

多重音基本周波数解析のための 無限重畳離散全極型モデル

吉井 和佳 糸山 克寿 (京大)

後藤 真孝 (産総研)

研究の背景


- 音楽音響信号の分解・再構成技術が望まれる

- 音楽鑑賞の楽しみ方を広げたい

- 調波音・打楽器音分離 [宮本2008, Rigaud2011]
- 楽器音イコライザ [糸山2008, 中村2014]

- 音楽制作の楽しみ方を広げたい

- マッシュアップ・二次創作
- 既存楽曲を構成する「パーツ」の組み合わせ




想定する応用

- Songle: 能動的音楽鑑賞用WEBサービス
 - 音楽音響信号の自動解析結果を表示
 - 誤り訂正も可能 → システムが賢くなる



ビート・コード・メロディ・繰り返し構造の自動解析が可能




今はメロディ(歌唱)の音高だけが解析対象

↓
全楽器パートが解析できるように拡張したい


統計的音楽音響信号処理

- 音楽音響信号の**生成モデル**に基づくアプローチ
 - 順問題：生成モデル → 音楽音響信号
 - 逆問題：音楽音響信号 → 生成モデル
- 様々な**生成モデル**を確率的に統合可能
 - 非負値行列分解 (NMF)
 - 音楽音響信号のパーツ分解 [Smaragdís 2003]
 - 線形予測分析 (LPC) / 自己回帰過程 (AR)
 - 音声信号のスペクトル包絡推定 [Itakura 1967]
 - 複合自己回帰モデル (CAR)
 - NMFとLPCの組み合わせ [Kameoka 2009, Yoshii 2012]




非負値行列分解 (NMF)

- 音源分離/自動採譜のための強力なアプローチ
 - 振幅スペクトログラムを**基底**と音量とに分解 [Smaragdakis 2003]




観測 X と再構成 $WH = Y$ との距離を
最小化するように W と H を学習



NMFの問題点

- 観測スペクトログラムが異なる音高ごとに分離される
 - 本当は「音高」ではなく「音色」で分離したい (楽器パート分離)
 - スペクトル基底を音色ごとにクラスタリングするのは難しい




音楽音響信号を構成する「パーツ」とは何かについて再考が必要

楽器音スペクトル


- 短時間フーリエ変換 (STFT) による周波数解析

楽器音 (F4/ピアノ) のスペクトログラム




楽器音の生成モデル

- ・ ソース・フィルタ理論に基づくモデル化
 - 楽器音スペクトル = 調波構造 + 包絡構造



調波構造(音高)が同じ


包絡構造(音色)が違う



多重音の生成モデル

- 音楽音響信号を「パーツ」の組み合わせで表現
 - 楽器音：2種類の要素「音高」と「音色」の組み合わせで構成

音高 (ソース)




音色 (フィルタ)



様々な楽器音
パーツを生成




重ね合わせ



混合音


複合自己回帰モデル (CAR)

- 多重音をソースとフィルタの組み合わせで表現 [Kameoka 2009]
 - 無限個のソースとフィルタを仮定する拡張も可能 [Yoshii 2012]



楽器音の生成モデル

- 楽器信号が自己回帰 (AR) 過程に従うと仮定
 - 線形予測分析：過去のサンプルの線形結合で次のサンプルを予測



$$x_m = \sum_{p=1}^P \hat{a}_p x_{m-p} + s_m$$

観測信号 予測係数 予測誤差


ソース・フィルタ理論の
観点では音源信号に対応

楽器音の生成モデル

- 楽器音スペクトル生成モデルのフーリエ領域表現
 - 時間領域での畳み込み → フーリエ領域での要素積

$$x_m = \sum_{p=1}^P \hat{a}_p x_{m-p} + s_m \rightarrow s_m = \sum_{p=0}^P a_p x_{m-p}$$

観測信号 予測係数 音源信号




線形予測分析 (LPC)

- 観測スペクトル $\{X_m\}_{m=1}^M$ からスペクトル包絡 $\{F_m\}_{m=1}^M$ を推定
 - 音源信号にガウス性白色雑音を仮定 (パワースペクトルは指数分布)
 - 生成モデルの最尤推定としての解釈 [Itakura 1967]

$$X_m = S_m F_m$$


$$S_m \sim \text{Exponential}(\sigma^2)$$

$$\longrightarrow X_m \sim \text{Exponential}(\sigma^2 F_m)$$



LPCの問題点

- 音源信号にガウス性白色雑音を仮定 $X_m = S_m F_m$
 - 音源スペクトル $\{S_m\}_{m=1}^M$ 自体を緻密にモデル化したい
- 全周波数帯域の利用
 - 調波構造のピークだけでスペクトル包絡を推定したい
- 線形周波数領域での定式化
 - 人間の聴覚特性に合致した対数周波数領域で定式化したい




離散全極型モデル (DAP)

- LPCを改良したスペクトル包絡推定法 [El-Jaroudi 1991]
 - 利点：調波構造ピークのみを考慮 / 対数周波数領域に適用可能
 - 欠点：音源信号に対する基本周波数推定が必要

$$X_m \sim \text{Exponential}(\sigma^2 F_m) \quad m \in \Omega$$


考慮すべき
周波数ビンの集合




提案するアプローチ

- 複合自己回帰モデル + 離散全極型モデル
 - 確率的な枠組みのもとで統一的な確率モデルを定式化

	複合自己回帰モデル (CAR)	離散全極型モデル (DAP)
多重音の 取り扱い	複数のソース・フィルタ に分解可能	×
音源信号の 取り扱い	音源スペクトル自体を 推定可能 (基本周波数も推定可能)	×
対数周波数の 取り扱い	×	周波数軸によらず に定式化可能




確率的に統合




複合自己回帰モデル (CAR)

- 線形周波数領域で定式化されたソース・フィルタNMF
 - 無限個のソースとフィルタを仮定する拡張も可能 (iCAR)




重畳離散全極型モデル (SDAP)

- 対数周波数領域で定式化されたソース・フィルタNMF
 - 無限個のソースとフィルタを仮定する拡張も可能 (iSDAP)




iCARの確率モデル

- NMFの拡張：ソース・フィルタモデル + 無限モデル



iSDAPの確率モデル

- iCARと同じ形式：ソース・フィルタモデルの改良




線形予測分析 (LPC)
→ 離散全極型モデル (DAP)

$$X_{mn} \sim \text{Poisson} \left(\sum_{i=1}^{I \rightarrow \infty} \sum_{j=1}^{J \rightarrow \infty} \theta_i \phi_j W_{ijm} H_{ijn} \right)$$

スペクトル基底のモデル

- スペクトル基底に対する離散全極型モデル (DAP)
 - 各倍音成分の重みをスペクトル包絡で決定



$$W_{ijm} = \sum_{r=1}^R S_{irm} F_{ijr} \begin{cases} S_{irm} = e^{-\frac{1}{2\sigma^2}(f_m - (\mu_i + 1200 \log_2 r))^2} & \text{ガウス関数 (倍音成分)} \\ F_{ijr} = \frac{1}{\left| \sum_{p=0}^P a_{jp} e^{-\omega_{ir} p i} \right|} & \text{全極型関数 (倍音の重み)} \end{cases}$$

ベイズ的取り扱い

- ノンパラメトリックベイズモデルの定式化

ポアソン尤度

$$X_{mn} \sim \text{Poisson} \left(\sum_{i=1}^{I \rightarrow \infty} \sum_{j=1}^{J \rightarrow \infty} \theta_i \phi_j W_{ijm} H_{ijn} \right)$$

モデルの学習

変分ベイズ法 (VB)
+
乗法更新 (MU)

ガウス関数 (倍音スペクトル)

$$S_{irm} = e^{-\frac{1}{2\sigma^2}(f_m - (\mu_i + 1200 \log_2 r))^2}$$

全極型関数 (倍音の重み)

$$F_{ijr} = \frac{1}{\left| \sum_{p=0}^P a_{jp} e^{-\omega_{ir} p i} \right|}$$

ガンマ過程事前分布



$$\theta_i \sim \text{GaP}(a_\theta, \mathbf{1})$$

$$\phi_j \sim \text{GaP}(a_\phi, \mathbf{1})$$

ガンマ事前分布


$$H_{nij} \sim \text{Gamma}(a_H, b_H)$$

実験結果



フィルタの推定結果


- 調波構造に対してもなめらかなスペクトル包絡が推定可能
 - データから倍音の減衰比率が学習可能
 - 従来法(PreFEst, HTC)では倍音の相対強度に対する事前分布が必要



まとめと今後の課題

- 無限重畳離散全極型モデル (iSDAP) を提案
 - 確率的な枠組みのもとで2つの確率モデルを統合

	複合自己回帰モデル (CAR)	離散全極型モデル (DAP)
多重音の取り扱い	複数のソース・フィルタに分解可能	×
音源信号の取り扱い	音源スペクトル自体を推定可能 (基本周波数も推定可能)	×
対数周波数の取り扱い	×	周波数軸によらずに定式化可能



- ### 今後の課題
- 打楽器音の取り扱い
 - 楽譜情報に相当する事前分布を導入