

モノラル音響信号に対する 音源分離のための 無限相関テンソル分解

吉井 和佳


京都大学 大学院情報学研究科 知能情報学専攻
理化学研究所 革新知能統合研究センター (RIKEN AIP)

yoshii@kuis.kyoto-u.ac.jp

<http://sap.ist.i.kyoto-u.ac.jp/members/yoshii/>

研究の背景

- モノラル音響信号の音源分離技術は音楽解析の基礎
 - 応用例：音楽信号の高度な加工
 - 歌声と伴奏の分離 [Rafii2011, Huang2012, 池宮2016]
 - 楽器音イコライザ [吉井2006, 宮本2008, 糸山2008]
- 時間-周波数領域で位相情報を無視する方法が一般的
 - 振幅スペクトルに着目すると音の特徴がとらえやすい
 - 低ランク性・スパース性などを手がかりとした分離が可能



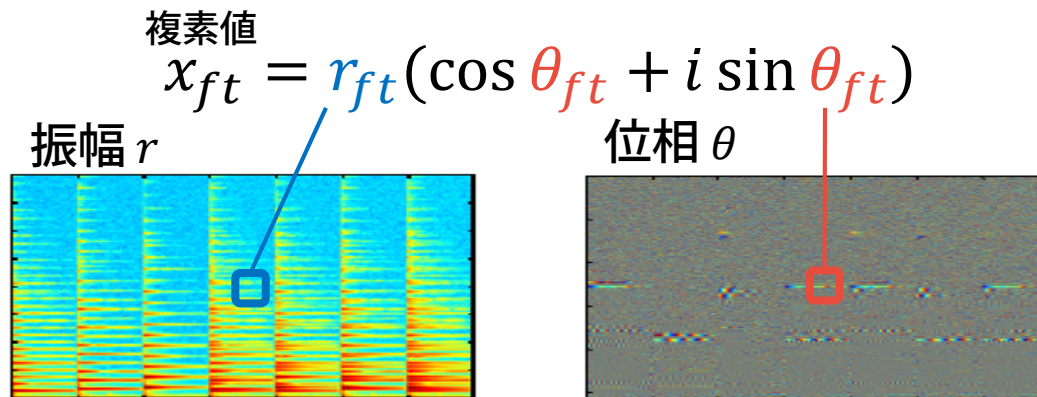
非負値行列分解 (NMF)
に基づく手法が主流

- 直感に合う
- 実装が簡単
- 高速に動作

研究の動機

- 位相情報をきちんと取り扱うための新しい方法論が必要
 - 複素スペクトルの加法性に基づく分解法がいくつか提案

	周波数方向	時間方向
複素NMF [亀岡 2009]	独立	独立
HR-NMF [Badeau 2011]	独立	自己回帰過程
PSDTF [吉井 2013]	相関を考慮	独立
CTF [本研究]	相関を考慮	相関を考慮



振幅や位相は時間-周波数
ごとに独立で定まる
わけではない！
→ 複素スペクトログラム
全体の整合性が重要

目次

- CTFの定式化
 - NMF・PSDTFの自然な拡張
- CTFの確率モデル
 - コスト関数 (LDダイバージェンス) の最小化
 - 尤度関数 (多変量複素ガウス分布) の最大化
- CTFの学習
 - EMアルゴリズム・MMアルゴリズム
- CTFに基づく音源分離
 - ウィナーフィルタリング
- CTFの計算量の削減
 - ブロック対角行列を用いた近似
 - 同時対角化

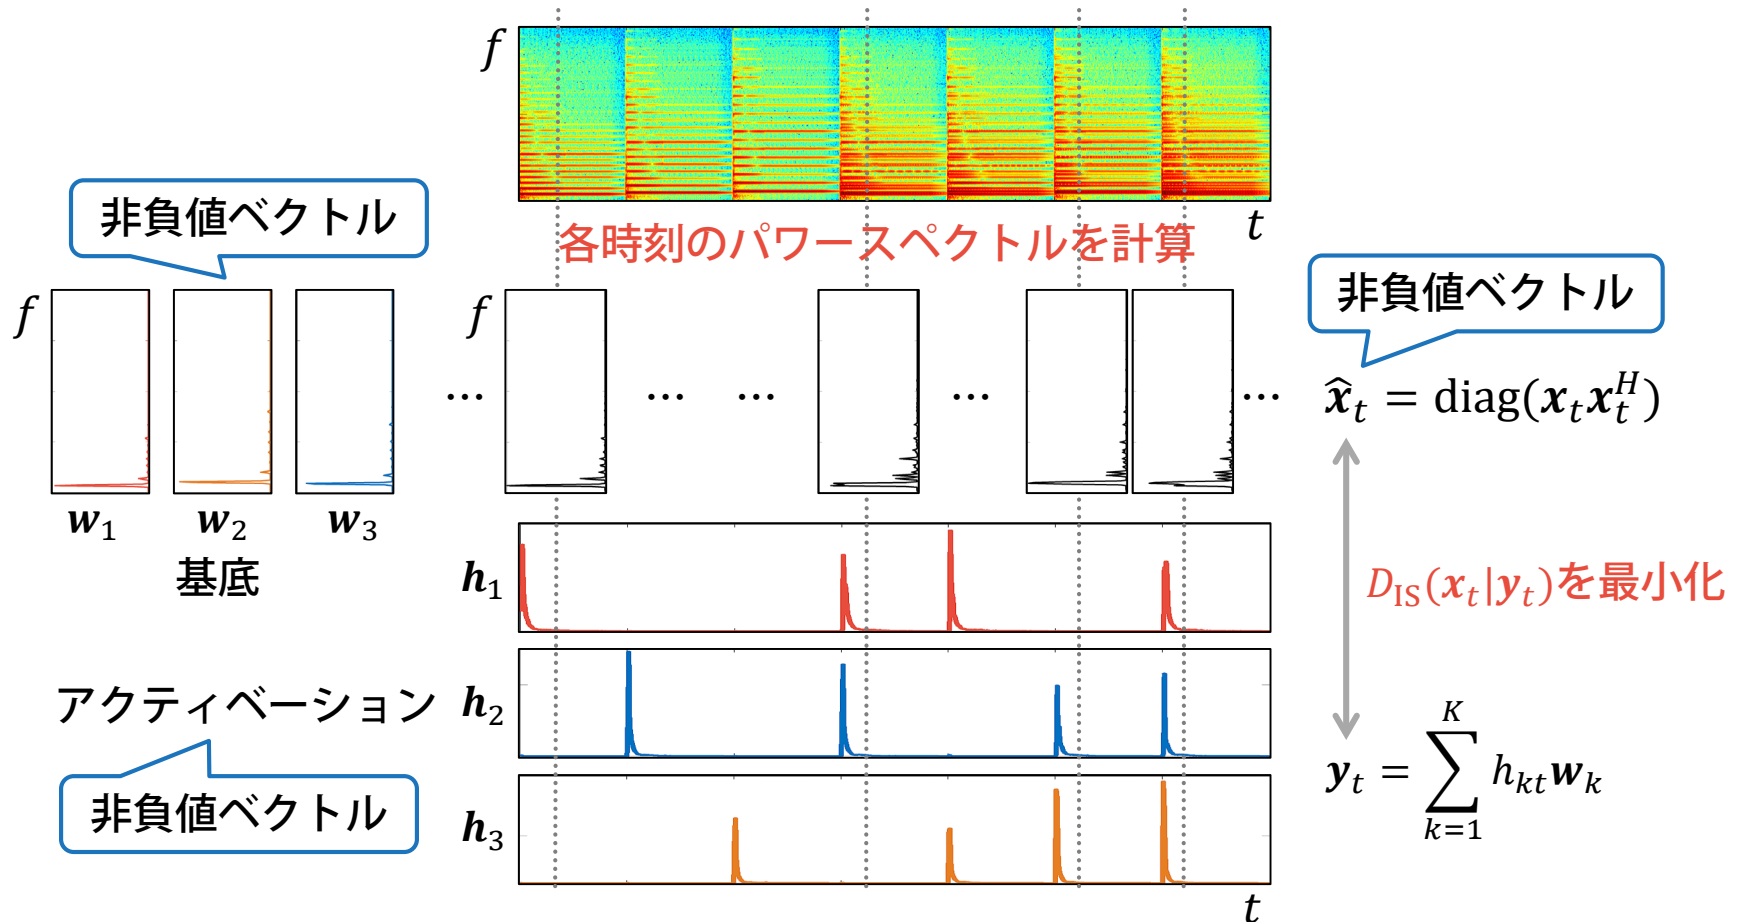
目次

- CTFの定式化
 - NMF・PSDTFの自然な拡張
- CTFの確率モデル
 - コスト関数 (LDダイバージェンス) の最小化
 - 尤度関数 (多変量複素ガウス分布) の最大化
- CTFの学習
 - EMアルゴリズム・MMアルゴリズム
- CTFに基づく音源分離
 - ウィナーフィルタリング
- CTFの計算量の削減
 - ブロック対角行列を用いた近似
 - 同時対角化

非負値行列分解 (NMF)

[Févotte 2009]

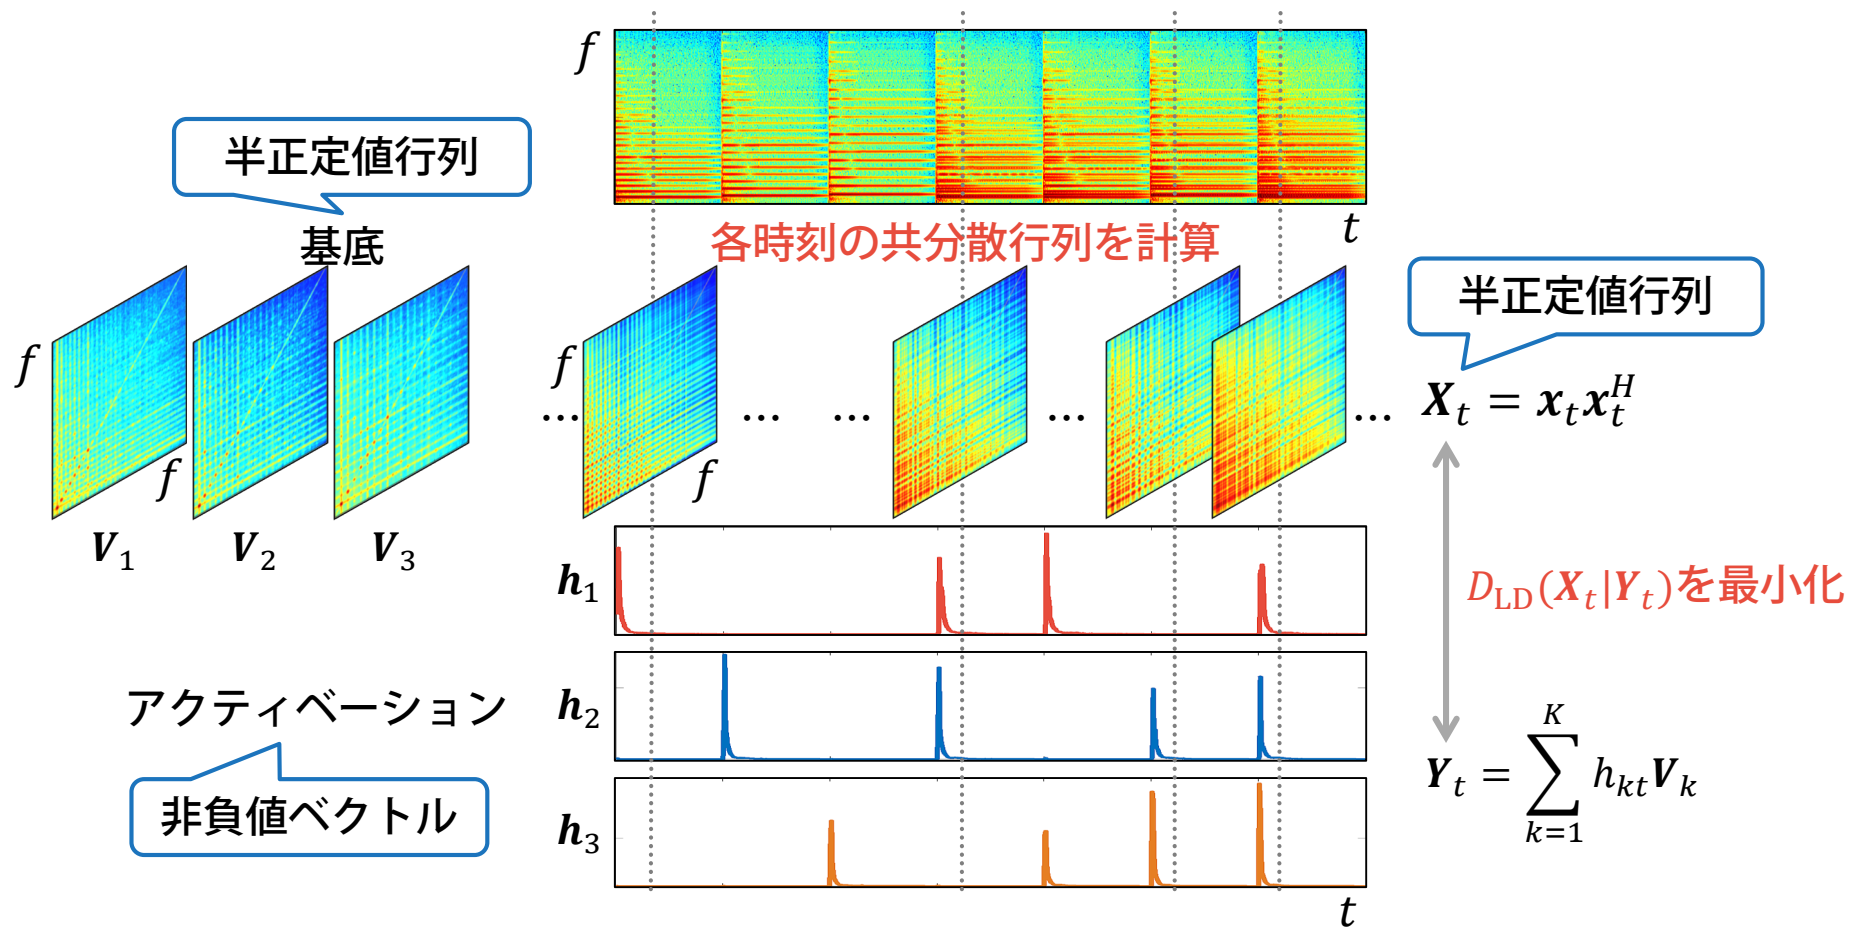
- 非負値ベクトルを少数の非負値ベクトルの線形和で近似



半正定値テンソル分解 (PSDTF)

[吉井 2013]

- 半正定値行列を少数の半正定値行列の線形和で近似



NMF vs PSDTF

- PSDTFはNMFの数学的に自然な拡張


- スカラ/ベクトルの非負値性 → 行列の半正定値性
- NMF = 半正定値行列を対角行列に限定したPSDTF

半正定値行列の
対角成分は常に非負

周波数方向の
相関を無視

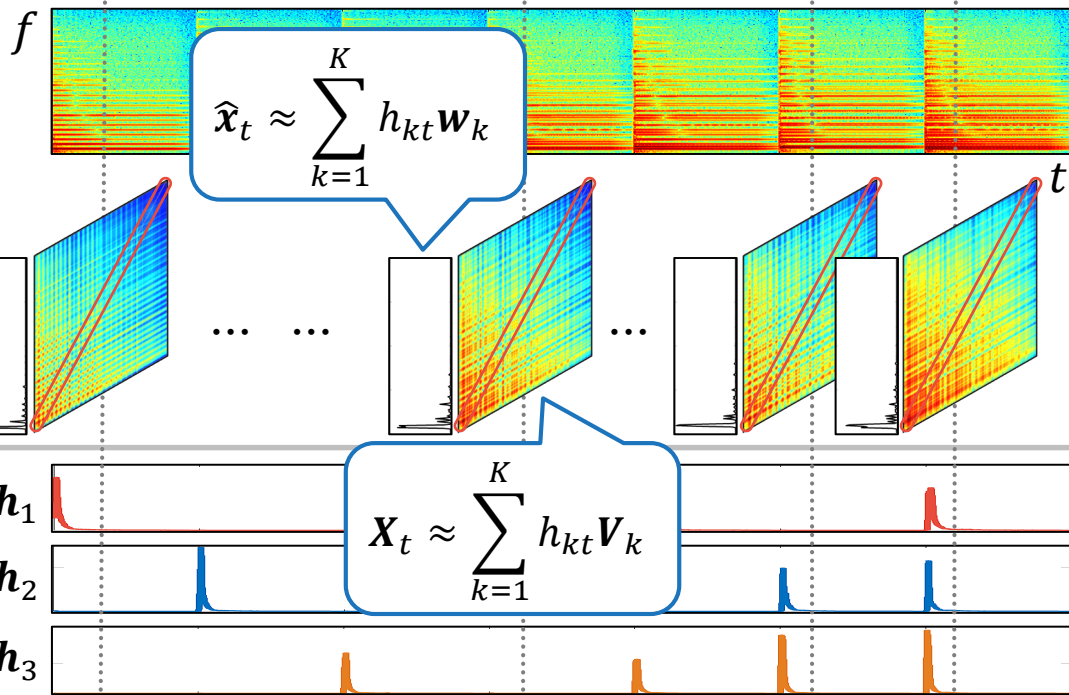
基底

非負値ベクトル



半正定値行列

アクティベーション



行列の半正定値性

- 半正定値性は非負値性の拡張概念
 - 非負値の和は非負値 (差は非負値とは限らない)
 - 半正定値行列の和は半正定値行列 (差は半正定値とは限らない)

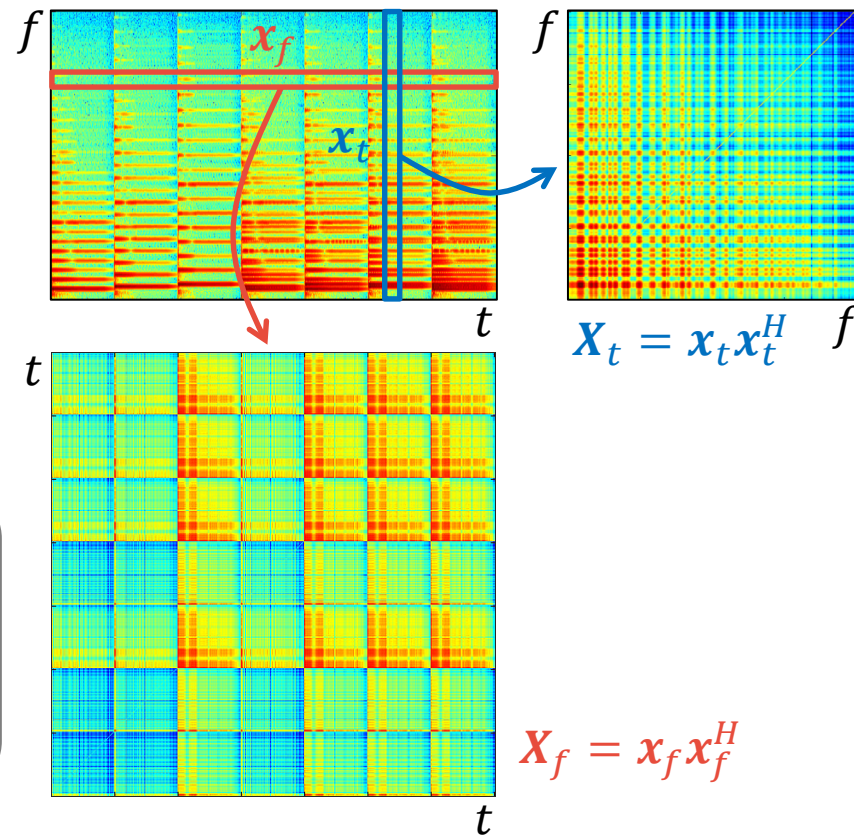
	非負値性	半正定値性
対象	実数 $x = x^C$	エルミート行列 $X = X^H$
	$x = 5$	$X = \begin{pmatrix} 7 & 6 + 3i \\ 6 - 3i & 10 \end{pmatrix}$
定義1	固有値が非負	全ての固有値が非負
	$5 \geq 0$	$15.3739, 1.6261 \geq 0$
定義2	$x = aa^C$ を満たす複素数 a が存在	$X = AA^H$ を満たす複素行列 A が存在
	$x = (1 + 2i)(1 - 2i)$	$X = \begin{pmatrix} 1 + i & 1 + 2i \\ 2 - i & 1 + 2i \end{pmatrix} \begin{pmatrix} 1 - i & 2 + i \\ 1 - 2i & 1 - 2i \end{pmatrix}$
備考		対角成分は全て非負

実行列なら
対称行列

相関の取り扱い

- 周波数方向の相関 or 時間方向の相関 を考慮可能
 - 複素スペクトログラムは単なる行列データ → 転置して解析可能

	周波数方向	時間方向
PSDTF-F	相関を考慮	独立
PSDTF-T	独立	相関を考慮




現実的には、音響信号が長くなっても半正定値行列サイズが一定になるので「PSDTF-F」の方が扱いやすい
(オリジナルのPSDTF)

周波数方向の相関を考慮したPSDTF

- 半正定値行列を少数の半正定値行列の線形和で近似


半正定値行列

基底




アクティベーション

非負値ベクトル



各時刻ごとに共分散行列を計算




半正定値行列

$$X_t = x_t x_t^H$$

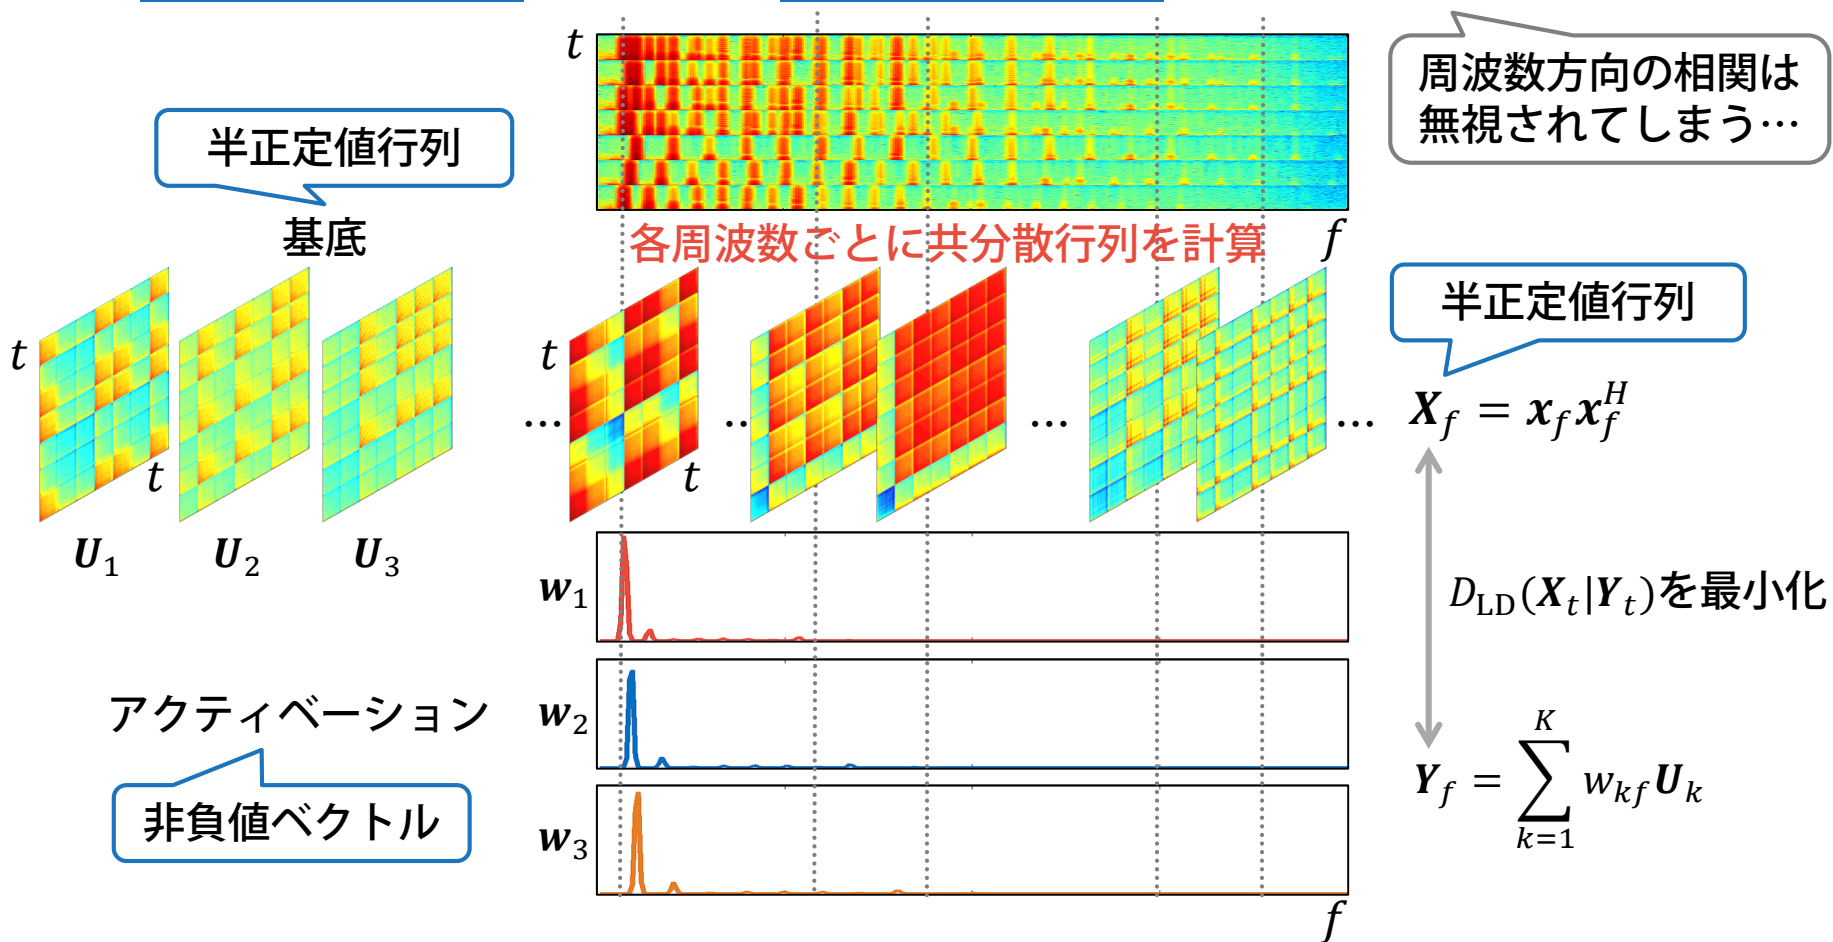
$D_{LD}(X_t|Y_t)$ を最小化

$$Y_t = \sum_{k=1}^K h_{kt} V_k$$



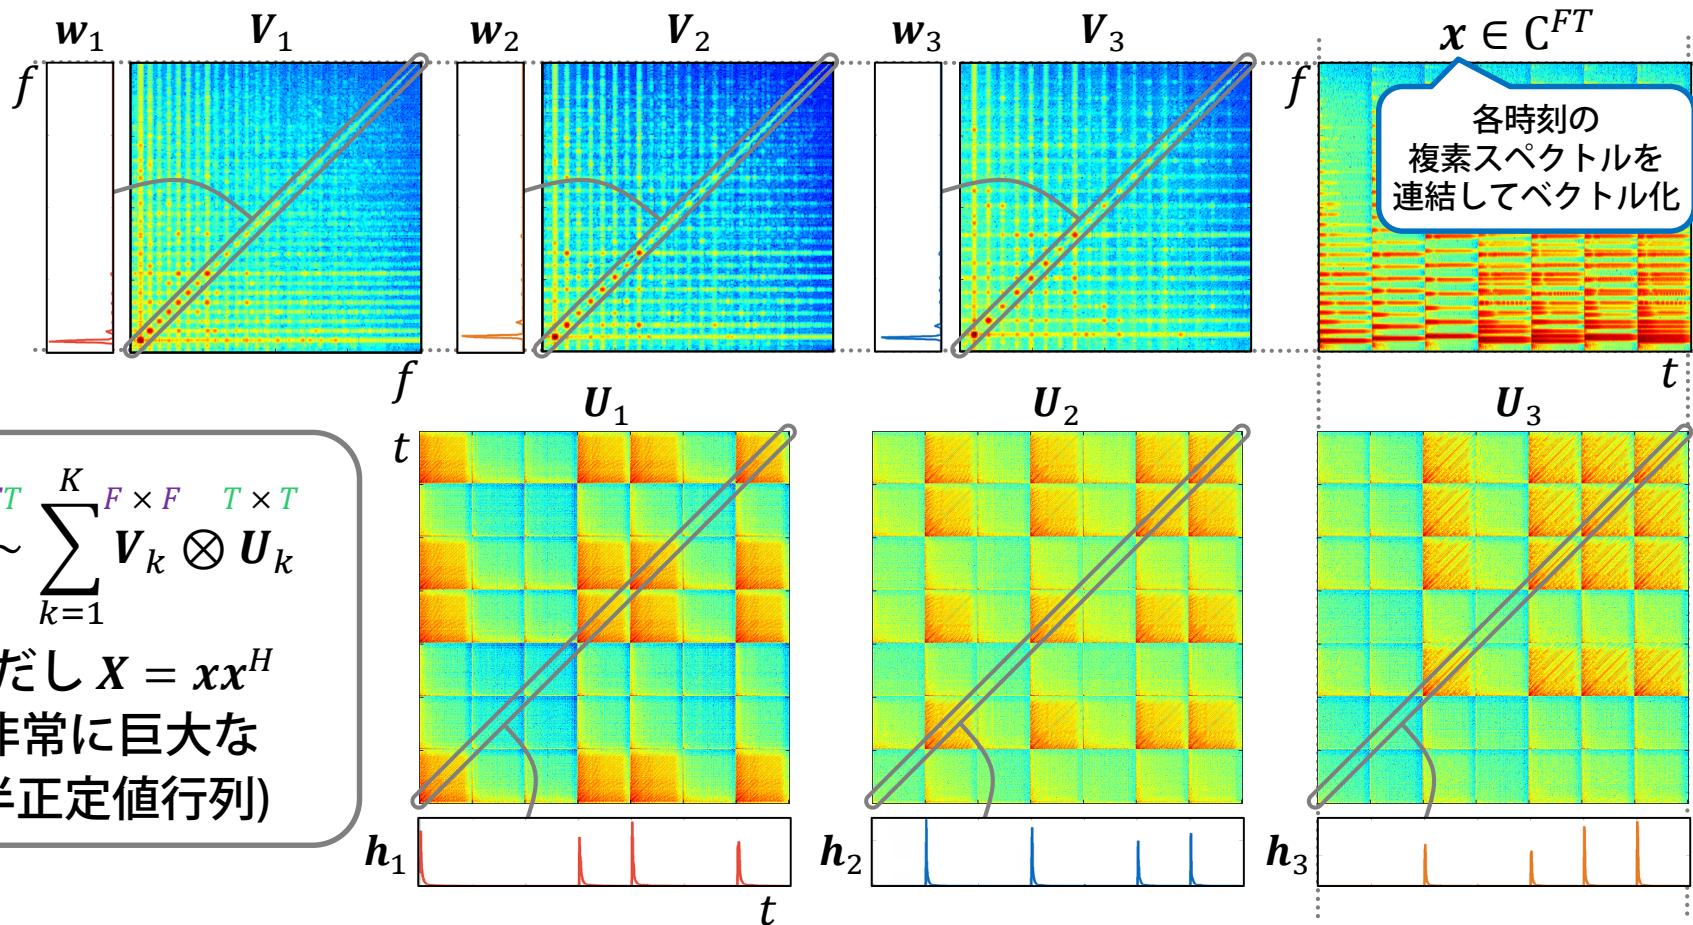
時間方向の相関を考慮したPSDTF

- 半正定値行列を少数の半正定値行列の線形和で近似




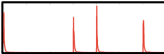
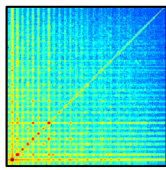
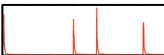

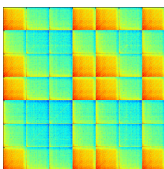
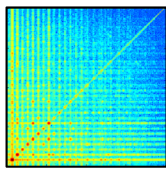
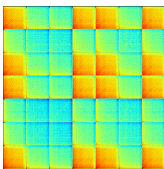
提案法：相関テンソル分解 (CTF)

- 時間-周波数平面上の相関を考慮した究極の分解法



NMF vs PSDTF vs CTF

- CTFの一部を対角行列に限定 → NMFやPSDTFに帰着

	周波数方向 相関	時間方向 相関	確率モデル	周波数 基底	時間 基底
NMF			$x_{ft} \sim N_c \left(0, \sum_{k=1}^K w_{kf} h_{kt} \right)$ スカラ	 w_k	 h_k
PSDTF-F	✓		$x_t \sim N_c \left(0, \sum_{k=1}^K v_k h_{kt} \right)$ F次元ベクトル	 v_k	 h_k
PSDTF-T		✓	$x_f \sim N_c \left(0, \sum_{k=1}^K w_{kf} u_k \right)$ T次元ベクトル	 w_k	 u_k
CTF	✓	✓	$x \sim N_c \left(0, \sum_{k=1}^K v_k \otimes u_k \right)$ FT次元ベクトル	 v_k	 u_k

クロネッカー積

定義と性質

- 二つの行列 $A \in \mathbb{C}^{M \times N}$, $B \in \mathbb{C}^{P \times Q}$ に対するクロネッカー積

$$A \otimes B = \begin{pmatrix} a_{11}B & \cdots & a_{1N}B \\ \vdots & \ddots & \vdots \\ a_{M1}B & \cdots & a_{MN}B \end{pmatrix} \in \mathbb{C}^{MP \times NQ}$$

- 一般に可換ではないが置換同値


- $A \otimes B \neq B \otimes A$

- $A \otimes B = P(B \otimes A)Q$ となるような置換行列 P, Q が存在

CTFにおける例

$$X \sim \sum_{k=1}^K \begin{matrix} FT \times FT \\ F \times F \\ T \times T \end{matrix} V_k \otimes U_k$$

F次元ベクトルをT個連結



$$X \sim \sum_{k=1}^K \begin{matrix} TF \times TF \\ T \times T \\ F \times F \end{matrix} U_k \otimes V_k$$

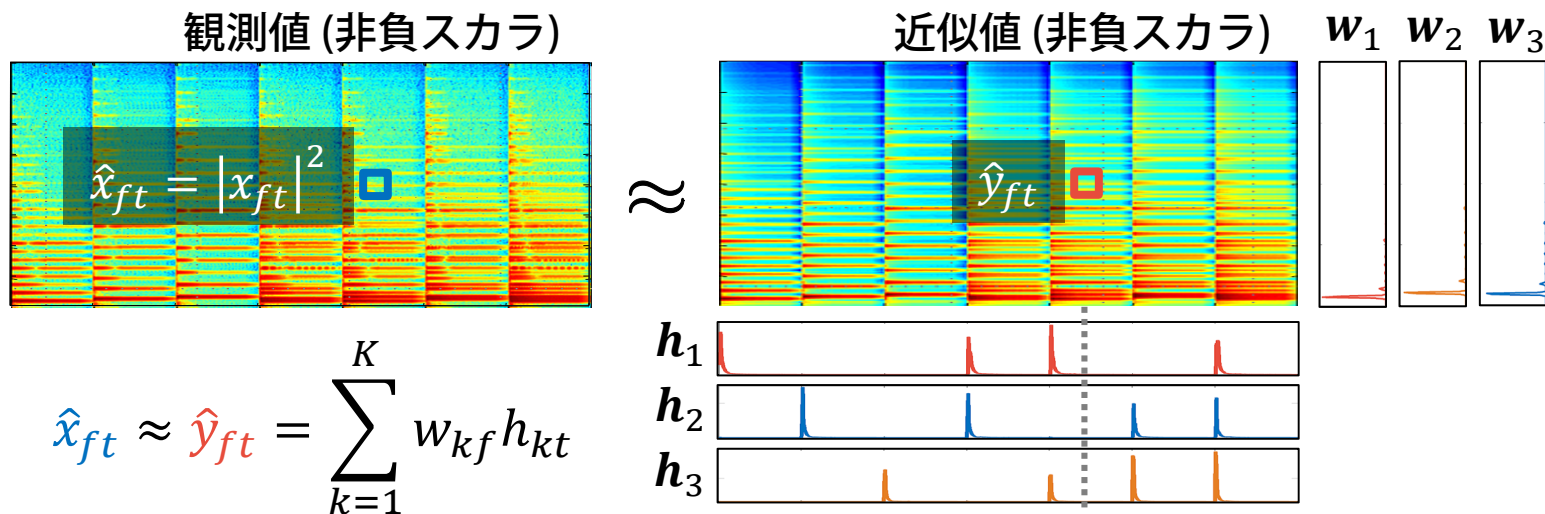
T次元ベクトルをF個連結

目次

- CTFの定式化
 - NMF・PSDTFの自然な拡張
- CTFの確率モデル
 - コスト関数 (LDダイバージェンス) の最小化
 - 尤度関数 (多変量複素ガウス分布) の最大化
- CTFの学習
 - EMアルゴリズム・MMアルゴリズム
- CTFに基づく音源分離
 - ウィナーフィルタリング
- CTFの計算量の削減
 - ブロック対角行列を用いた近似
 - 同時対角化

Itakura-Saito NMF (IS-NMF) [Févotte 2009]

- 板倉-齋藤ダイバージェンスをコスト関数にもつNMF
 - 混合音のパワースペクトログラムを低ランク行列で近似
 - ランク K (音源数) は事前に設定



$$\hat{x}_{ft} \approx \hat{y}_{ft} = \sum_{k=1}^K w_{kf} h_{kt}$$

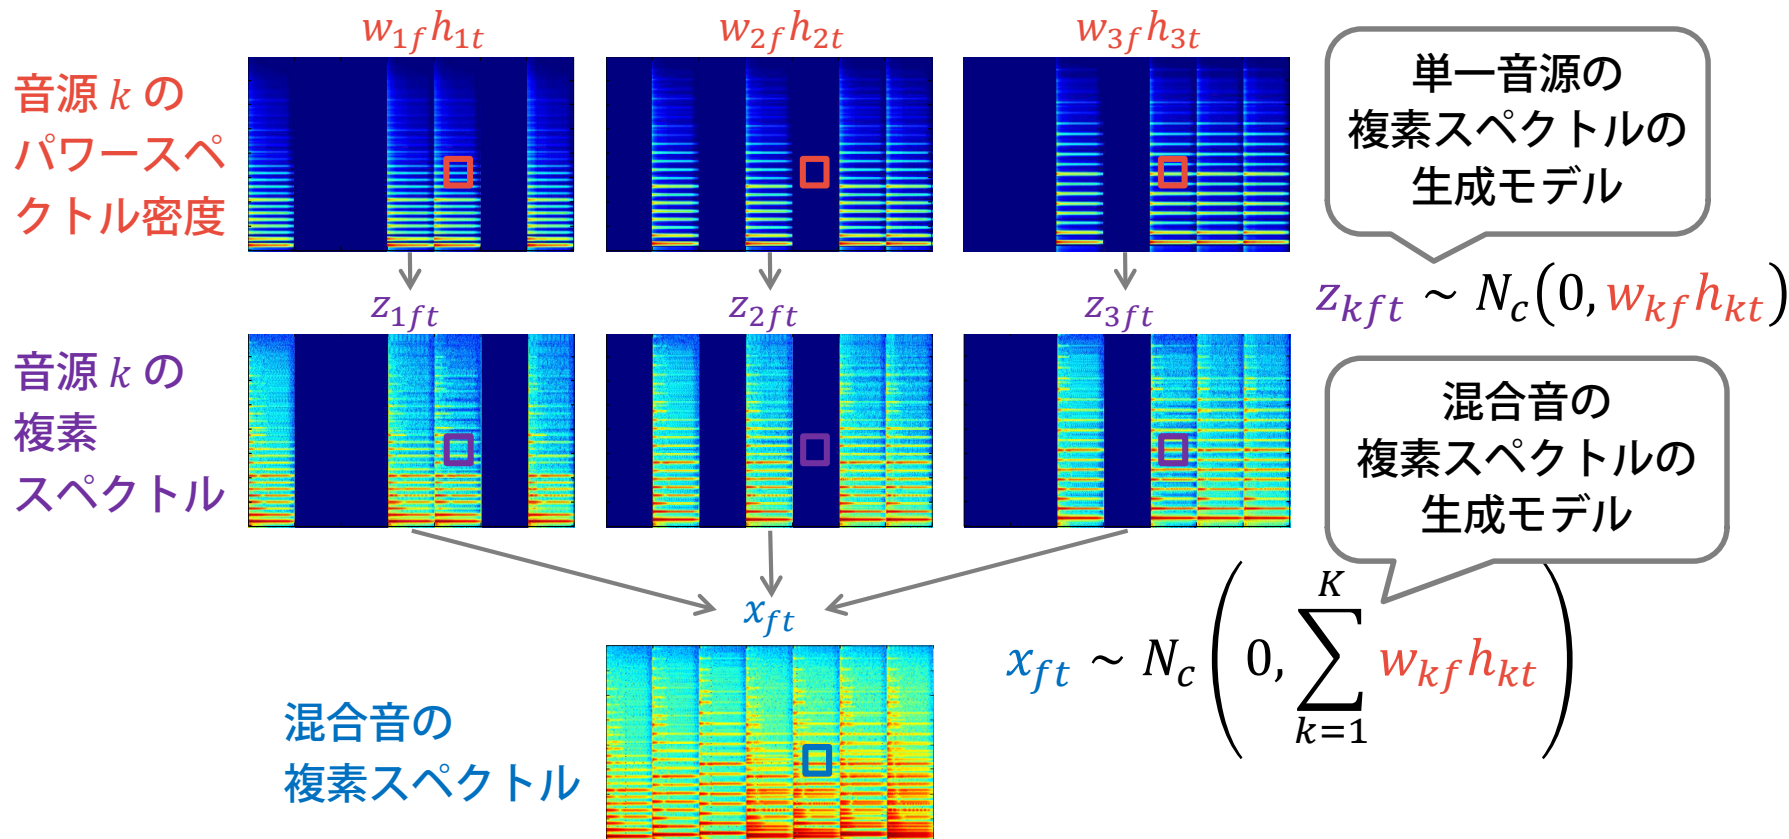
$$D_{\text{IS}}(\hat{x}_{ft} | \hat{y}_{ft}) = -\log \frac{\hat{x}_{ft}}{\hat{y}_{ft}} + \frac{\hat{x}_{ft}}{\hat{y}_{ft}} - 1$$

スケール不変な尺度

$$D_{\text{IS}}(\hat{x}_{ft} | \hat{y}_{ft}) = D_{\text{IS}}(\alpha \hat{x}_{ft} | \alpha \hat{y}_{ft})$$

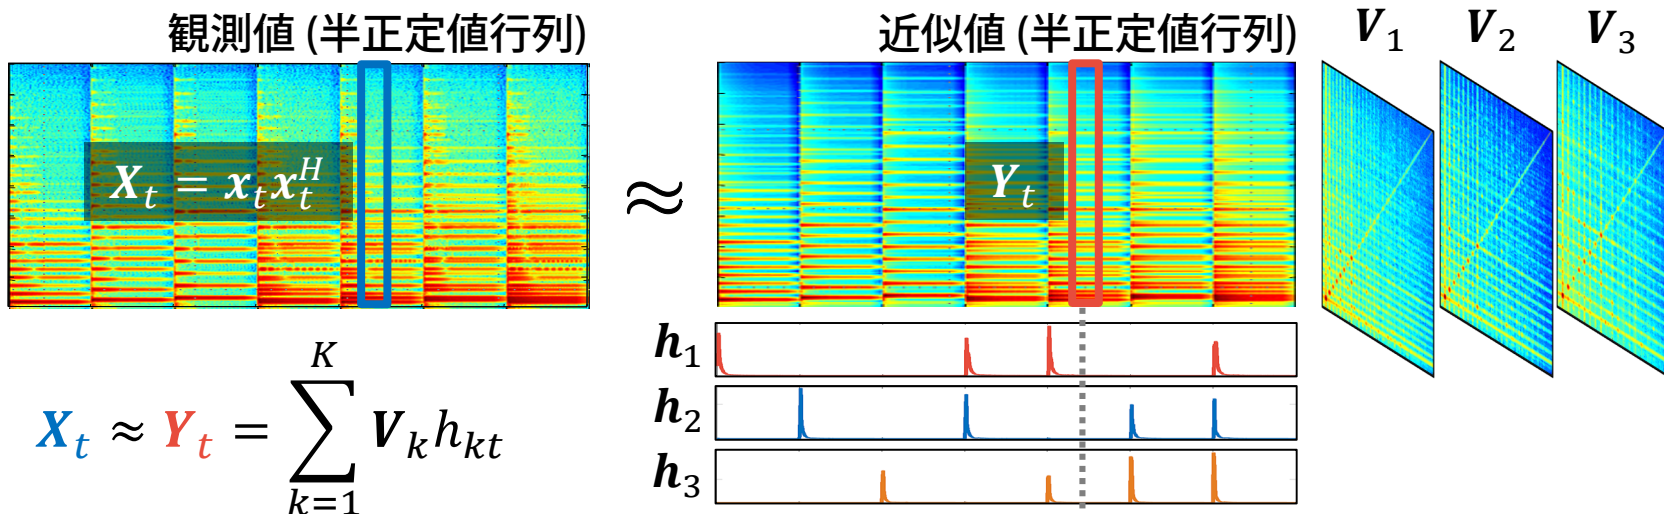
IS-NMFの確率モデル

- 複素ガウス分布を尤度関数にもつNMF
 - 複素ガウス尤度の最大化 = ISダイバージェンスの最小化



LogDet PSDTF (LD-PSDTF) [吉井 2013]

- LogDetダイバージェンスをコスト関数にもつPSDTF
 - 各時刻の共分散行列を基底行列の重み付き和で近似
 - 周波数方向の相関を考慮



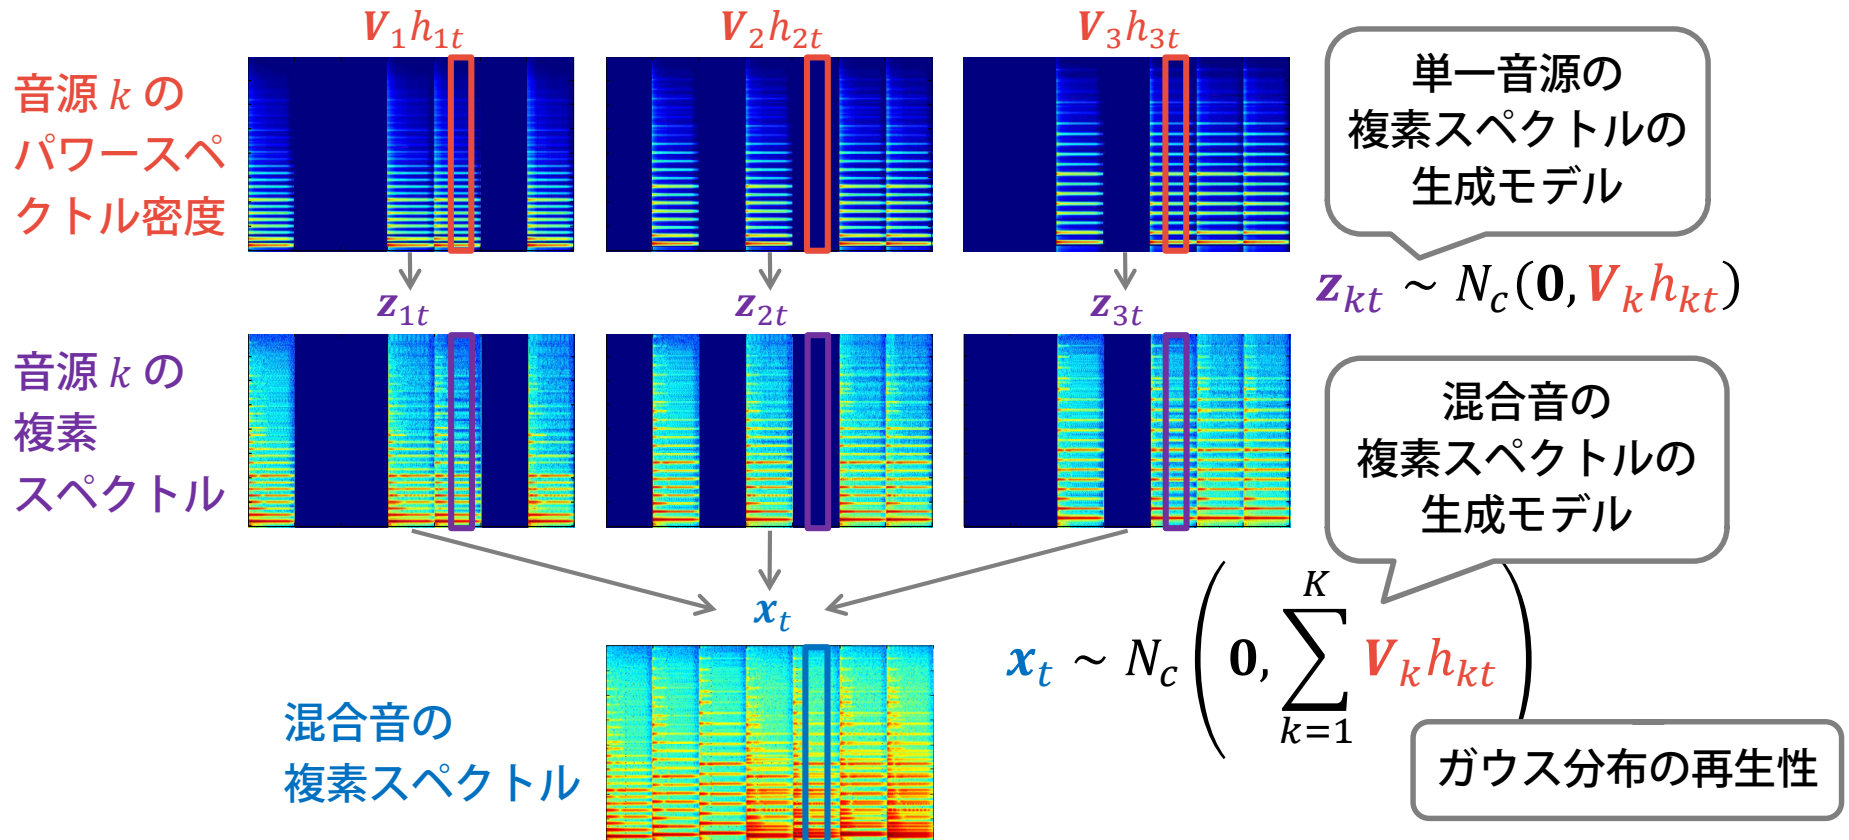
$$D_{LD}(X_t | Y_t) = -\log |X_t Y_t^{-1}| + \text{tr}(X_t Y_t^{-1}) - F$$

スケール不変な尺度

$$D_{LD}(X_t | Y_t) = D_{LD}(\alpha X_t | \alpha Y_t)$$

LD-PSDTFの確率モデル


- 多変量複素ガウス分布を尤度関数にもつPSDTF
 - 多変量複素ガウス尤度の最大化 = LDダイバージェンスの最小化




LogDet PSDTF (LD-CTF) [提案法]

- LogDetダイバージェンスをコスト関数にもつCTF
 - 周波数-時間平面上の巨大な共分散行列を、
周波数基底行列と時間基底行列とのクロネッカー積の和で近似

観測値 (半正定値行列)




近似値 (半正定値行列)




≈

$$X \approx Y = \sum_{k=1}^K V_k \otimes U_k$$


U_1



U_2




U_3



V_1

V_2

V_3



$$D_{LD}(X|Y) = -\log|XY^{-1}| + \text{tr}(XY^{-1}) - FT$$

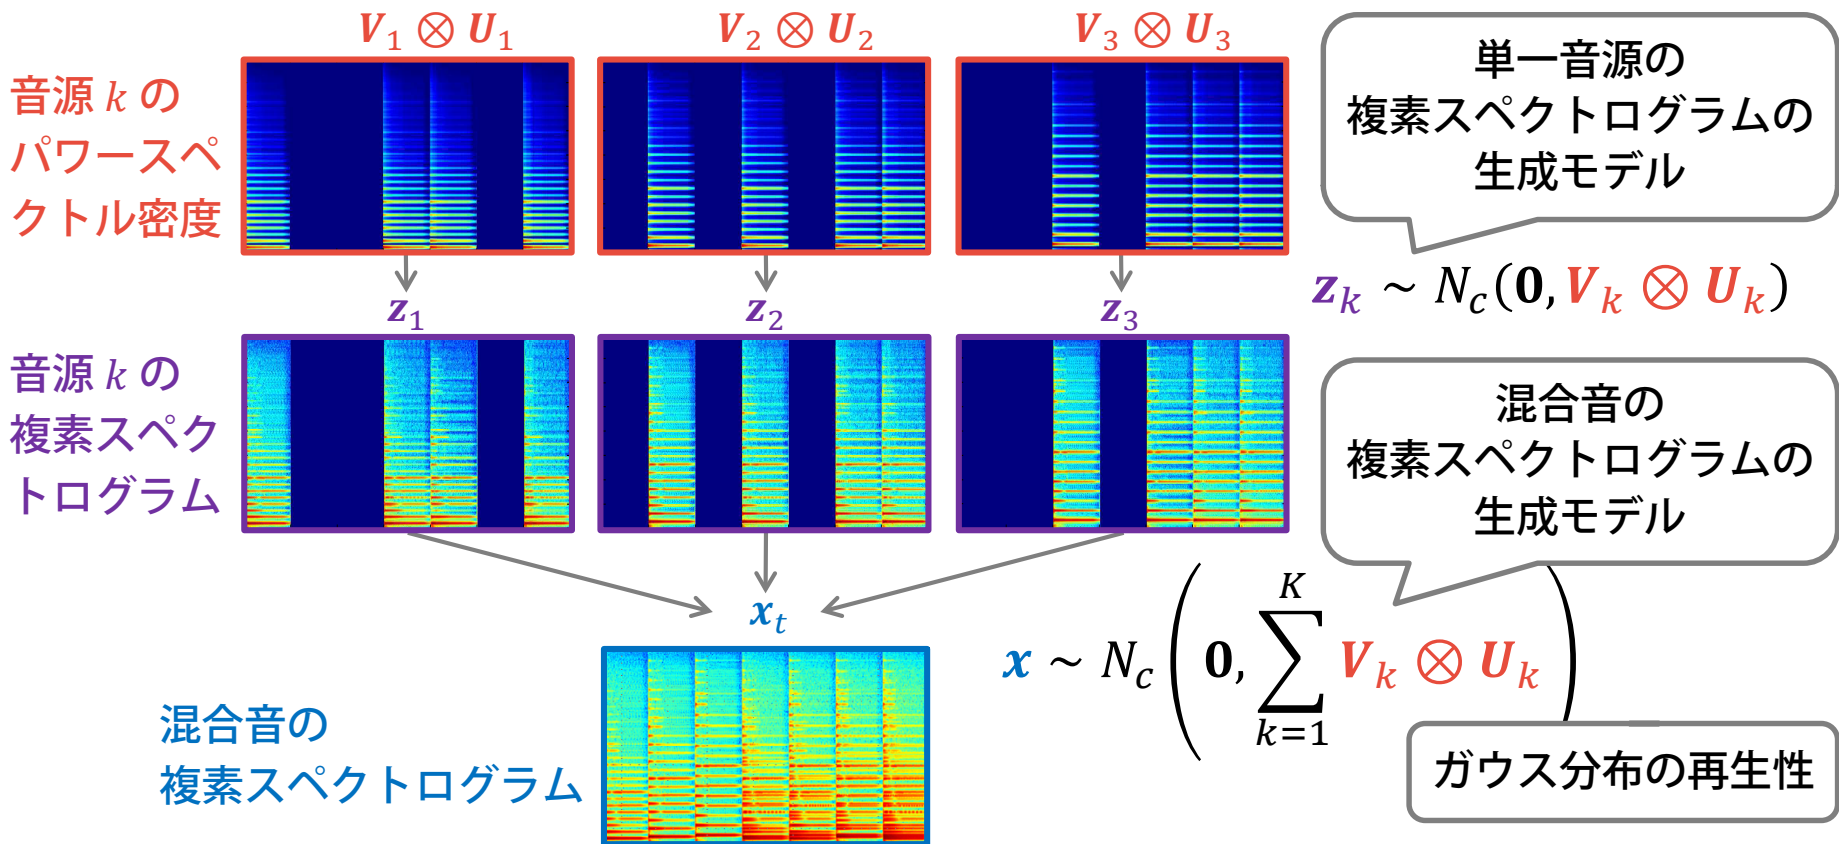
スケール不変な尺度

$$D_{LD}(X|Y) = D_{LD}(\alpha X|\alpha Y)$$

LD-CTFの確率モデル

- 多変量複素ガウス分布を尤度関数にもつCTF

- 多変量複素ガウス尤度の最大化 = LDダイバージェンスの最小化



目次

- CTFの定式化
 - NMF・PSDTFの自然な拡張
- CTFの確率モデル
 - コスト関数 (LDダイバージェンス) の最小化
 - 尤度関数 (多変量複素ガウス分布) の最大化
- CTFの学習
 - EMアルゴリズム・MMアルゴリズム
- CTFに基づく音源分離
 - ウィナーフィルタリング
- CTFの計算量の削減
 - ブロック対角行列を用いた近似
 - 同時対角化

CTFの学習

- 多変量複素ガウス分布に基づく最尤推定が可能
 - Expectation-Maximization (EM) アルゴリズム
 - Eステップ：各音源 k の複素スペクトログラム z_k の推定
 - Mステップ：パラメータ V_k, U_k の更新
 - Minorization-Maximization (MM) アルゴリズム
 - ステップ1：最適な補助変数の推定
 - ステップ2：パラメータ V_k, U_k の更新
 - いくつかの注意
 - Eステップ (ステップ1) で得られた最適値を
Mステップ (ステップ2) に代入すれば更新式が得られる
 - MMアルゴリズムのほうが収束が高速である場合が多い

MMアルゴリズム

- 収束が保証された汎用的な最適化アルゴリズム
 - CTFやPSDTFのためのclosed-formな更新則の導出に初めて成功

$$\mathbf{P}_k = (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{1 \times T}) \left((\mathbf{I}_{F \times F} \otimes \mathbf{U}_k^T) \odot \mathbf{Y}^{-1} \right) (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{T \times 1})$$

$$\mathbf{Q}_k = (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{1 \times T}) \left((\mathbf{I}_{F \times F} \otimes \mathbf{U}_k^T) \odot \mathbf{Y}^{-1} \mathbf{X} \mathbf{Y}^{-1} \right) (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{T \times 1})$$

$$\mathbf{V}_k \leftarrow \mathbf{P}_k^{-\frac{1}{2}} \left(\mathbf{P}_k^{\frac{1}{2}} \mathbf{V}_k \mathbf{Q}_k \mathbf{V}_k \mathbf{P}_k^{\frac{1}{2}} \right)^{\frac{1}{2}} \mathbf{P}_k^{-\frac{1}{2}} = \mathbf{P}_k^{-1} \circ \mathbf{V}_k \mathbf{Q}_k \mathbf{V}_k$$

$A \circ B$ は半正定値行列
どうしの幾何平均を表す

$$\mathbf{R}_k = (\mathbf{1}_{1 \times F} \otimes \mathbf{I}_{T \times T}) \left((\mathbf{V}_k^T \otimes \mathbf{I}_{T \times T}) \odot \mathbf{Y}^{-1} \right) (\mathbf{1}_{F \times 1} \otimes \mathbf{I}_{T \times T})$$

$$\mathbf{S}_k = (\mathbf{1}_{1 \times F} \otimes \mathbf{I}_{T \times T}) \left((\mathbf{V}_k^T \otimes \mathbf{I}_{T \times T}) \odot \mathbf{Y}^{-1} \mathbf{X} \mathbf{Y}^{-1} \right) (\mathbf{1}_{F \times 1} \otimes \mathbf{I}_{T \times T})$$

$$\mathbf{U}_k \leftarrow \mathbf{R}_k^{-\frac{1}{2}} \left(\mathbf{R}_k^{\frac{1}{2}} \mathbf{U}_k \mathbf{S}_k \mathbf{U}_k \mathbf{R}_k^{\frac{1}{2}} \right)^{\frac{1}{2}} \mathbf{R}_k^{-\frac{1}{2}} = \mathbf{R}_k^{-1} \circ \mathbf{U}_k \mathbf{S}_k \mathbf{U}_k$$

IS-NMF vs LD-CTF

- どちらの更新則も幾何平均となっている
 - LD-CTFの場合はある種の乗法更新則とみなせる

$$\mathbf{P}_k = (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{1 \times T}) \left((\mathbf{I}_{F \times F} \otimes \mathbf{U}_k^T) \odot \mathbf{Y}^{-1} \right) (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{T \times 1})$$

$$\mathbf{Q}_k = (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{1 \times T}) \left((\mathbf{I}_{F \times F} \otimes \mathbf{U}_k^T) \odot \mathbf{Y}^{-1} \mathbf{X} \mathbf{Y}^{-1} \right) (\mathbf{I}_{F \times F} \otimes \mathbf{1}_{T \times 1})$$

$$\mathbf{V}_k \leftarrow \mathbf{P}_k^{-\frac{1}{2}} \left(\mathbf{P}_k^{\frac{1}{2}} \mathbf{V}_k \mathbf{Q}_k \mathbf{V}_k \mathbf{P}_k^{\frac{1}{2}} \right)^{\frac{1}{2}} \mathbf{P}_k^{-\frac{1}{2}} = \mathbf{P}_k^{-1} \circ \mathbf{V}_k \mathbf{Q}_k \mathbf{V}_k$$

$$W_{km} \leftarrow W_{km} \sqrt{\frac{\sum_n \frac{x_{nm} h_{kn}}{y_{nm}^2}}{\sum_n \frac{h_{kn}}{y_{nm}}}}$$

IS-NMF

$$\mathbf{R}_k = (\mathbf{1}_{1 \times F} \otimes \mathbf{I}_{T \times T}) \left((\mathbf{V}_k^T \otimes \mathbf{I}_{T \times T}) \odot \mathbf{Y}^{-1} \right) (\mathbf{1}_{F \times 1} \otimes \mathbf{I}_{T \times T})$$

$$\mathbf{S}_k = (\mathbf{1}_{1 \times F} \otimes \mathbf{I}_{T \times T}) \left((\mathbf{V}_k^T \otimes \mathbf{I}_{T \times T}) \odot \mathbf{Y}^{-1} \mathbf{X} \mathbf{Y}^{-1} \right) (\mathbf{1}_{F \times 1} \otimes \mathbf{I}_{T \times T})$$

$$\mathbf{U}_k \leftarrow \mathbf{R}_k^{-\frac{1}{2}} \left(\mathbf{R}_k^{\frac{1}{2}} \mathbf{U}_k \mathbf{S}_k \mathbf{U}_k \mathbf{R}_k^{\frac{1}{2}} \right)^{\frac{1}{2}} \mathbf{R}_k^{-\frac{1}{2}} = \mathbf{R}_k^{-1} \circ \mathbf{U}_k \mathbf{S}_k \mathbf{U}_k$$

$$h_{kn} \leftarrow h_{kn} \sqrt{\frac{\sum_m \frac{x_{nm} w_{km}}{y_{nm}^2}}{\sum_m \frac{w_{km}}{y_{nm}}}}$$

IS-NMF

目次

- CTFの定式化
 - NMF・PSDTFの自然な拡張
- CTFの確率モデル
 - コスト関数 (LDダイバージェンス) の最小化
 - 尤度関数 (多変量複素ガウス分布) の最大化
- CTFの学習
 - EMアルゴリズム・MMアルゴリズム
- CTFに基づく音源分離
 - ウィナーフィルタリング
- CTFの計算量の削減
 - ブロック対角行列を用いた近似
 - 同時対角化

ウィナーフィルタリング

- 潜在変数 (音源の複素スペクトログラム) の事後分布計算
 - 複素ガウス分布の性質から容易に計算可能

	確率モデル	音源分離 Eステップに対応 (音源の複素スペクトログラムの事後確率の計算)
IS-NMF	$x_{ft} \sim N_c \left(0, \sum_{k=1}^K \underbrace{w_{kf}}_{\text{purple}} \underbrace{h_{kt}}_{\text{green}} \right)$	$z_{kft} x_{ft} \sim N_c(\hat{y}_{kft} \hat{y}_{ft}^{-1} x_{ft}, \hat{y}_{kft} - \hat{y}_{kft} \hat{y}_{ft}^{-1} \hat{y}_{kft})$ <p>音源 混合音 周波数・時間ごとに独立に分離</p>
LD-PSDTF	$x_t \sim N_c \left(0, \sum_{k=1}^K \underbrace{Y_{kt}}_{\text{red}} \underbrace{V_k}_{\text{purple}} \underbrace{h_{kt}}_{\text{green}} \right)$	$z_{kt} x_t \sim N_c(Y_{kt} Y_t^{-1} x_t, Y_{kt} - Y_{kt} Y_t^{-1} Y_{kt})$ <p>音源 混合音 時間ごとに独立に分離</p>
LD-CTF	$x \sim N_c \left(0, \sum_{k=1}^K \underbrace{V_k}_{\text{purple}} \otimes \underbrace{U_k}_{\text{green}} \right)$	$z_k x \sim N_c(Y_k Y^{-1} x, Y_k - Y_k Y^{-1} Y_k)$ <p>音源 混合音 複素スペクトログラムが一挙に求まる!</p>


目次

- CTFの定式化
 - NMF・PSDTFの自然な拡張
- CTFの確率モデル
 - コスト関数 (LDダイバージェンス) の最小化
 - 尤度関数 (多変量複素ガウス分布) の最大化
- CTFの学習
 - EMアルゴリズム・MMアルゴリズム
- CTFに基づく音源分離
 - ウィナーフィルタリング
- CTFの計算量の削減
 - ブロック対角行列を用いた近似
 - 同時対角化

計算量の比較

- CTFの時間計算量は莫大
 - そのまま実行するのは非現実的 ($F = 1024, T = 3000$ など)
 - 何らかの高速化の工夫が必要
 - 基底行列をブロック対角行列で近似
 - 基底行列を対角行列+低ランク行列で近似
 - 基底行列の同時対角化

	時間計算量	空間計算量
IS-NMF	$O(KFT)$	$O(K(F + T))$
LD-PSDTF-F	$O(KF^3T)$	$O(K(F^2 + T))$
LD-PSDTF-T	$O(KFT^3)$	$O(K(F + T^2))$
LD-CTF	$O(KF^3T^3)$	$O(K(F^2 + T^2))$




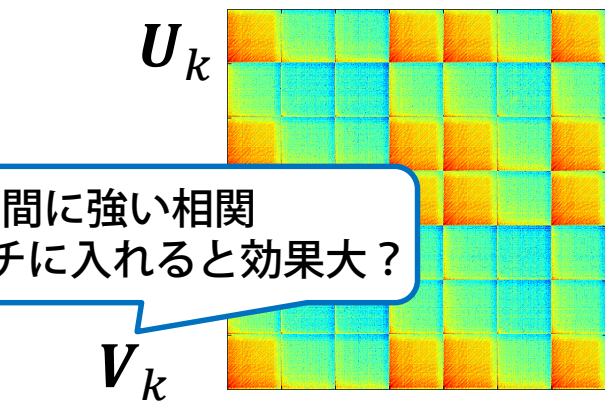
高速化の工夫1

- 基底行列をブロック対角行列に限定

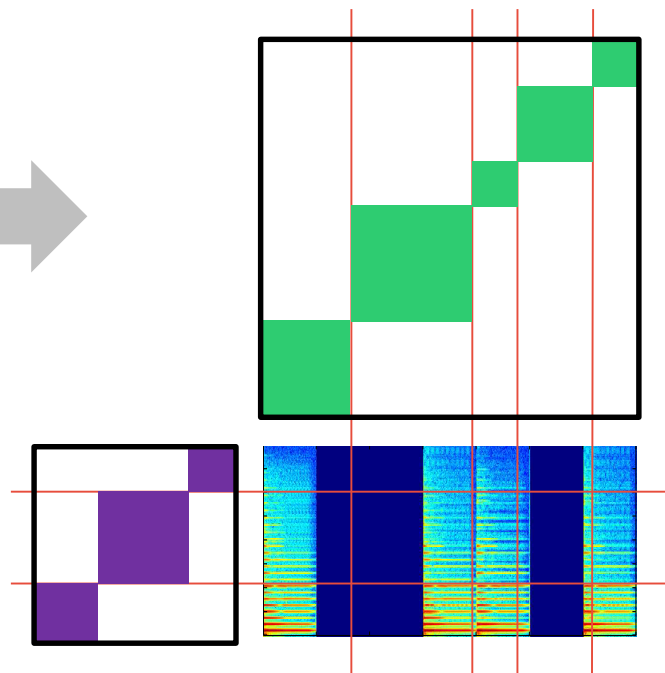
- 時間・周波数平面を小さなパッチに分割する
- 各パッチに対して基底行列を共有しながらCTF → 大幅高速化

必ずしも隣接した周波数や時間でもなくてもよい

倍音間に強い相関
→ 同じパッチに入れると効果大?




$$\mathbf{z}_k \sim N_C(\mathbf{U}_k \otimes \mathbf{V}_k)$$



高速化の工夫2

- 基底行列を対角行列+低ランク行列で近似 [Liutkus 2017]
 - 大域的な相関を考慮可能
 - ランクの設定：倍音のピークの個数程度にするとよい
 - CTFではこれだけだと高速化として不十分

$$V_k \approx D_k + L_k S_k L_k^H$$




対角行列

≈



+

低ランク行列

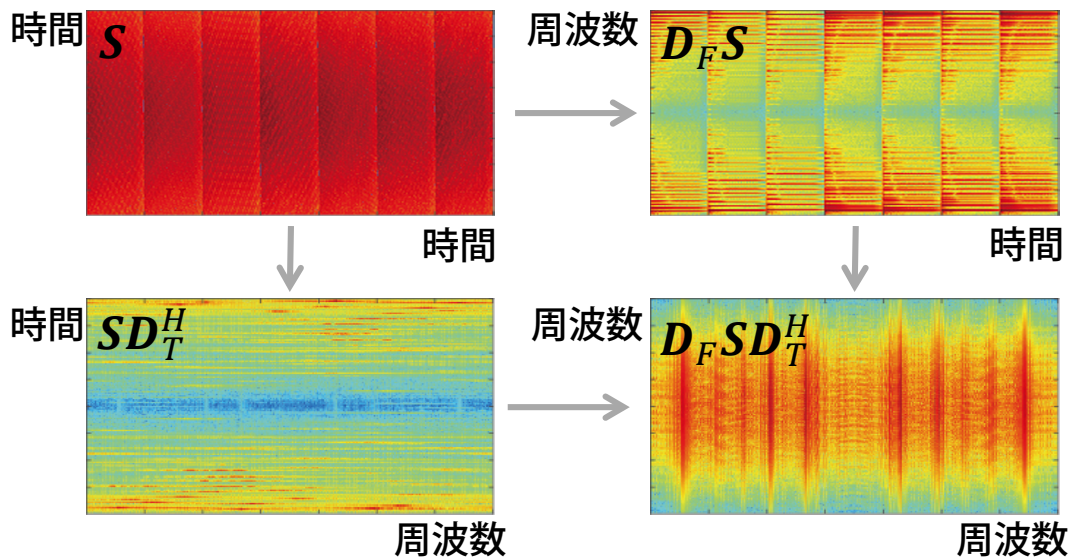


高速化の工夫3

- K 個の半正定値行列を同時対角化

- 変換後の空間ではIS-NMFと等価なので、極めて効率的

$$\underbrace{S \sim N_c \left(0, \sum_{k=1}^K V_k \otimes U_k \right)}_{\text{行列形式}} \xrightarrow{\text{空間変換}} ASB \sim N_c \left(0, \sum_{k=1}^K \underbrace{AV_k A^H}_{\text{対角行列}} \otimes \underbrace{B^H U_k B}_{\text{対角行列}} \right)$$



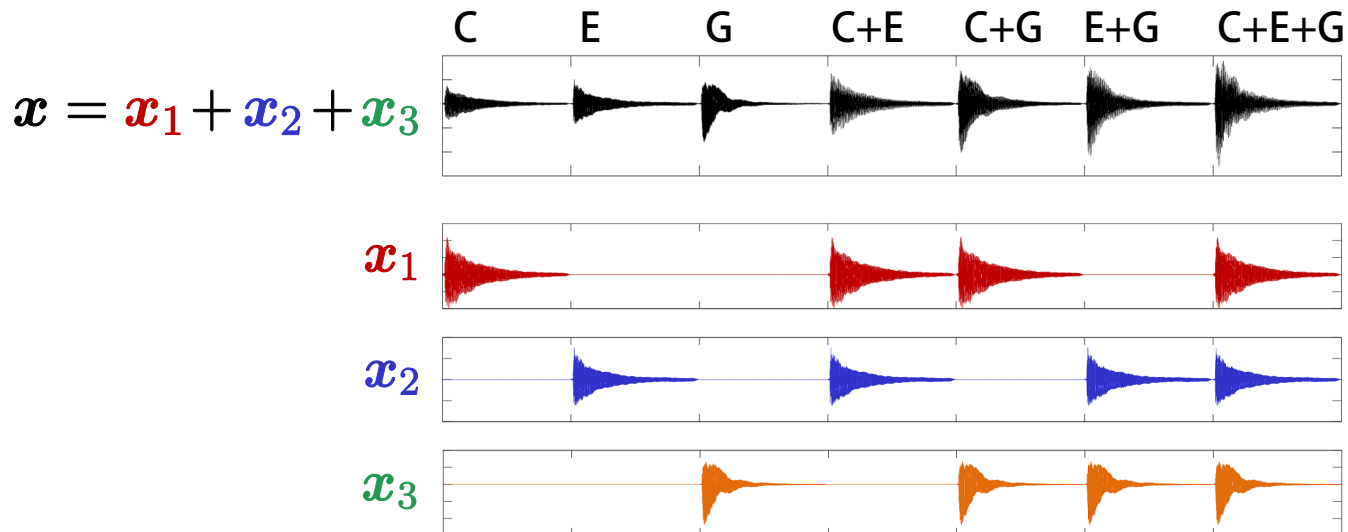
理論的にはフーリエ変換が理想
定常信号に対して無相関化できる



実際にはSTFTを使う
フレーム内で信号は非定常
+ 窓関数の影響により相関が発生
(LD-PSDTFで性能が向上する根拠)

評価実験

- 人工的に混合音を作成して基本的な音源分離性能を評価
 - 基底数は $K=3$ (C4, E4, G4に対応)
 - ブロック対角化行列による近似を検証
 - ピアノ音のMIDI信号を合成して作成
 - BSS Eval Toolbox [Vincent2006] を使用して評価



実験結果

- IS-NMFに比べて性能向上は確認
 - LD-PSDTF-FやLD-PSDTF-TはいずれもIS-NMFより高性能
 - LD-CTF@ブロック対角行列版はLD-PSDTFには及ばない
 - 局所的な時間-周波数領域内の相関だけでは不十分

	IS-NMF	LD-PSDTF-F	LD-PSDTF-T	LD-CTF		
ブロックサイズ (<i>F</i> 方向, <i>T</i> 方向)	(1, 1)	(256, 1)	(840, 1)	(128, 10)	(64, 20)	(32, 40)
SDR	18.88	21.58	21.04	19.68	20.60	20.21
SIR	24.14	27.01	24.67	25.29	26.17	25.45
SAR	20.45	23.14	23.50	21.47	21.47	22.15

まとめと今後の課題

- 時間-周波数平面上の相関を完全に考慮できるCTFを提案
 - NMF・PSDTFを拡張した究極の分解技法
 - 多変量複素ガウス分布に基づく最尤推定が可能
 - EMアルゴリズム
 - MMアルゴリズム：経験的にこちらのほうが高速
 - 計算量の削減が極めて重要な課題
 - ブロック対角行列による近似
 - 対角行列+低ランク行列による近似 (未検証)
 - 同時対角化+IS-NMFによる近似 (未検証)
- 今後の課題：既存手法のNMF部分をCTFに置き換え
 - 多変量 α 安定分布：任意の α で加法性が保証
 - von Neumann-CTFの導出 (KL-NMFの拡張)