}{W^T W}$$

- Prise en compte de l'invariance d'échelle
 - normalisations des colonnes de H
 - OU
 - normalisation des lignes de W
- Arrêt lorsque la SSE cesse de décroître

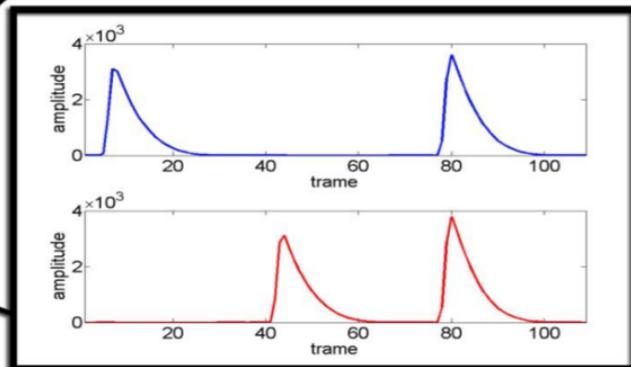
5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives



$$WH \approx V$$

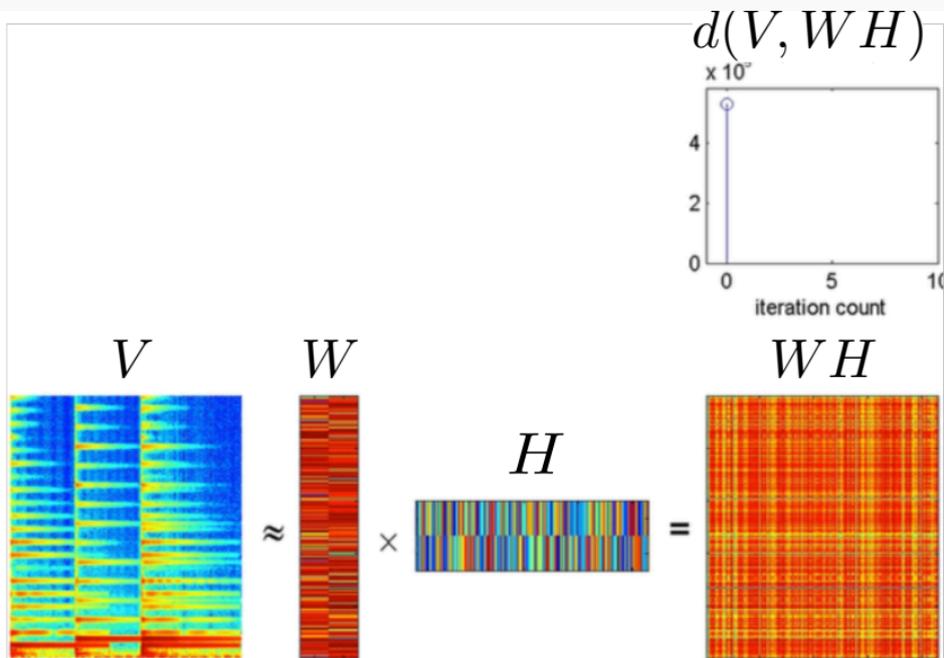
Image d'après R. Hennequin



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Initialisation

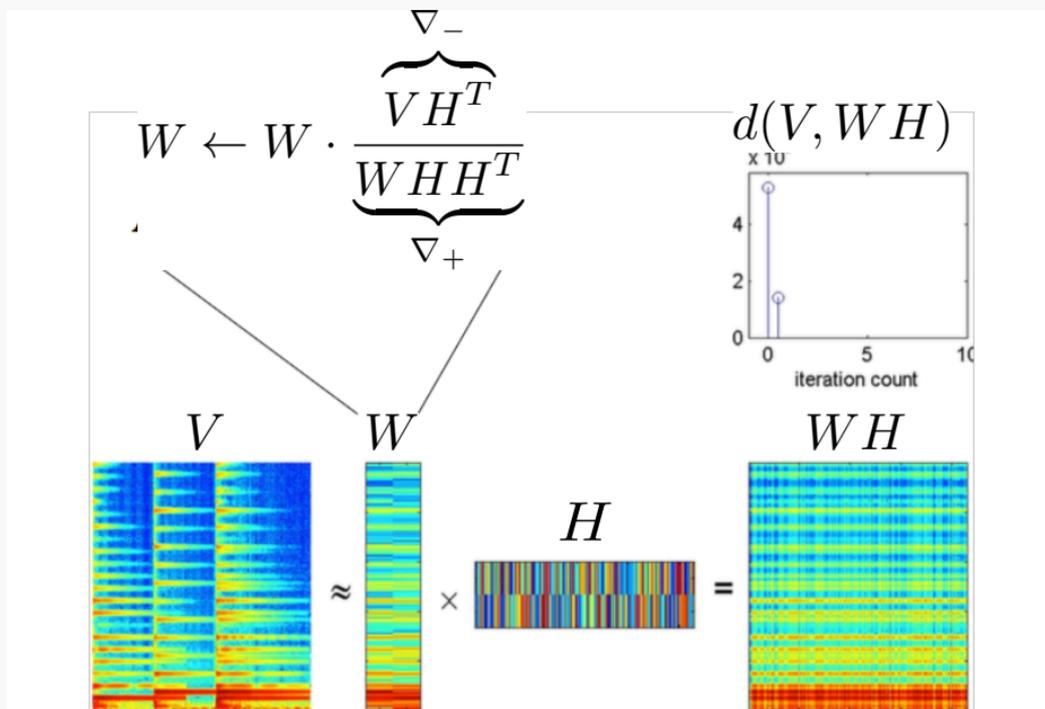


source : Tuomas Virtanen

5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

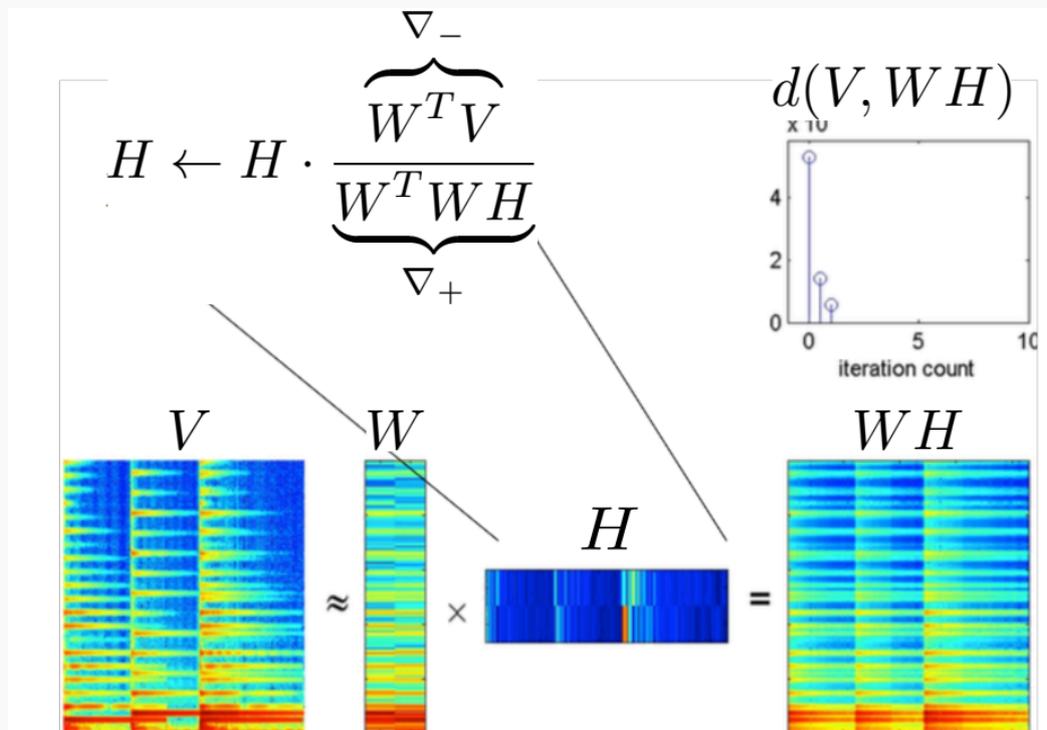
Iteration 1 : Mise à jour de W



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

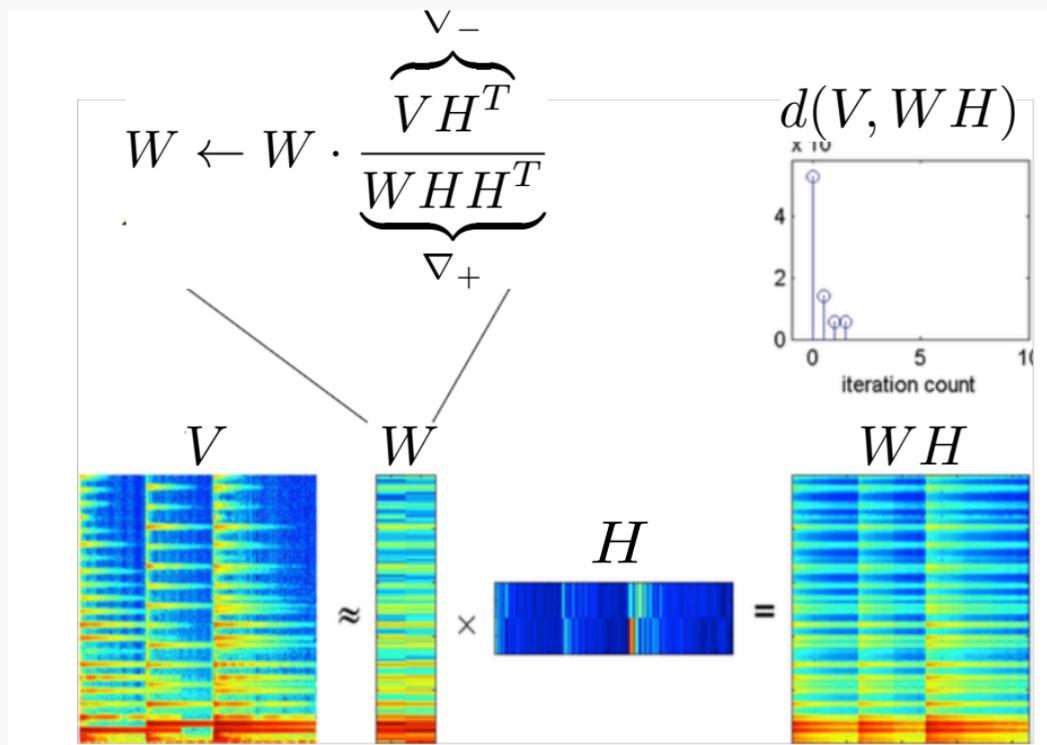
Iteration 1 : Mise à jour de H



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

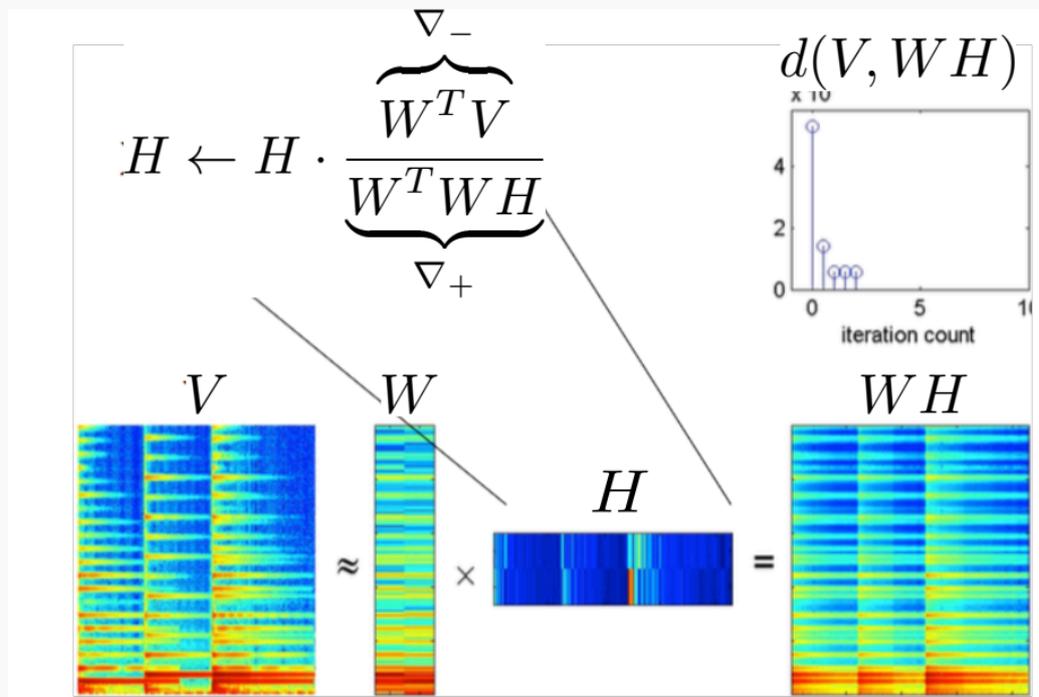
Iteration 2 : Mise à jour de W



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Iteration 2 : Mise à jour de H

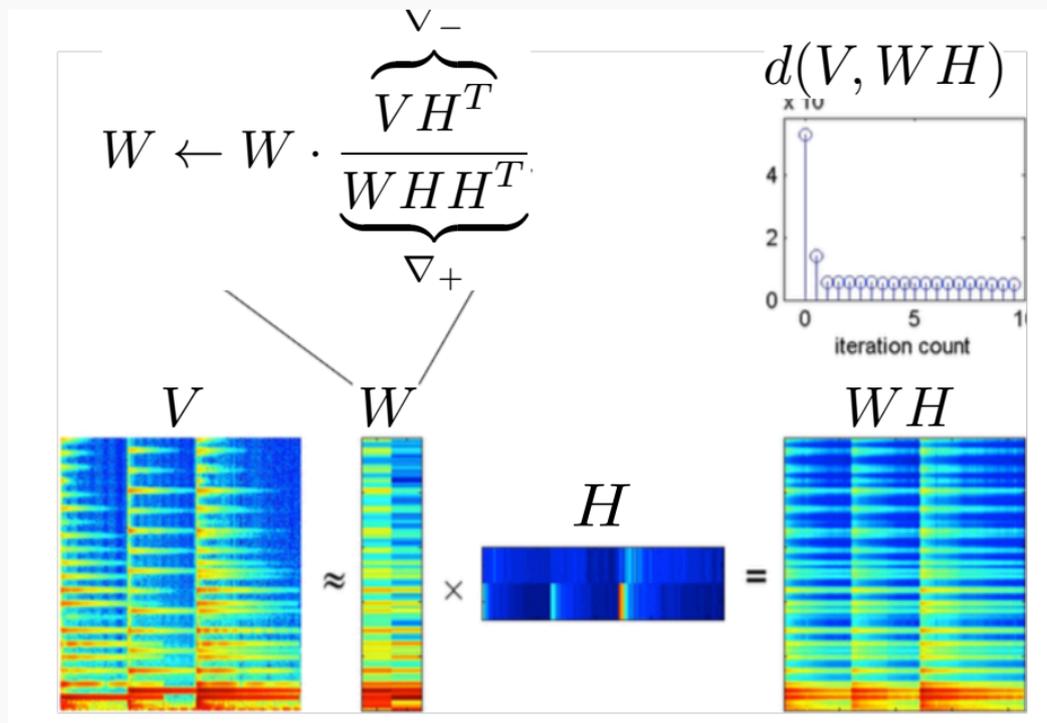


source : Tuomas Virtanen

5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

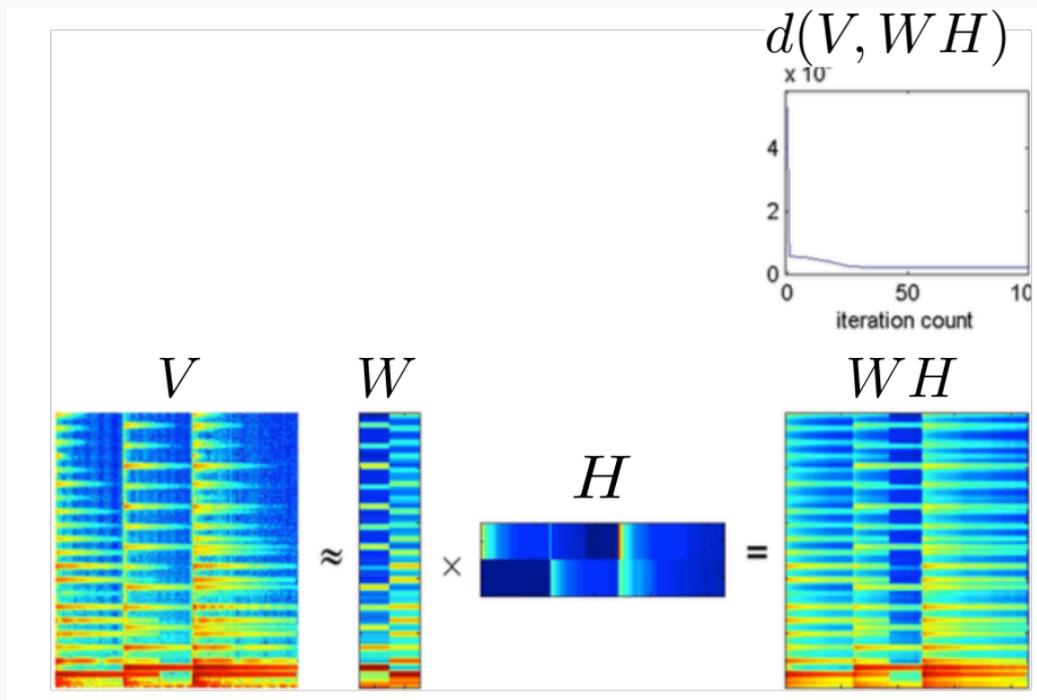
Iteration 10 : Mise à jour de W



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Iteration 100

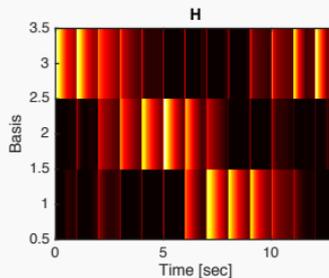
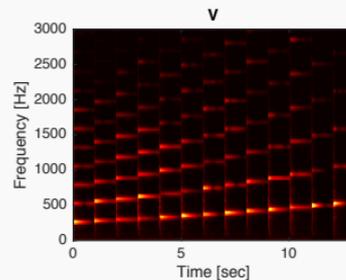
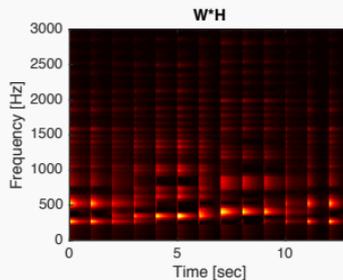
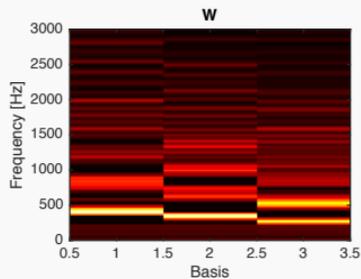


source : Tuomas Virtanen

5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

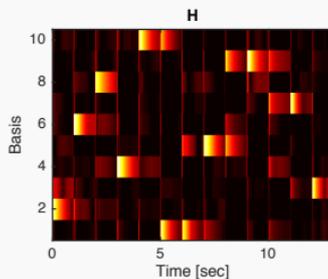
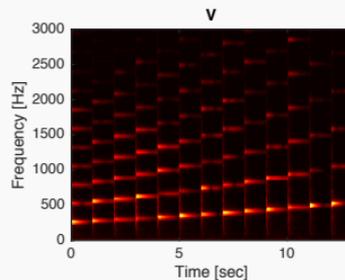
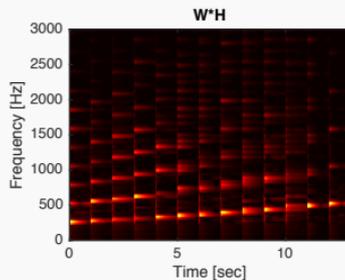
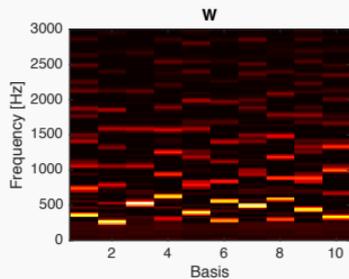
Choix du nombre de bases $K = 3$ (trop faible)



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

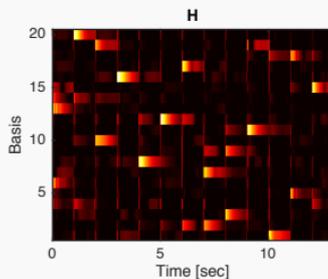
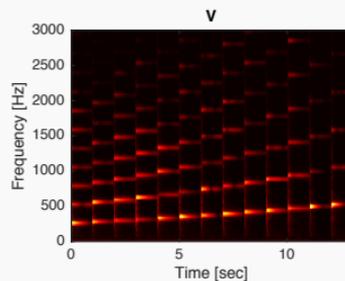
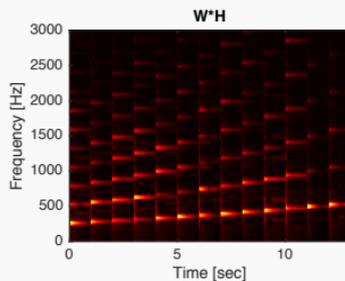
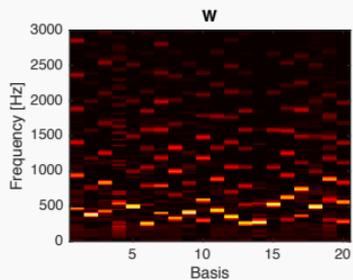
Choix du nombre de bases $K = 10$ (correcte)



5- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Choix du nombre de bases $K = 20$ (trop grand)



6- Transformation du signal

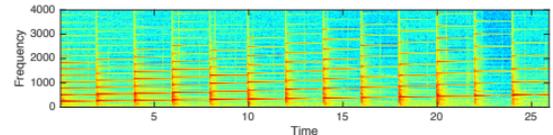
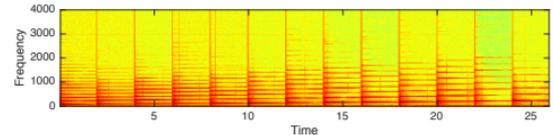
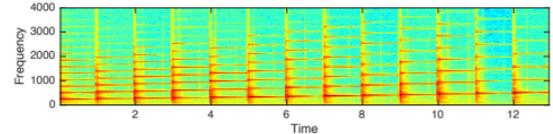
6.1- Application : dilatation/ contraction du temps par vocodeur de phase

6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Technique de DJ pour changer le tempo

- Ralentir/accélérer la vitesse de lecture (du vinyl, de la bande magnétique)
- $x(\alpha t) \Leftrightarrow \frac{1}{\alpha} X\left(\frac{f}{|\alpha|}\right)$
- Ralentir le temps : $\alpha < 1$
 - mais contracte aussi les fréquences (on abaisse les hauteurs)
- Accélérer le temps : $\alpha > 1$
 - mais étend aussi les fréquences (on augmente les hauteurs)



[haut] : signal original, [milieu] $\alpha < 1$ par ré-échantillonnage, [bas] : $\alpha < 1$ par vocodeur de phase

Objectif

- Changer le temps et les hauteurs de manière **indépendante**

6- Transformation du signal

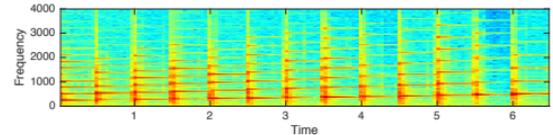
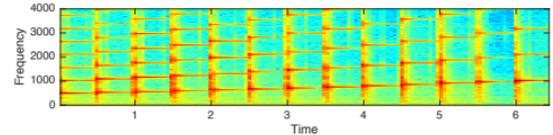
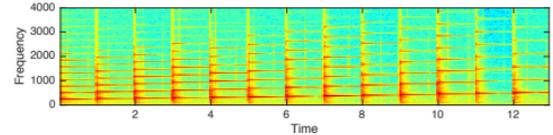
Application : dilatation/ contraction du temps par vocodeur de phase

Technique de DJ pour changer le tempo

- Ralentir/accélérer la vitesse de lecture (du vinyl, de la bande magnétique)
- $x(\alpha t) \Leftrightarrow \frac{1}{\alpha} X\left(\frac{f}{|\alpha|}\right)$
- Ralentir le temps : $\alpha < 1$
 - mais contracte aussi les fréquences (on abaisse les hauteurs)
- Accélérer le temps : $\alpha > 1$
 - mais étend aussi les fréquences (on augmente les hauteurs)

Objectif

- Changer le temps et les hauteurs de manière **indépendante**



[haut] : signal original, [milieu] $\alpha > 1$ par ré-échantillonnage, [bas] : $\alpha > 1$ par vocodeur de phase

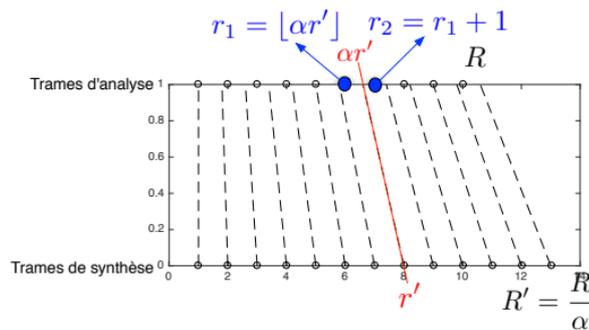
6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

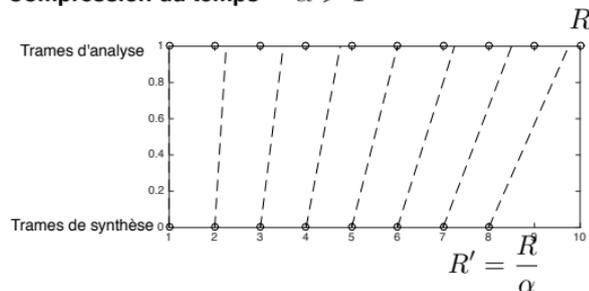
Le vocodeur de phase

- **Méthode pour rallonger/raccourcir le signal :**
 - changer le nombre de trames utilisées pour la resynthèse par TFCT^{-1}
- Soit R :
 - le nombre de trames d'**analyse** de la TFCT
- Soit $R' = \frac{R}{\alpha}$:
 - le nombre de trames de **synthèse** (utilisées pour la resynthèse par TFCT^{-1})
- $\alpha < 1 \rightarrow$ on dilate (ralentit) le temps
- $\alpha > 1 \rightarrow$ on comprime (accélère) le temps
- Le contenu d'une trame de synthèse $r' \in [1, R' = \frac{R}{\alpha}]$ est obtenu en recherchant les trames d'analyse r correspondantes les plus proches
 - $r_1 = \lfloor \alpha r' \rfloor$ et
 - $r_2 = r_1 + 1$

Dilatation du temps $\alpha < 1$



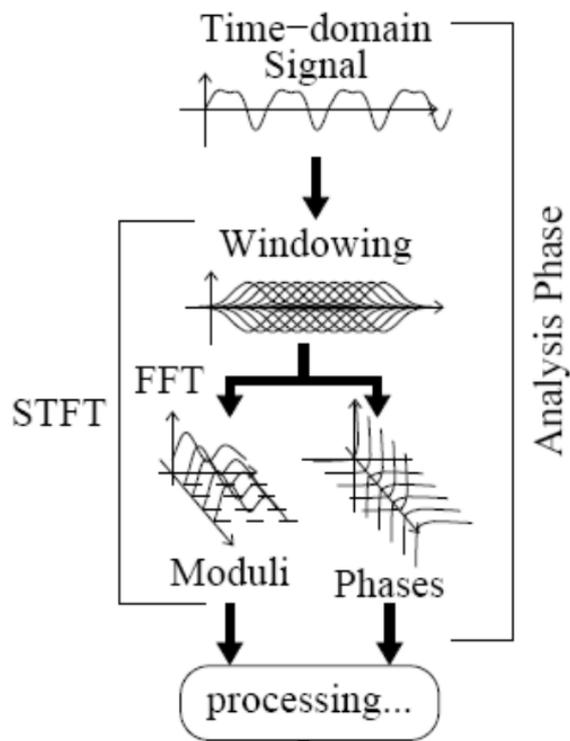
Compression du temps $\alpha > 1$



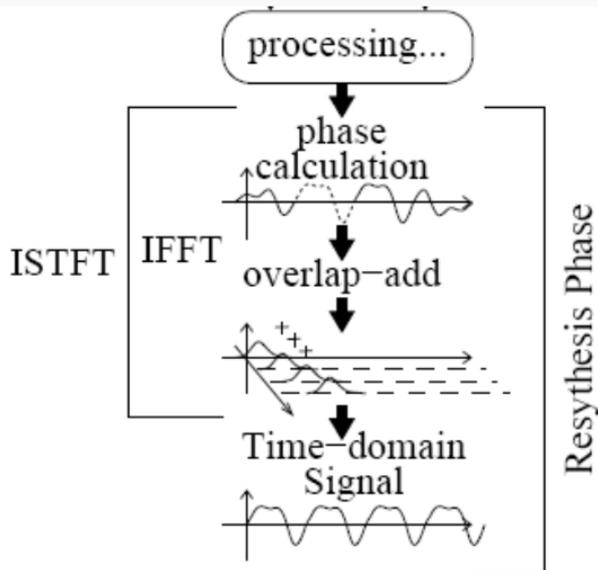
6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Le vocoder de phase : analyse



Le vocoder de phase : synthèse



6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Le vocodeur de phase

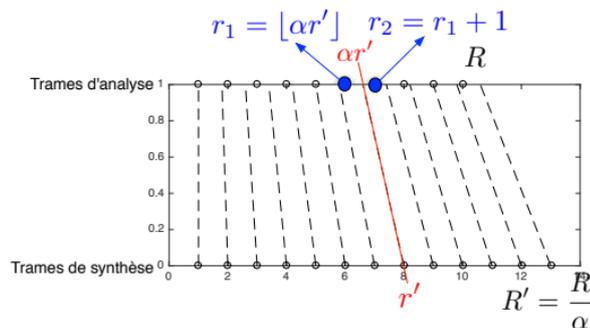
1) Spectre d'amplitude

- Le spectre d'amplitude à la trame r' , est obtenu par interpolation linéaire des spectres d'amplitude en r_1 et $r_2 = r_1 + 1$:
- $A(k, r') = (1 - \Delta)A(k, r_1) + \Delta A(k, r_2)$
- avec $\Delta = \alpha r' - r_1$

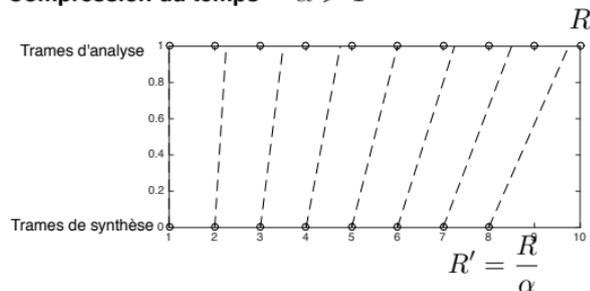
2) Spectre de phase

- c'est plus compliqué !!!**

Dilatation du temps $\alpha < 1$



Compression du temps $\alpha > 1$

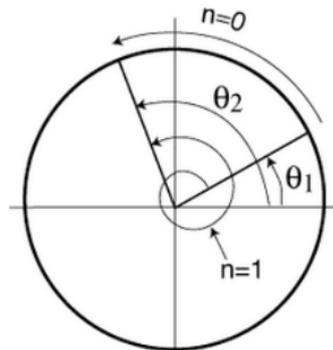
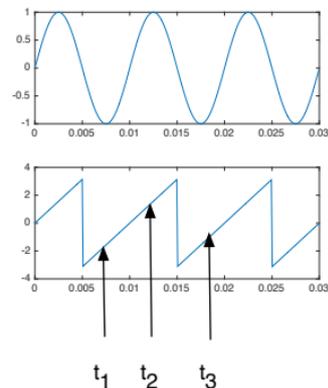


6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

La phase et la fréquence instantanée

- Considérons un signal formé d'une sinusoïde à la fréquence f_0 :
 - $x(t) = \sin(2\pi f_0 t) = \sin(\phi(t))$
- Entre les instants t_1 et t_2 , sa phase a "tourné" de $\phi(t_1)$ à $\phi(t_2)$
- Puisqu'il s'agit d'une sinusoïde pure, elle a tourné de
 - $\phi(t_2) = \phi(t_1) + 2\pi f_0(t_2 - t_1)$
- On peut donc estimer f_0 à partir de la différence de phase
 - $f_0 = \frac{\phi(t_2) - \phi(t_1)}{2\pi(t_2 - t_1)}$
- **Problème** :
 - la phase est uniquement définie dans l'intervalle $[-\pi, \pi]$
 - $\phi(t) \in [-\pi, \pi]$
 - donc en pratique le $\hat{\phi}(t_2)$ qu'on observe n'est pas $\phi(t_2)$ mais
 - $\hat{\phi}(t_2) = \phi(t_2) + n2\pi = \phi(t_1) + 2\pi f_0(t_2 - t_1) + n2\pi$
 - avec $n \in \mathbb{N}$ indéterminé
 - pour estimer f_0 il faut donc déterminer n
 - $f_0 = \frac{\phi(t_2) + n2\pi - \phi(t_1)}{2\pi(t_2 - t_1)}$

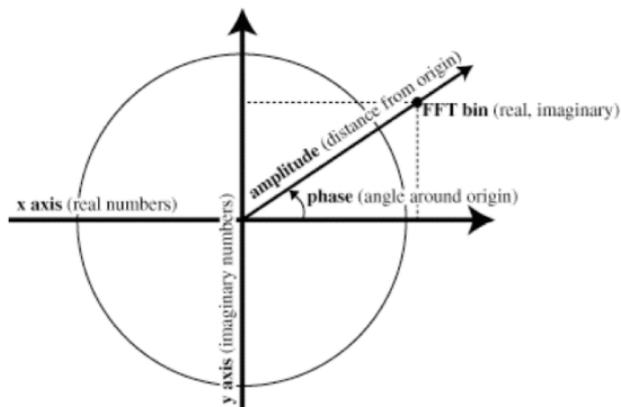


6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Phase dans le Transformée de Fourier à Court Term (TFCT)

- Pour chaque trame n et fréquence k la TFCT est un nombre complexe
 - $X(k, n) = \sum_m x(m)w(n-m)e^{-j2\pi\frac{k}{N}m}$
- Il peut se décomposer en amplitude (module) et phase :
 - $X(k, n) = A(k, n)e^{j\phi(k, n)}$



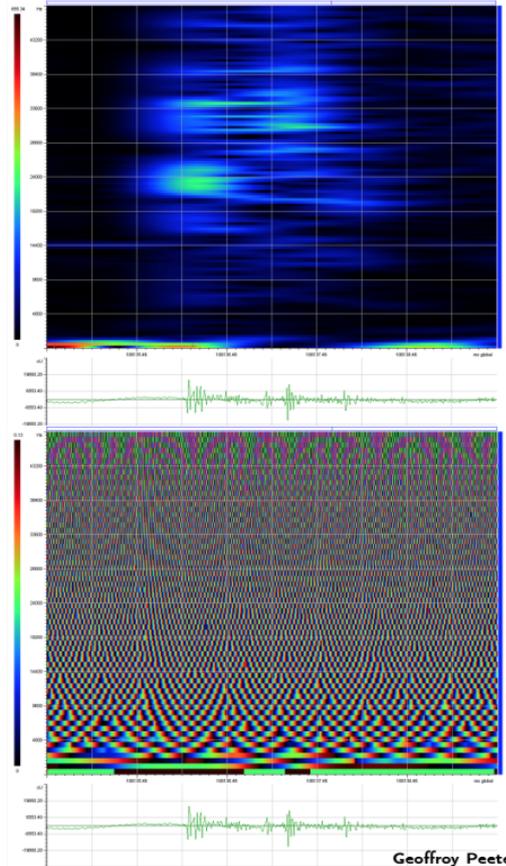
FFT Cartesian to Polar Conversion

6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Phase dans le Transformée de Fourier à Court Term (TFCT)

- On a donc une valeur d'amplitude et de phase pour chaque (k, n)
- Spectrogramme
 - d'amplitude $A(k, n)$
 - de phase $\phi(k, n)$
- La phase indique la position de la cosinusoïde,
- La variation temporelle de phase indique la fréquence instantanée
 - On peut donc calculer une fréquence instantanée pour chaque fréquence k et chaque couple de trames successives $(n - 1) \rightarrow n$.



6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Le vocodeur de phase

2) Spectre de phase

- A la trame r' le spectre de phase dans le filtre k de la TFCT est obtenu en propageant la phase à partir de la fréquence contenu dans ce filtre

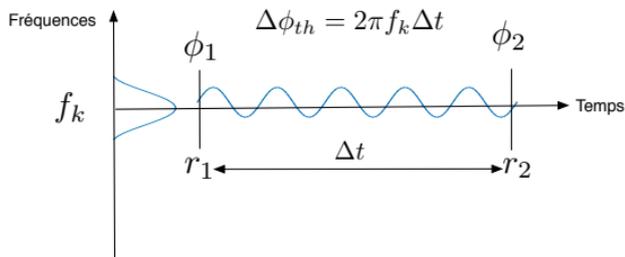
• 1) Solution **simplifiée** :

- On suppose qu'à travers le filtre k de la TFCT on peut observer uniquement une sinusoïde à la fréquence f_k
- On propage l'évolution de la phase au cours du temps en utilisant la prédiction théorique de la phase : $\Delta\phi_{th} = 2\pi f_k \Delta t$
- Donc

$$\begin{aligned}\phi(k, r') &= \phi(k, r' - 1) + \Delta\phi_{th} \\ &= \phi(k, r' - 1) + 2\pi f_k \Delta t\end{aligned}$$

- avec comme phase **initiale** :

$$\phi(k, r' = 1) = \phi(k, r = 1)$$



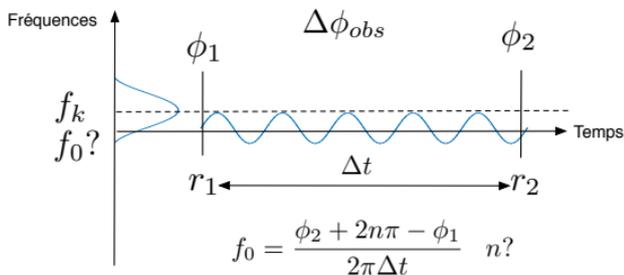
6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Le vocodeur de phase

2) Spectre de phase

- 2) Solution **correcte** :
 - En pratique, à travers le filtre k de la TFCT, on peut observer des sinusoides à des fréquences proches mais différentes de f_k
 - ceci est dû à la largeur du lobe principale, aux lobes secondaires
 - Il faut **estimer cette fréquence f_0** que l'on observe à travers le filtre f_k pour ensuite appliquer la propagation de phase
 - $\phi(k, r') = \phi(k, r' - 1) + 2\pi f_0 \Delta t$



6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Le vocodeur de phase : spectre de phase

- **Estimer cette fréquence f_0 ?**

- En utilisant la **fréquence instantanée** :

- $f_0(n) = \frac{\phi_2 + n2\pi - \phi_1}{2\pi\Delta t}$

- **Déterminer n ?**

- on cherche n tel que $f_0 \simeq f_k$

$$n \text{ tel que } \min_n |f_0 - f_k|$$

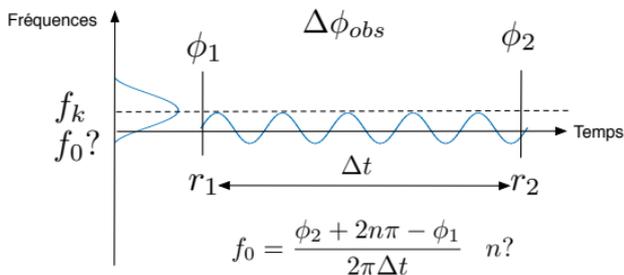
$$\min_n \left| \frac{\phi_2 + n2\pi - \phi_1}{2\pi\Delta t} - f_k \right|$$

$$\min_n |\phi_2 + n2\pi - \phi_1 - 2\pi\Delta t f_k|$$

$$\min_n |\phi_2 + n2\pi - \phi_1 - \Delta\phi_{th}|$$

- ce qui revient à

- trouver la détermination principale (la valeur dans l'intervalle $[-\pi, \pi]$) de
 - $n = [(\phi_2 - \phi_1 - \Delta\phi_{th}) / (2\pi)]$
- il s'agit de la différence de phase non-expliquée par le modèle théorique $\Delta\phi_{th}$



6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Le vocodeur de phase : spectre de phase

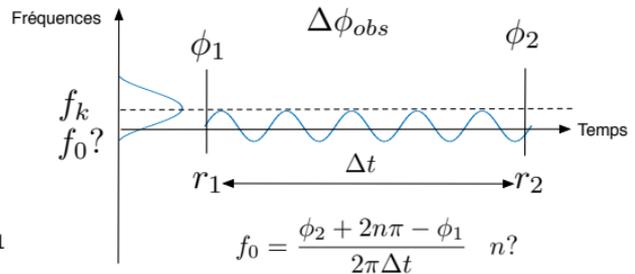
- 2) Solution **correcte** :

- Finalement la phase est incrémentée de

$$\begin{aligned}\phi(k, r') &= \phi(k, r' - 1) + 2\pi f_0 \Delta t \\ &= \phi(k, r' - 1) + \phi_2 + n2\pi - \phi_1\end{aligned}$$

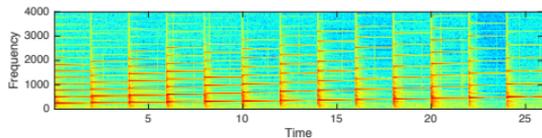
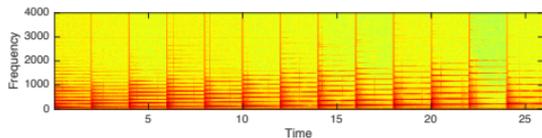
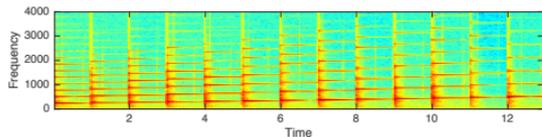
- avec comme phase **initiale** :

$$\phi(k, r' = 1) = \phi(k, r = 1)$$

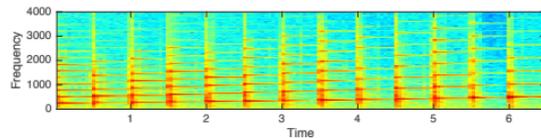
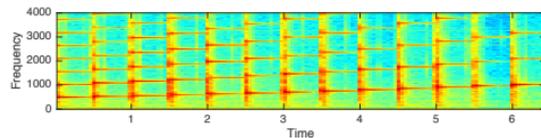
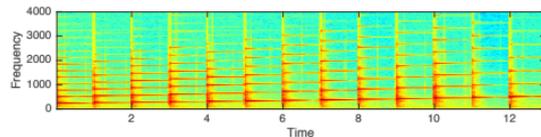


6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase



[haut] : signal original, [milieu] $a < 1$ par ré-échantillonnage, [bas] : $a > 1$ par vocodeur de phase



[haut] : signal original, [milieu] $a > 1$ par ré-échantillonnage, [bas] : $a < 1$ par vocodeur de phase

6- Transformation du signal

Application : dilatation/ contraction du temps par vocodeur de phase

Changement de hauteur

- Ré-échantillonnage du signal pour correction de la longueur par phase-vocoder

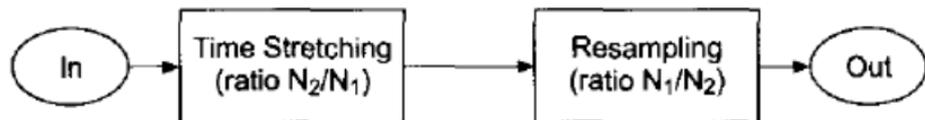


Figure 8.24 Resampling of a time stretching algorithm.