

モノラル音響信号に対する 音源分離のための 無限半正定値テンソル分解

PSDTF


吉井 和佳¹⁾ 富岡 亮太²⁾
持橋 大地³⁾ 後藤 真孝¹⁾

- 1) 産業技術総合研究所 (AIST)
- 2) 東京大学
- 3) 統計数理研究所 (ISM)

NMFの“美しい”数学的拡張 PSDTFを発見した！


覚えて帰ってほしいこと

- 半正定値テンソル分解 (PSDTF)
 - 非負値行列分解 (NMF) の数学的に自然な拡張
 - 基底数の自動決定が可能
 - ノンパラメトリックベイズモデル
- Log-Determinant PSDTF (LD-PSDTF)
 - Itakura-Saito NMF (IS-NMF) の自然な拡張
 - 補助関数法に基づく反復最適化
 - 最尤推定：乗法更新則
 - ベイズ推定：変分ベイズ法
- モノラル音源分離への応用
 - NMFより優れた分離品質を達成
 - 計算量の削減が課題



研究の背景

- **モノラル音響信号の音源分離に関する研究がさかん**
 - 応用例：音楽信号の高度な加工
 - 歌声と伴奏の分離 [Rafii2011, Huang2012]
 - 楽器音イコライザ [吉井2006, 宮本2008, 糸山2008]
- **スペクトル領域で音源分離を行うのが一般的**
 - **位相を無視**すると音の特徴がとらえやすくなる
 - 調波構造・スパース性などに着目




非負値行列分解 (NMF)
に基づく手法が席卷

- 直感に合う
- 実装が簡単
- 高速に動作

非負値行列分解 (NMF)

- 「非負のベクトル」を少数の「非負のベクトル」の凸結合で表現




よく利用されるコスト関数：Bregmanダイバージェンス

$$\mathcal{D}_\phi(\mathbf{x}_n | \mathbf{y}_n) = \phi(\mathbf{x}_n) - \phi(\mathbf{y}_n) - \phi'(\mathbf{y}_n)^T (\mathbf{x}_n - \mathbf{y}_n)$$

研究の動機


- 音響信号とは何か、原点にたちかえって考えよう！
 - 非負スペクトログラムを出発点 → 不適切
 - 位相情報は重要
 - デジタル信号を出発点 → 不適切
 - 空気振動 (物理現象) は連続時間上に存在



アナログ信号を直接モデル化する方法はあるだろうか？

ガウス過程 (GP)

- 連続時間上の確率過程の一種
 - 例：白色雑音・ブラウン運動など
 - 連続関数 f に対する確率分布 $p(f)$




あらゆる信号波形の「もっともらしさ」を評価可能！

$$p(f_1) \quad p(f_2) \quad p(f_3)$$

ガウス過程はこわくない

- ガウス過程 \Leftrightarrow 無限次元のガウス分布

– 連続関数 f \Leftrightarrow 無限個の出力値 $\mathbf{x} = [x_1, x_2, \dots, x_\infty]^T$



- 任意の M 点の周辺分布はガウス分布!

$$f \begin{cases} \mathbf{t} = [t_1, t_2, \dots, t_M]^T \\ \mathbf{x} = [x_1, x_2, \dots, x_M]^T \end{cases} \quad \mathbf{x} \sim \mathcal{N}(\mathbf{0}, \mathbf{K})$$

カーネル行列
(半正定値)

単位行列カーネル


- 定常な白色雑音を生成

- 周辺分布 $\mathbf{x} \sim \mathcal{N}(\mathbf{0}, \mathbf{K})$

$$f \begin{cases} \mathbf{t} = [t_1, t_2, \dots, t_M]^T \\ \mathbf{x} = [x_1, x_2, \dots, x_M]^T \end{cases}$$

$$\mathbf{K} = \begin{matrix} & t_1 & & & t_M \\ t_1 & \color{red}{\blacksquare} & & & \\ & & \color{red}{\blacksquare} & & \\ & & & \color{red}{\blacksquare} & \\ & & & & \color{red}{\blacksquare} \\ t_M & & & & \color{red}{\blacksquare} \end{matrix}$$

単位行列であれば
各 x_m は独立







等間隔の離散的なサンプリング時刻を考える

ガウス関数型カーネル

- なめらかな連続関数を生成
 - 周辺分布 $\mathbf{x} \sim \mathcal{N}(\mathbf{0}, \mathbf{K})$

$$f \begin{cases} \mathbf{t} = [t_1, t_2, \dots, t_M]^T \\ \mathbf{x} = [x_1, x_2, \dots, x_M]^T \end{cases}$$







近傍間は相関が強い t
 → 滑らかな変化

周期カーネル

- 周期的な連続関数を生成
 - 周辺分布 $\boldsymbol{x} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{K})$


$$f \begin{cases} \boldsymbol{t} = [t_1, t_2, \dots, t_M]^T \\ \boldsymbol{x} = [x_1, x_2, \dots, x_M]^T \end{cases}$$



一定間隔で相関が強い t
→ 周期的な変化


音響信号に適用できるか？

- 混合音はガウス過程の重ね合わせ
 - 各音源信号は周期カーネルをもつガウス過程？




音響信号の生成と分離


- 順問題：ガウス変数の和 → ガウス変数





$$\boldsymbol{x}_1 \sim \mathcal{N}(\mathbf{0}, \mathbf{K}_1)$$



$$\boldsymbol{x}_2 \sim \mathcal{N}(\mathbf{0}, \mathbf{K}_2)$$



$$\boldsymbol{x}_3 \sim \mathcal{N}(\mathbf{0}, \mathbf{K}_3)$$




$$\boldsymbol{x} = \boldsymbol{x}_1 + \boldsymbol{x}_2 + \boldsymbol{x}_3$$

$$\sim \mathcal{N}(\mathbf{0}, \mathbf{K}_1 + \mathbf{K}_2 + \mathbf{K}_3)$$


$$\parallel$$

$$\mathbf{K}$$

- 逆問題：ガウス変数の分解 → ガウス変数




$$\boldsymbol{x}_1 \sim \mathcal{N}(\mathbf{0}, \mathbf{K}_1)$$



$$\boldsymbol{x}_2 \sim \mathcal{N}(\mathbf{0}, \mathbf{K}_2)$$



$$\boldsymbol{x}_3 \sim \mathcal{N}(\mathbf{0}, \mathbf{K}_3)$$



$$\boldsymbol{x} = \boldsymbol{x}_1 + \boldsymbol{x}_2 + \boldsymbol{x}_3$$

$$\sim \mathcal{N}(\mathbf{0}, \mathbf{K}_1 + \mathbf{K}_2 + \mathbf{K}_3)$$

$$\boldsymbol{x}_1 | \boldsymbol{x} \sim \mathcal{N}(\mathbf{K}_1 \mathbf{K}^{-1} \boldsymbol{x}, \mathbf{K}_1 - \mathbf{K}_1 \mathbf{K}^{-1} \mathbf{K}_1)$$


$$\boldsymbol{x}_2 | \boldsymbol{x} \sim \mathcal{N}(\mathbf{K}_2 \mathbf{K}^{-1} \boldsymbol{x}, \mathbf{K}_2 - \mathbf{K}_2 \mathbf{K}^{-1} \mathbf{K}_2)$$

$$\boldsymbol{x}_3 | \boldsymbol{x} \sim \mathcal{N}(\mathbf{K}_3 \mathbf{K}^{-1} \boldsymbol{x}, \mathbf{K}_3 - \mathbf{K}_3 \mathbf{K}^{-1} \mathbf{K}_3)$$

カーネルさえ求まれば
ウィナーフィルタで
音源分離が可能！

ここで問題


- 観測信号だけからどうやってカーネルを求めるか？
 - カーネルの種類すら不明



音楽信号の「非定常性」に着目する！

非定常な楽器音のモデル

- 非定常 = 時刻によって各種統計量 (例えば分散) が変化




$$\phi_{kn} \sim \mathcal{N}(\mathbf{0}, \mathbf{V}_k) \longrightarrow \mathbf{x}_{kn} \sim \mathcal{N}(\mathbf{0}, h_{kn} \mathbf{V}_k)$$

定常 $\rightarrow n$ に依存しない

≥ 0 $\succeq 0$
非負 半正定

混合音の確率モデル

- ガウス変数 (局所信号) の足し合わせはガウス変数



$$\left. \begin{aligned}
 \boldsymbol{x}_{1n} &\sim \mathcal{N}(\mathbf{0}, h_{1n} \mathbf{V}_1) \\
 \boldsymbol{x}_{2n} &\sim \mathcal{N}(\mathbf{0}, h_{2n} \mathbf{V}_2) \\
 \boldsymbol{x}_{3n} &\sim \mathcal{N}(\mathbf{0}, h_{3n} \mathbf{V}_3)
 \end{aligned} \right\} \longrightarrow \boldsymbol{x}_n \sim \mathcal{N} \left(\mathbf{0}, \sum_{k=1}^K h_{kn} \mathbf{V}_k \right)$$


時変スケール×カーネル

半正定 $\succeq 0$

非負 ≥ 0

最尤推定

- 対数尤度を最大化するパラメータ H, V を求めたい



$$\mathbf{x}_n \sim \mathcal{N} \left(\mathbf{0}, \sum_{k=1}^K h_{kn} \mathbf{V}_k \right) \longrightarrow \text{最大化}$$

半正定値行列

$$\mathbf{X}_n = \mathbf{x}_n \mathbf{x}_n^T$$

$$\mathbf{Y}_n = \sum_{k=1}^K h_{kn} \mathbf{V}_k \quad \text{と定義}$$

半正定値行列

ガウス変数の対数尤度

$$\log p(\mathbf{X}_n | \mathbf{Y}_n) \stackrel{c}{=} -\frac{1}{2} \log |\mathbf{Y}_n| - \frac{1}{2} \text{tr}(\mathbf{X}_n \mathbf{Y}_n^{-1}) \longrightarrow \text{最大化}$$


⇕ 等価!

Log-Detダイバージェンス

$$\mathcal{D}_{\text{LD}}(\mathbf{X}_n | \mathbf{Y}_n) = -\log |\mathbf{X}_n \mathbf{Y}_n^{-1}| + \text{tr}(\mathbf{X}_n \mathbf{Y}_n^{-1}) - M \longrightarrow \text{最小化}$$

半正定値テンソル分解

- 「半正定値行列」を少数の「半正定値行列」の凸結合で表現



NMF と PSDTF

• 非負値行列分解 (NMF)

– 非負ベクトルを非負ベクトルの和に分解

$$\mathbf{x}_n \approx \mathbf{y}_n = \sum_{k=1}^K h_{kn} \mathbf{w}_k$$

– Bregman ダイバージェンス

• カルバック・ライブラ (KL) ダイバージェンス

$$\mathcal{D}_{\text{KL}}(\mathbf{x}_n | \mathbf{y}_n) = \sum_m (x_{mn} \log x_{mn} y_{mn}^{-1} - x_{mn} + y_{mn})$$

• 板倉・齋藤 (IS) ダイバージェンス

$$\mathcal{D}_{\text{IS}}(\mathbf{x}_n | \mathbf{y}_n) = \sum_m (-\log x_{mn} y_{mn}^{-1} + x_{mn} y_{mn}^{-1} - 1)$$

• 半正定値テンソル分解 (PSDTF)

– 半正定値行列を半正定値行列の和に分解

$$\mathbf{X}_n \approx \mathbf{Y}_n = \sum_{k=1}^K h_{kn} \mathbf{V}_k$$

– Bregman “行列” ダイバージェンス

• フォン・ノイマン (vN) ダイバージェンス

$$\mathcal{D}_{\text{vN}}(\mathbf{X}_n | \mathbf{Y}_n) = \text{tr} (\mathbf{X}_n \log \mathbf{X}_n \mathbf{Y}_n^{-1} - \mathbf{X}_n + \mathbf{Y}_n)$$

• Log-Det (LD) ダイバージェンス

$$\mathcal{D}_{\text{LD}}(\mathbf{X}_n | \mathbf{Y}_n) = -\log |\mathbf{X}_n \mathbf{Y}_n^{-1}| + \text{tr} (\mathbf{X}_n \mathbf{Y}_n^{-1}) - M$$

半正定性

- 実対称行列 $A = A^T$ が半正定

⇔ すべての固有値が非負

⇔ $A = X X^T$ をみたす実行列 X が存在

任意の実数の
二乗は常に非負

- 複素エルミート行列 $A = A^H$ が半正定

⇔ すべての固有値が非負

⇔ $A = X X^H$ をみたす複素行列 X が存在

共役な複素数の
積は常に非負


「行列の半正定性」は「スカラ/ベクトルの非負性」の拡張概念！

非負値 + 非負値 = 非負値
半正定値行列 + 半正定値行列 = 半正定値行列

非負値 - 非負値 ≠ 非負値
半正定値行列 - 半正定値行列 ≠ 半正定値行列

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)
 - RWC研究用音楽データベースから3種類の楽器の単独音を使用
 - ピアノ・エレキギター (減衰音) / クラリネット (持続音)
 - BSS Eval Toolbox [Vincent2006] を使用して評価



音源分離結果

- KL-NMF や IS-NMF より優れた音源分離品質を達成

– 課題：計算量の削減・複雑な信号への適用



	正解			
ピアノ	KL-NMF			
	IS-NMF			
	LD-PSDTF			
	正解			
エレキ	KL-NMF			
	IS-NMF			
	LD-PSDTF			
	正解			
クラ	KL-NMF			
	IS-NMF			
	LD-PSDTF			


■ KL-NMF
■ IS-NMF
■ LD-PSDTF (提案法)

NMFの“美しい”数学的拡張 PSDTFを発見した！

まとめと今後の課題

- 半正定値テンソル分解 (PSDTF)
 - 非負値行列分解 (NMF) の数学的に自然な拡張
 - 基底数の自動決定が可能
 - ノンパラメトリックベイズモデル
- Log-Determinant PSDTF (LD-PSDTF)
 - Itakura-Saito NMF (IS-NMF) の自然な拡張
 - 補助関数法に基づく反復最適化
- モノラル音源分離への応用
 - NMFより優れた分離品質を達成
 - 計算量の削減が課題


- NMFに基づくすべての手法が改善する可能性！
 - 他のコスト関数を用いたPSDTFの開発



PSDTFの計算量

- 窓幅 M フレーム数 N 基底数 $K \rightarrow$ 計算量 $O(M^3 NK)$

– NMFは $O(MNK)$



$$\left. \begin{aligned} \boldsymbol{x}_{1n} &\sim \mathcal{N}(\mathbf{0}, h_{1n} \mathbf{V}_1) \\ \boldsymbol{x}_{2n} &\sim \mathcal{N}(\mathbf{0}, h_{2n} \mathbf{V}_2) \\ \boldsymbol{x}_{3n} &\sim \mathcal{N}(\mathbf{0}, h_{3n} \mathbf{V}_3) \end{aligned} \right\} \rightarrow \boldsymbol{x}_n \sim \mathcal{N}\left(\mathbf{0}, \sum_{k=1}^K h_{kn} \mathbf{V}_k\right)$$

時変スケール×カーネル

サイズ M の行列の基本演算に $O(M^3)$

計算量削減：低ランク近似すれば $O(R^2 M)$

計算量削減&局所解回避：NMFである程度最適化してからPSDTFに移行

PSDTFの最適化技法

- 補助関数法に基づく乗法更新アルゴリズム
 - もとのパラメータと補助パラメータとを反復更新

Log-Detダイバージェンス

$$\mathcal{D}_{\text{LD}}(\mathbf{X}_n | \mathbf{Y}_n) = -\log |\mathbf{X}_n \mathbf{Y}_n^{-1}| + \text{tr}(\mathbf{X}_n \mathbf{Y}_n^{-1}) - M \longrightarrow \text{最小化}$$

任意の半正定値行列 \mathbf{X} に対して

$$\log |\mathbf{X}| \leq \log |\mathbf{\Omega}| + \text{tr}(\mathbf{\Omega}^{-1} \mathbf{X}) - M$$

任意の半正定値行列 \mathbf{X}, \mathbf{Y} に対して

$$\text{tr} \left(\left(\sum_{k=1}^K \mathbf{X}_k \right)^{-1} \mathbf{Y} \right) \leq \sum_{k=1}^K \text{tr}(\mathbf{X}_k^{-1} \mathbf{\Phi}_k \mathbf{Y} \mathbf{\Phi}_k^T)$$

$$\begin{cases} \mathbf{X}_n = \mathbf{x}_n \mathbf{x}_n^T \\ \mathbf{Y}_n = \sum_{k=1}^K h_{kn} \mathbf{V}_k \end{cases}$$

$$\begin{aligned} \mathcal{D}_{\text{LD}}(\mathbf{X}_n | \mathbf{Y}_n) &\stackrel{c}{=} \log |\mathbf{Y}_n| + \text{tr}(\mathbf{X}_n \mathbf{Y}_n^{-1}) \\ &\leq \log |\mathbf{\Omega}_n| + \text{tr}(\mathbf{Y}_n \mathbf{\Omega}_n^{-1}) - M + \sum_{k=1}^K \text{tr}(\mathbf{Y}_{kn}^{-1} \mathbf{\Phi}_{kn} \mathbf{X}_n \mathbf{\Phi}_{kn}^T) \\ &\longrightarrow \text{最小化} \end{aligned}$$

PSDTFの無限化

- ガンマ過程 (GaP) を用いると可算無限個の基底数を考慮可能
 - 「半正定値行列」を無限個の「半正定値行列」の凸結合に分解
 - 観測データに合わせて一部の基底のみが使われる

$$\mathbf{X}_n \approx \mathbf{Y}_n = \sum_{k=1}^{K \rightarrow \infty} \theta_k h_{kn} \mathbf{V}_k$$

重みパラメータを導入！

無限次元の
非負ベクトル

$\theta \sim \text{GaP}(\alpha)$ ガンマ過程事前分布

