

ENSEA 3ème SyM (2017-2018)
Traitement du signal audio musical
Partie 1: transformation et séparation du son

Geoffroy.Peeters@ircam.fr
UMR SMTS 9912 (IRCAM CNRS UPMC)

1. Théorie : Traitement du signal fréquentiel
 - 1.1 Transformée de Fourier (temps et fréquences continus)
 - 1.2 Transformée de Fourier (temps et fréquences discrets)
 - 1.3 Transformée de Fourier (à Court Terme) : TFCT
 - 1.4 Transformée à Q-Constant (CQT)
 - 1.5 Deux interprétations de la TFCT
 - 1.6 Reconstruction du signal par addition/ recouvrement (TFTC inverse)
 - 1.7 Application : filtrage constant au cours du temps
 - 1.8 Application : débruitage par soustraction spectrale
 - 1.9 Application : dilatation/ contraction du temps par vocodeur de phase
2. Séparation de sources
 - 2.1 Séparation de la partie harmonique et percussive d'un morceau de musique
 - 2.2 Factorisation (décomposition) en matrices non-négatives

1- Théorie : Traitement du signal fréquentiel


1- Théorie : Traitement du signal fréquentiel

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



$\sin(2 \pi f t)$



1- Théorie : Traitement du signal fréquentiel

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 $X^*(f)$

1- Théorie : Traitement du signal fréquentiel

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** : $f_{Nyquist} = \frac{sr}{2} > f_{\max}$

1- Théorie : Traitement du signal fréquentiel

Transformée de Fourier (temps et fréquences discrets)

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

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



1- Théorie : Traitement du signal fréquentiel


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

1- Théorie : Traitement du signal fréquentiel

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

1- Théorie : Traitement du signal fréquentiel

Transformée de Fourier (à Court Terme) : TFCT

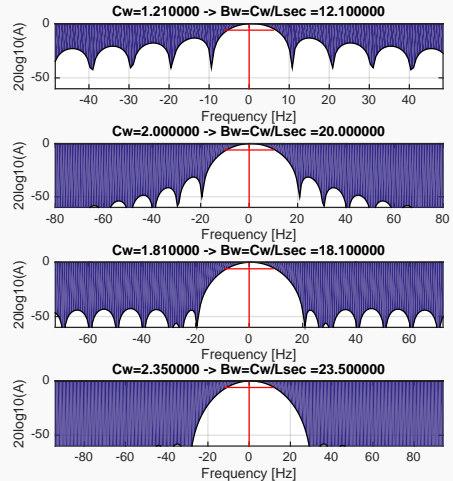

Choix du **type** de la fonction :

- 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
 - $w(n) = a_0 - a_1 \cos(\frac{2\pi n}{N-1}) + a_2 \cos(\frac{4\pi n}{N-1})$
 - $Bw = 2.35$

1- Théorie : Traitement du signal fréquentiel

Transformée de Fourier (à Court Terme) : TFCT

Influence du **type** de la fonction



1- Théorie : Traitement du signal fréquentiel

Transformée de Fourier (à Court Terme) : TFCT

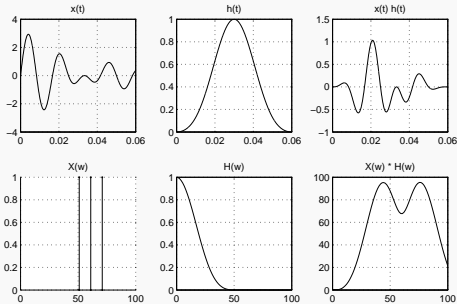
Choix de la **longueur temporelle** L :

- 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.


1- Théorie : Traitement du signal fréquentiel

Transformée de Fourier (à Court Terme) : TFCT

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




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




1- Théorie : Traitement du signal fréquentiel

Transformée de Fourier (à Court Terme) : TFCT

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



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







1- Théorie : Traitement du signal fréquentiel

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

1- Théorie : Traitement du signal fréquentiel

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

1- Théorie : Traitement du signal fréquentiel


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

1- Théorie : Traitement du signal fréquentiel

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


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




1- Théorie : Traitement du signal fréquentiel

Transformée à Q-Constant (CQT)

Exemples (en utilisant la DFT)



Exemples (en utilisant la CQT)




1- Théorie : Traitement du signal fréquentiel

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



1- Théorie : Traitement du signal fréquentiel

1.5- Deux interprétations de la TFCT

1- Théorie : Traitement du signal fréquentiel

Deux interprétations de la TFCT


Deux interprétations de la TFCT

- Interprétation **passé-bas** :
 - on regarde l'évolution du signal à une fréquence f_0 donnée

$$X(f, n) = \sum_{m=-\text{inf}}^{+\text{inf}} x(m)w(n-m)e^{-j2\pi fm}$$

$$\begin{aligned} X(f_0, n) &= \sum_{m=-\text{inf}}^{+\text{inf}} [x(m)e^{-j2\pi f_0 m}] w(n-m) \\ &= \sum_{m=-\text{inf}}^{+\text{inf}} x_0(m)w(n-m) \\ &= x_0(n) \circledast w(n) \end{aligned}$$

- avec $x_0(m) = x(m)e^{-j2\pi f_0 m}$ le signal modulé
- il s'agit d'une convolution de $x_0(m)$ par le filtre passe-bas $w(m)$



source : Patrick J. Wolfe, 2009

1- Théorie : Traitement du signal fréquentiel

Deux interprétations de la TFCT

Déduction du pas d'avancement

1- Théorie : Traitement du signal fréquentiel

Deux interprétations de la TFCT

Deux interprétations de la TFCT

- Interprétation **passé-bande** :

- on regarde l'évolution du signal à une fréquence f_0 donnée

$$X(f, n) = \sum_{m=-\infty}^{+\infty} x(m)w(n-m)e^{-j2\pi fm}$$

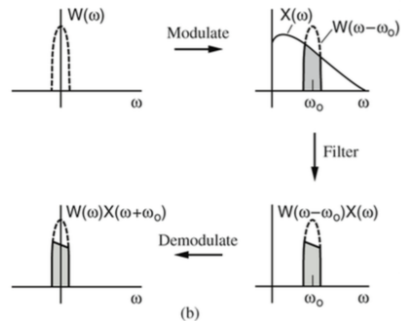

$$X(f_0, n) = \sum_{m=-\infty}^{+\infty} x(m) \underbrace{w(n-m)e^{j2\pi f_0(n-m)}}_{w_0(n-m)} e^{-j2\pi f_0 n}$$

$$= \sum_{m=-\infty}^{+\infty} x(m)w_0(n-m)e^{-j2\pi f_0 n}$$

$$= e^{-j2\pi f_0 n} \sum_{m=-\infty}^{+\infty} x(m)w_0(n-m)$$

$$= e^{-j2\pi f_0 n} \cdot [x(m) \circledast w_0(n)]$$

- avec $w_0(m) = w(m)e^{j2\pi f_0 m}$ la fenêtre démodulée
- il s'agit d'une convolution de $x(m)$ par le filtre passe-bande $w_0(m)$



source : Patrick J. Wolfe, 2009

1- Théorie : Traitement du signal fréquentiel

1.6- Reconstruction du signal par addition/ recouvrement (TFTC inverse)

1- Théorie : Traitement du signal fréquentiel

Reconstruction du signal par addition/ recouvrement (TFCT inverse)

On peut reconstruire le signal audio à partir des informations de la TFCT

- Méthode d'addition/recouvrement (OverLap-Add, OLA)

$$X(k, n) = \sum_m x(m)w(n - m)e^{-j2\pi \frac{k}{N}m}$$

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

$$\text{si } n=m \quad \frac{1}{Nw(0)} \sum_{k=0}^{N-1} X(k, n)e^{+j2\pi \frac{k}{N}n} = x(n)$$

1- Théorie : Traitement du signal fréquentiel

Reconstruction du signal par addition/ recouvrement (TFTC inverse)

On peut reconstruire le signal audio à partir des informations de la TFCT

- Si on note $n = rl$
 - $r \in \mathbb{N}$ le numéro de la trame d'analyse
 - l le pas d'avancement en échantillons

$$y(m, rl) = \frac{1}{N} \sum_{k=0}^{N-1} X(k, rl) e^{+j2\pi \frac{k}{N} m}$$

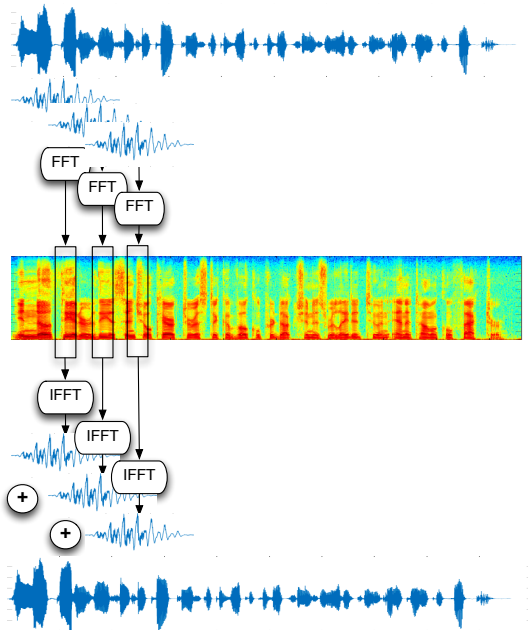
$$= x(m) w(rl - m)$$

$$y(m) = \sum_r y(m, rl)$$

$$= \sum_r x(m) w(rl - m)$$

$$= x(m) \sum_r w(rl - m)$$

$$x(n) = \frac{\sum_r y(m, rl)}{\sum_r w(rl - n)}$$



1- Théorie : Traitement du signal fréquentiel

Reconstruction du signal par addition/ recouvrement (TFTC inverse)

On peut reconstruire le signal audio à partir des informations de la TFCT

- Si on note $n = rl$
 - $r \in \mathbb{N}$ le numéro de la trame d'analyse
 - l le pas d'avancement en échantillons

$$y(m, rl) = \frac{1}{N} \sum_{k=0}^{N-1} X(k, rl) e^{+j2\pi \frac{k}{N} m}$$


$$= x(m)w(rl - m)$$

$$y(m) = \sum_r y(m, rl)$$

$$= \sum_r x(m)w(rl - m)$$

$$= x(m) \sum_r w(rl - m)$$

$$x(n) = \frac{\sum_r y(m, rl)}{\sum_r w(rl - n)}$$



1- Théorie : Traitement du signal fréquentiel

1.7- Application : filtrage constant au cours du temps


1- Théorie : Traitement du signal fréquentiel

Application : filtrage constant au cours du temps

Application : filtrage constant au cours du temps

Filtrage dans le domaine fréquentiel = très économique en coût de calcul

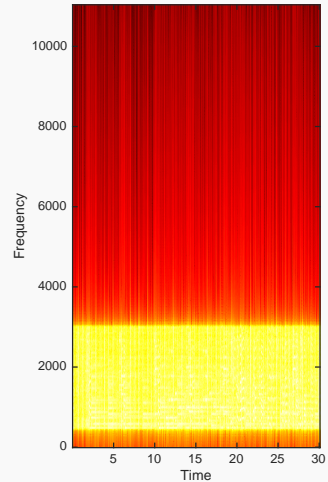


- $x(t) \otimes h(t) \Leftrightarrow X(\omega)H(\omega)$
- convolution en temps \Leftrightarrow produit en fréquence
- utilisation de l'algorithme FFT



1- Théorie : Traitement du signal fréquentiel

Application : filtrage constant au cours du temps

Application : filtrage constant au cours du temps



1- Théorie : Traitement du signal fréquentiel

1.8- Application : débruitage par soustraction spectrale


1- Théorie : Traitement du signal fréquentiel

Application : débruitage par soustraction spectrale

Application : débruitage par soustraction spectrale

[S. F. Boll. Suppression of acoustic noise in speech using spectral subtraction. Acoustics, Speech and Signal Processing, IEEE Transactions on, 27(2) :113–120, 1979.]

- soit $x(t) = s(t) + n(t)$
 - $s(t)$ est un signal de parole
 - $n(t)$ est un bruit additif
 - on peut écrire le modèle :
$$X(\omega) = S(\omega) + N(\omega)$$
- **Méthode**
 - On cherche un filtre fréquentiel $H(\omega)$ permettant de retirer le bruit additif
 - Amplitude de ce filtre
 - = valeur moyenne de $|N(\omega)|^2$ calculée sur un segment ne contenant que du bruit
 - $\mu(\omega) = E\{|N(\omega)|\}$
 - Phase
 - = la phase de X : $\phi_x(\omega)$



1- Théorie : Traitement du signal fréquentiel

Application : débruitage par soustraction spectrale


Application : débruitage par soustraction spectrale

- Soustraction :

$$\begin{aligned}\hat{S}(\omega) &= [|X(\omega)| - \mu(\omega)] e^{j\phi_x} \\ &= \underbrace{\left[1 - \frac{\mu(\omega)}{|X(\omega)|} \right]}_{H(\omega)} |X(\omega)| e^{j\phi_x} \\ &= H(\omega)X(\omega)\end{aligned}$$

- **Amélioration** :


- pour éviter des problèmes lorsque $|X(\omega)| < \mu(\omega)$ (quand le spectre d'amplitude est < au spectre moyen du bruit)
- rectification demi-onde (half-wave rectification) : $H_R(\omega) = \frac{H(\omega) + |H(\omega)|}{2}$




1- Théorie : Traitement du signal fréquentiel

Application : débruitage par soustraction spectrale

Spectrogramme speech+noise



Spectrogramme speech



1- Théorie : Traitement du signal fréquentiel




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

1- Théorie : Traitement du signal fréquentiel

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**

1- Théorie : Traitement du signal fréquentiel

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**


1- Théorie : Traitement du signal fréquentiel

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 $\alpha > 1$



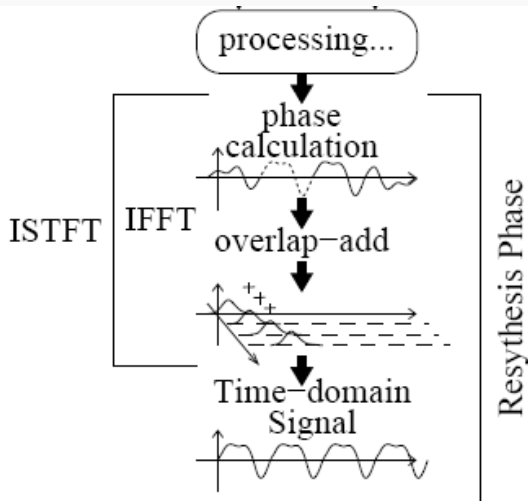
1- Théorie : Traitement du signal fréquentiel

Application : dilatation/ contraction du temps par vocodeur de phase

Le vocoder de phase : analyse



Le vocoder de phase : synthèse



1- Théorie : Traitement du signal fréquentiel

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 $\alpha > 1$





1- Théorie : Traitement du signal fréquentiel

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
 - $f_0 = \frac{\phi(t_2) + n2\pi - \phi(t_1)}{2\pi(t_2 - t_1)}$

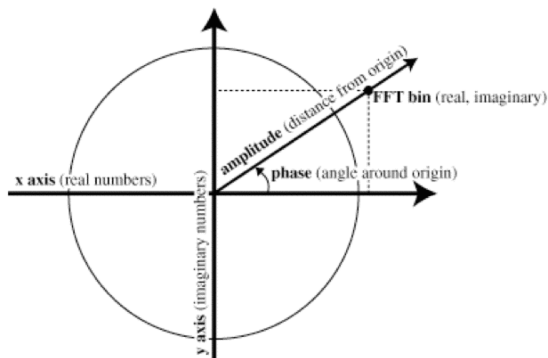


1- Théorie : Traitement du signal fréquentiel

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 :
 - $X(k, n) = A(k, n)e^{j\phi(k, n)}$



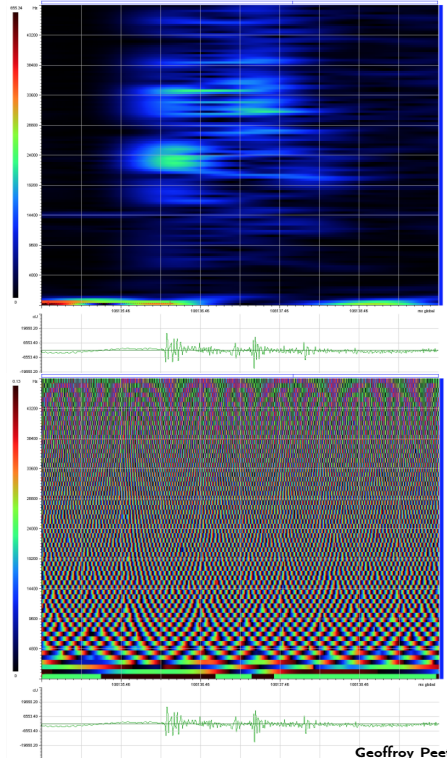
FFT Cartesian to Polar Conversion

1- Théorie : Traitement du signal fréquentiel

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 $(n - 1) \rightarrow n$.



1- Théorie : Traitement du signal fréquentiel

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** :

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




1- Théorie : Traitement du signal fréquentiel

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
 - $\phi(k, r') = \phi(k, r' - 1) + 2\pi f_0 \Delta t$



1- Théorie : Traitement du signal fréquentiel

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 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 $\Delta\phi_{th}$



1- Théorie : Traitement du signal fréquentiel

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** :

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






1- Théorie : Traitement du signal fréquentiel

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

1- Théorie : Traitement du signal fréquentiel

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.

2- Séparation de sources

2- Séparation de sources

2.1- Séparation de la partie harmonique et percussive d'un morceau de musique


2- Séparation de sources

Séparation de la partie harmonique et percussive d'un morceau de musique

Séparation de la partie harmonique et percussive d'un morceau de musique

[D. Fitzgerald. Harmonic/percussive separation using median filtering. In Proc. of DAFX, Graz, Austria, 2010.]

- **HPSS** : Harmonic-Percussive Source Separation
- On considère la TFCT comme le résultat de l'addition de composantes harmoniques et percussives
 - $X(f, n) = H(f, n) + P(f, n)$
- Morphologie en temps/fréquence des instruments de musique
 - composantes harmoniques :
 - lignes horizontales
 - composantes percussives :
 - lignes verticales





2- Séparation de sources


Séparation de la partie harmonique et percussive d'un morceau de musique

Séparation de la partie harmonique et percussive d'un morceau de musique

- Création d'un **spectrogramme harmonique** $H(f, n)$:
 - pour chaque f on applique un filtrage médian de $X(f, n)$ à travers les n
- Création d'un **spectrogramme percussif** $P(f, n)$:
 - pour chaque n on applique un filtrage médian de $X(f, n)$ à travers les f
- **Filtrage médian** ?
 - remplace chaque entrée par la **valeur médiane** de son voisinage
 - Valeur médiane ?
 - valeur telle que 50% des valeurs en-dessous et 50% au-dessus



Filtrage median de $X(f, n)$ à travers les n



2- Séparation de sources

Séparation de la partie harmonique et percussive d'un morceau de musique

Séparation de la partie harmonique et percussive d'un morceau de musique

- Création d'un **masque harmonique**

$$M_H(f, n) = \begin{cases} 1 & \text{si } H(f, n) > P(f, n) \\ 0 & \text{sinon} \end{cases}$$


- Création d'un **masque percussif**

$$M_P(f, n) = \begin{cases} 1 & \text{si } P(f, n) > H(f, n) \\ 0 & \text{sinon} \end{cases}$$


- Re-cr ation de la TFCT

$$H(f, n) = X(f, n) \cdot M_H(f, n)$$

$$P(f, n) = X(f, n) \cdot M_P(f, n)$$




Filtrage median de $X(f, n)$   travers les n



2- Séparation de sources

Séparation de la partie harmonique et percussive d'un morceau de musique

Séparation de la partie percussive et harmonique d'un morceau de musique



2- Séparation de sources

2.2- Factorisation (décomposition) en matrices non-négatives


2- 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


2- 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


2- 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


2- 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

2- 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 :

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

2- 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 : $\|A\|_F = \sqrt{\sum_i \sum_j a_{ij}^2}$

2- 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)

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

2- 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 $\eta = \frac{H}{W^T WH}$

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

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

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


2- 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**

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



2- 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

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


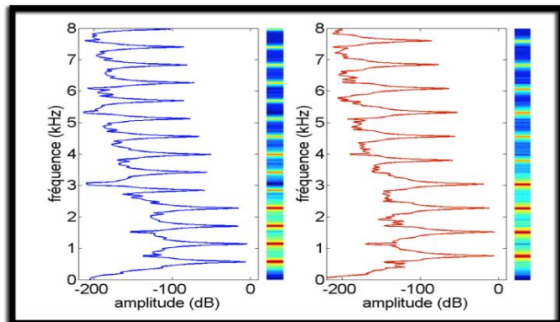
- Mise à jour des activations H étant donné les bases W

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

- 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

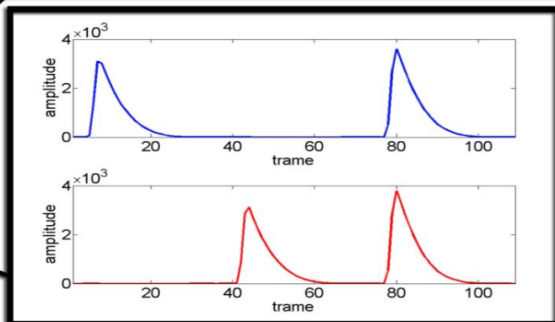
2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives



$$WH \approx V$$

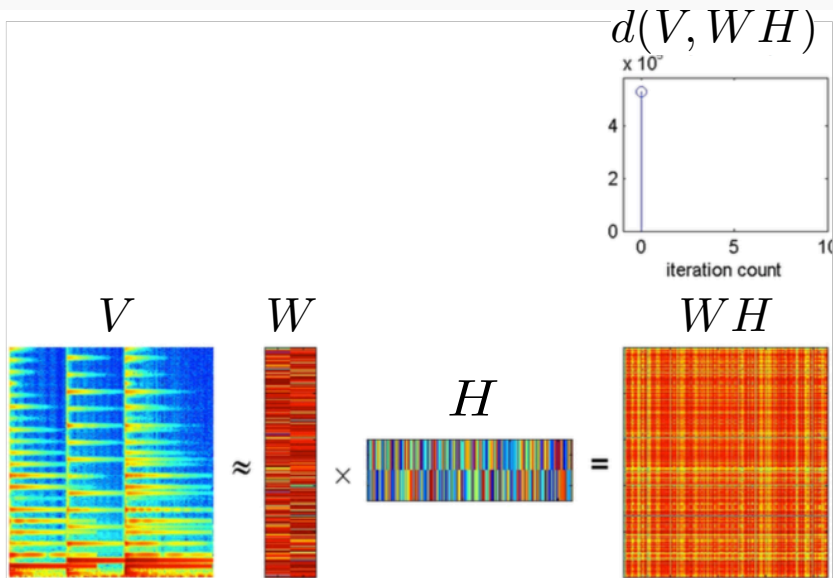
Image d'après R. Hennequin



2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Initialisation




source : Tuomas Virtanen

2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Iteration 1 : Mise à jour de W




source : Tuomas Virtanen

2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

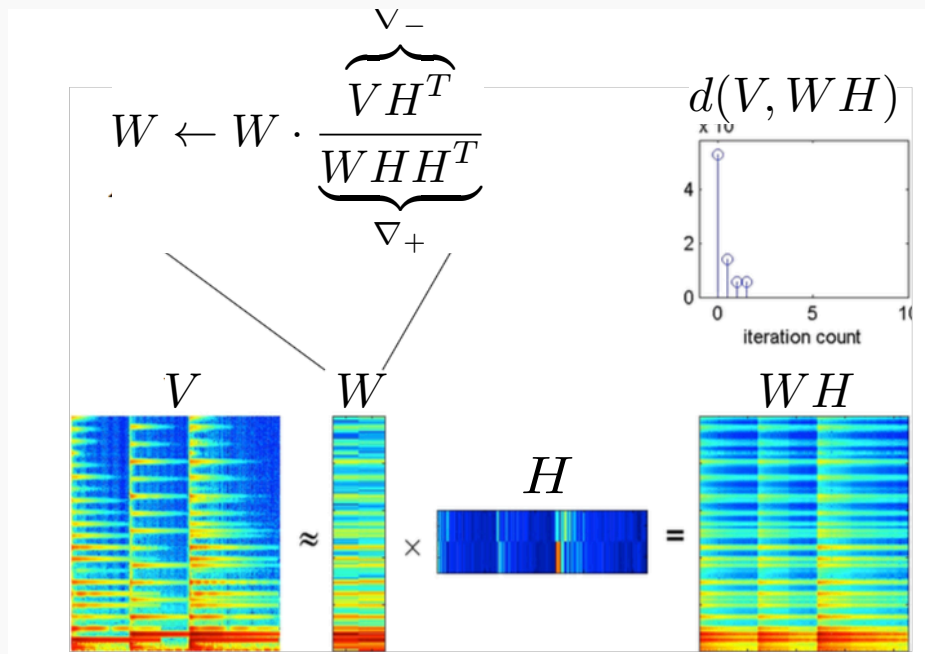
Iteration 1 : Mise à jour de H



2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

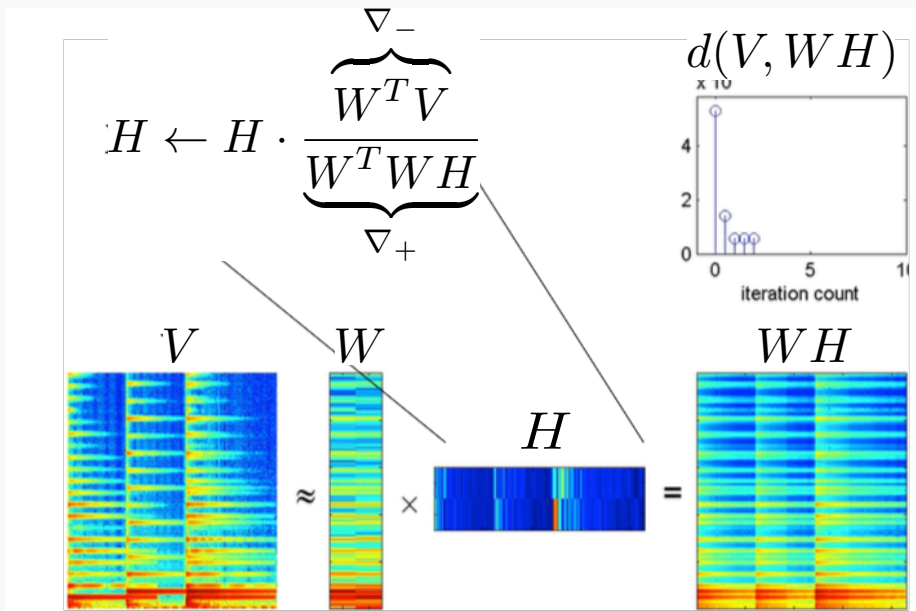
Iteration 2 : Mise à jour de W



2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Iteration 2 : Mise à jour de H




source : Tuomas Virtanen

2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

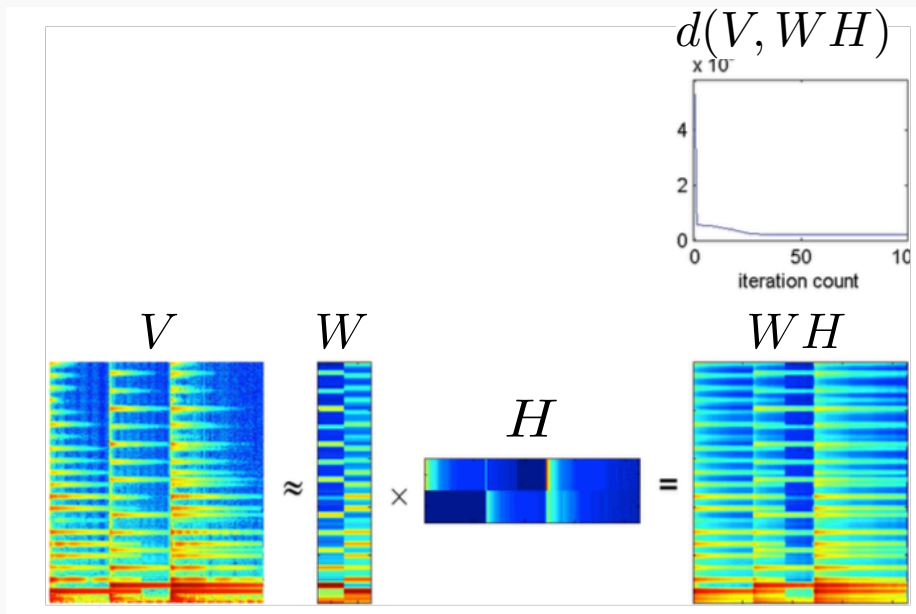
Iteration 10 : Mise à jour de W



2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

Iteration 100







source : Tuomas Virtanen

2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives





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



2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

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



2- Séparation de sources

Factorisation (décomposition) en matrices non-négatives

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

