

# 多重音基本周波数解析のための 無限潜在的調波配分法

吉井 和佳 後藤 真孝  
産業技術総合研究所  
k.yoshii@aist.go.jp

# 研究の意義

不確実性のベイズ的取り扱い

# 研究の背景

- 基本周波数解析は重要な基礎技術
  - 自動採譜・音源分離・歌手識別・楽器識別
  - 歌詞認識・歌詞アラインメント
- 行列分解手法の利用が一般的
  - 非負値行列因子分解 (NMF)
    - 因子モデル (Factorial Model)
    - 実装が簡単で高速に動作
  - 確率的潜在コンポーネント分析 (PLCA)
    - 混合モデル (Mixture Model)
    - トピックモデルの音源分離への適用
    - スペクトルを「粒子」に分解する必要あり

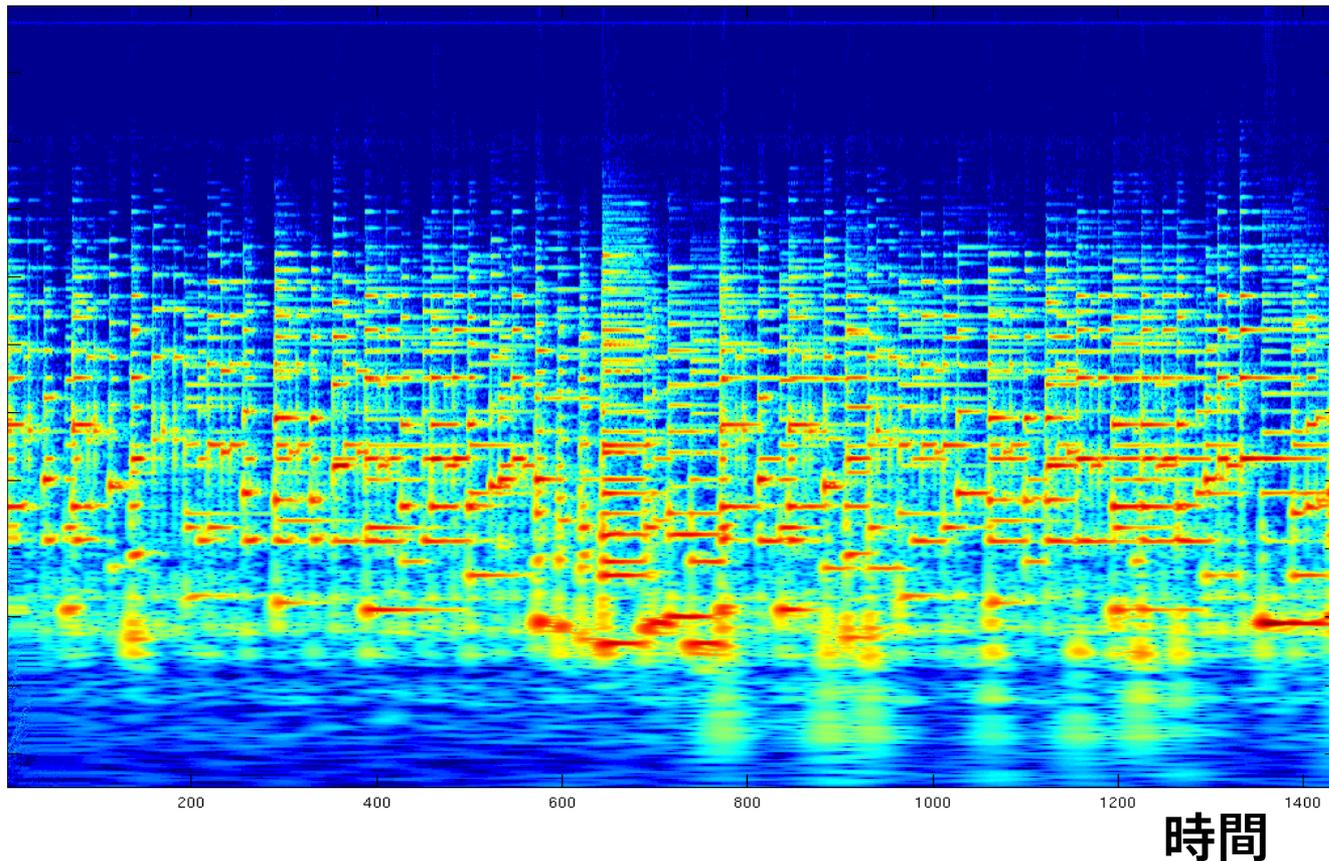
基底に分解後、それぞれに対してF0を後から推定

→ モデル自体にF0パラメータが入っている方がよい！

# 複数基本周波数解析の難しさ

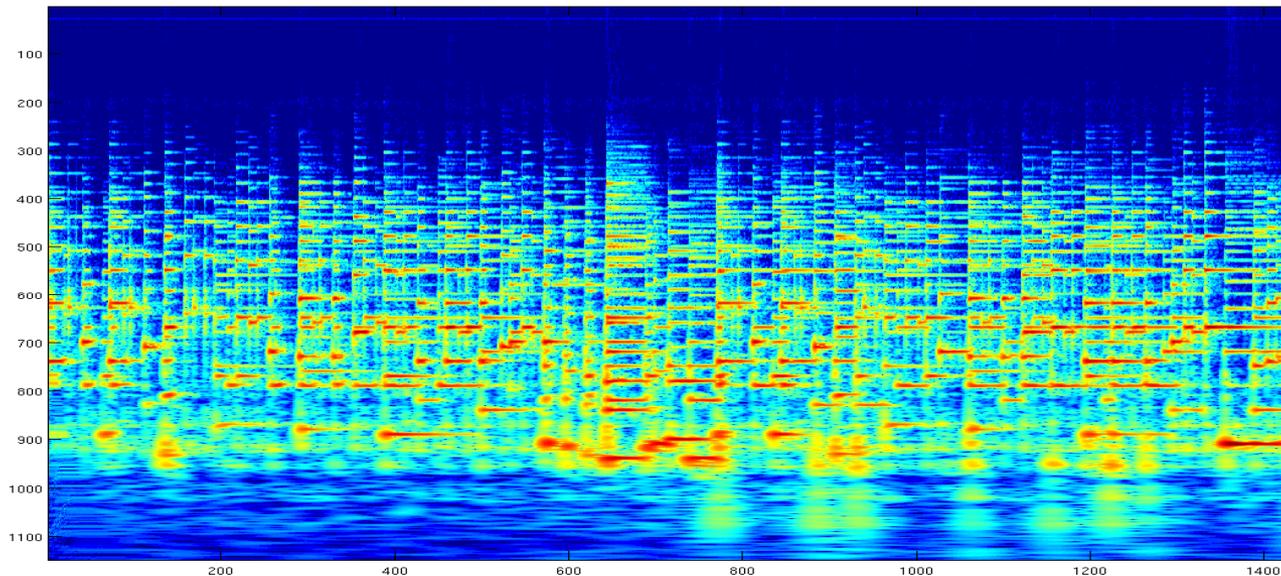
- 倍音が豊富に含まれていてそれらが重畳
  - 混合音声と異なり周波数領域でのスパース性が弱い
  - 基底の形状 (調波構造) に関するパラメトリックな表現が望まれる

周波数



# 処理すべきデータ量

- 音楽音響信号処理は非常に重い！
  - 典型的な周波数解析の設定
    - 10 [ms]シフト = 5分の楽曲で 30,000フレーム
    - 2048点FFT = 1フレーム当たり 1,024個のデータ
  - **1曲の持つデータ量 = 3000万サンプル！**
    - 並列分散処理がしやすいEMが好まれる傾向あり

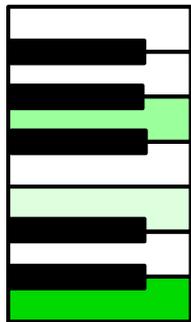


# 研究の動機

- 不確実性 (Uncertainty) を適切に取り扱いたい
  - 音楽解析において必然的に表れる性質



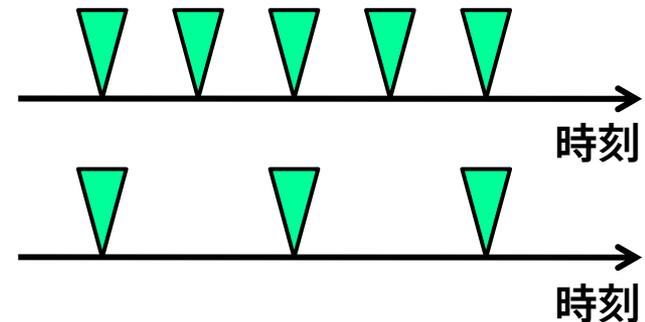
例：基本周波数推定



- ← まずまず自信あり
- ← あまり自信がない
- ← 存在を確信！

楽器音が複雑に重なり合うと  
解釈の正しさを確信できない

例：ビートトラッキング



テンポ知覚に曖昧性があると  
解釈を一意に決めかねる

未知事象の不確実性を表現して伝播させる方法論が必要

# 「完全な」ベイズ的取り扱い

- 観測データ以外はすべて未知：不確実性が存在
  - パラメータ
    - 基本周波数の値は？
  - 確率モデルの複雑さ
    - いくつかの音源・倍音(混合数)が含まれているのか？
  - 超パラメータ
    - 上記に対する事前分布のパラメータの設定方法は？

未知事象の不確実性を表現して伝播させる方法論が必要

	パラメータ	複雑さ	超パラメータ	頑健性
最尤推定	一意に決定	手動で設定	不使用	×
MAP推定	一意に決定	手動で設定	手動で設定	△
古典的なベイズ推定	事後分布を推定	手動で設定	手動で設定	○
ノンパラメトリックベイズ	事後分布を推定	事後分布を推定	(手動で設定)	◎
階層ベイズモデル	事後分布を推定	(手動で設定)	事後分布を推定	◎

階層ノンパラメトリックベイズモデルは何も一意に決定しない！

# 研究の概要

階層ノンパラメトリックベイズモデル

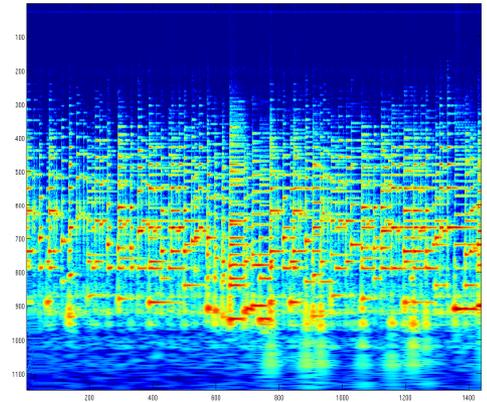
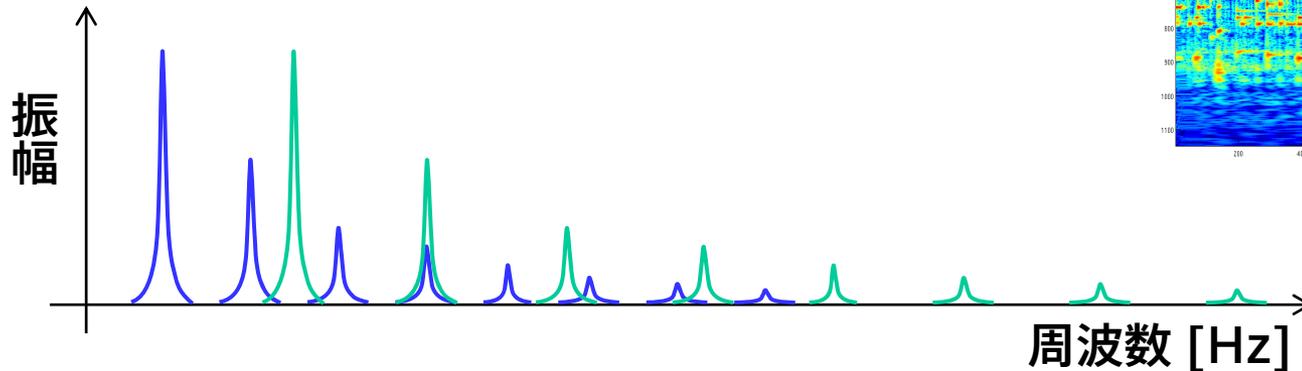
# 本研究の概要

- **問題**：多重音中の複数の基本周波数の推定
  - 調波構造を持たない音(ドラム音など)は対象外
  - 音源数は未知
  - 倍音数は未知
- **手法**：現代的な統計的機械学習
  - 階層ノンパラメトリックベイズモデル
- **成果**：完全自動化・高い推定精度を達成
  - 人手で最適化した従来手法と同程度

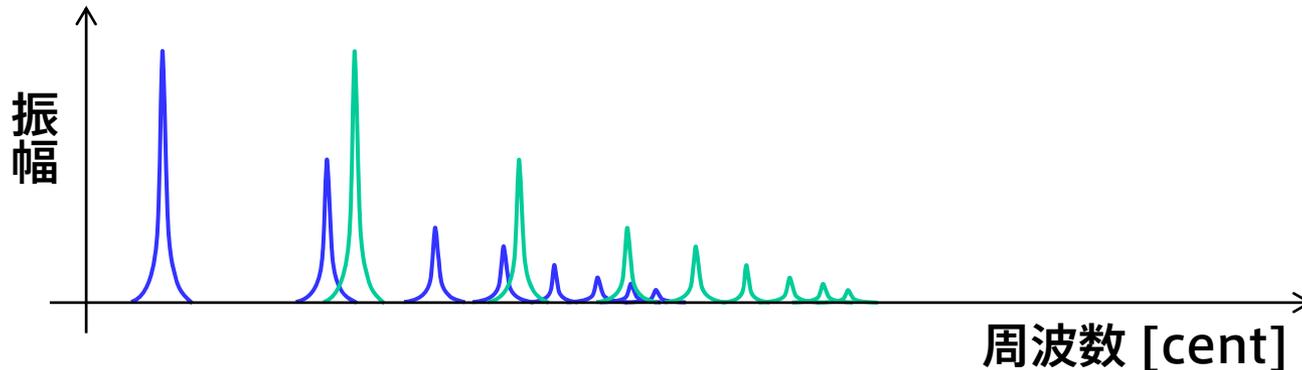
# 調波構造

- 基本周波数 ( $F_0$ ) の整数倍にピークを持つ
  - 線形周波数軸だと調波構造は伸縮
  - 対数周波数軸だと調波構造は**平行移動**

フーリエ変換によるスペクトル

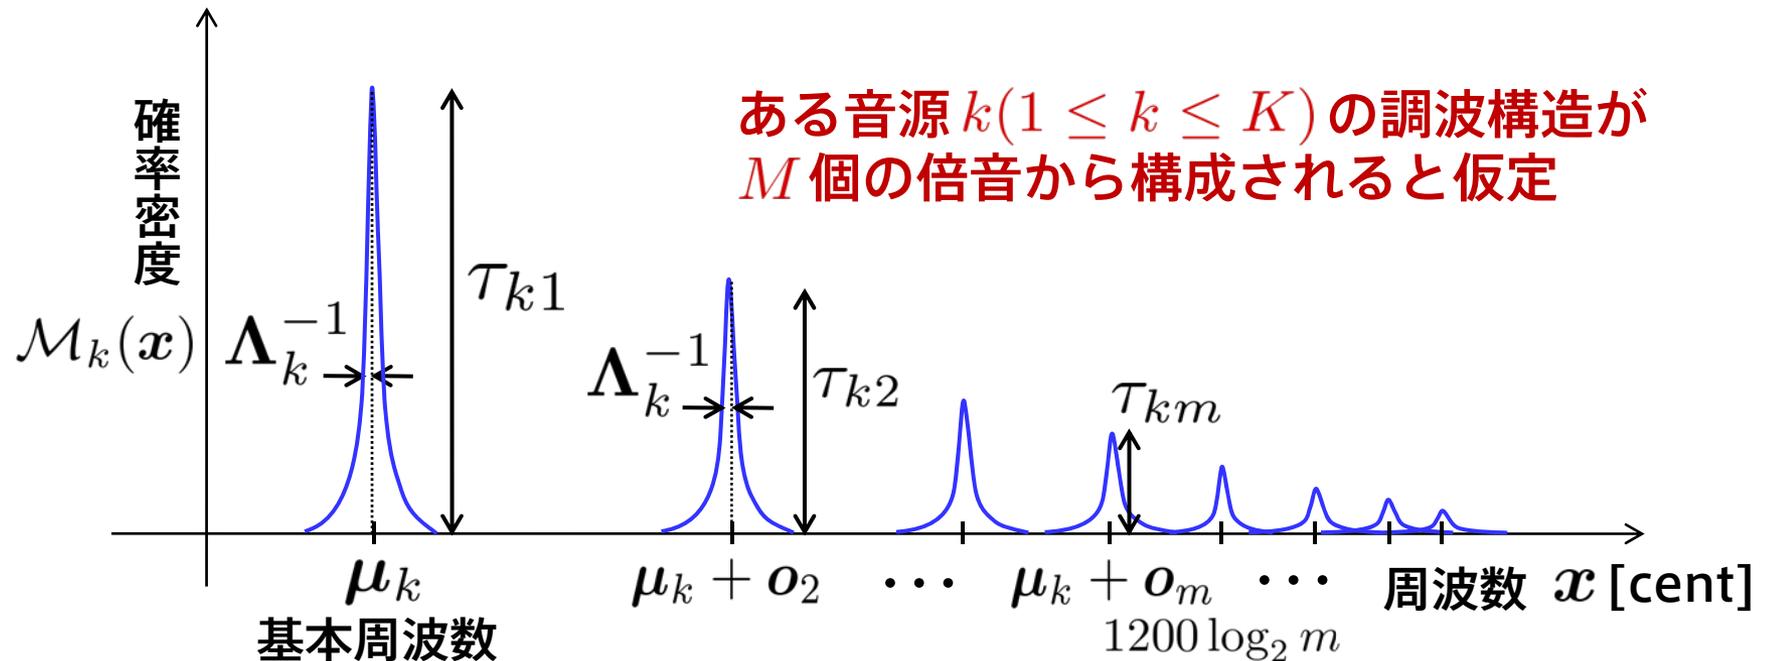


ウェーブレット変換によるスペクトル



# 単一音源に対する確率分布

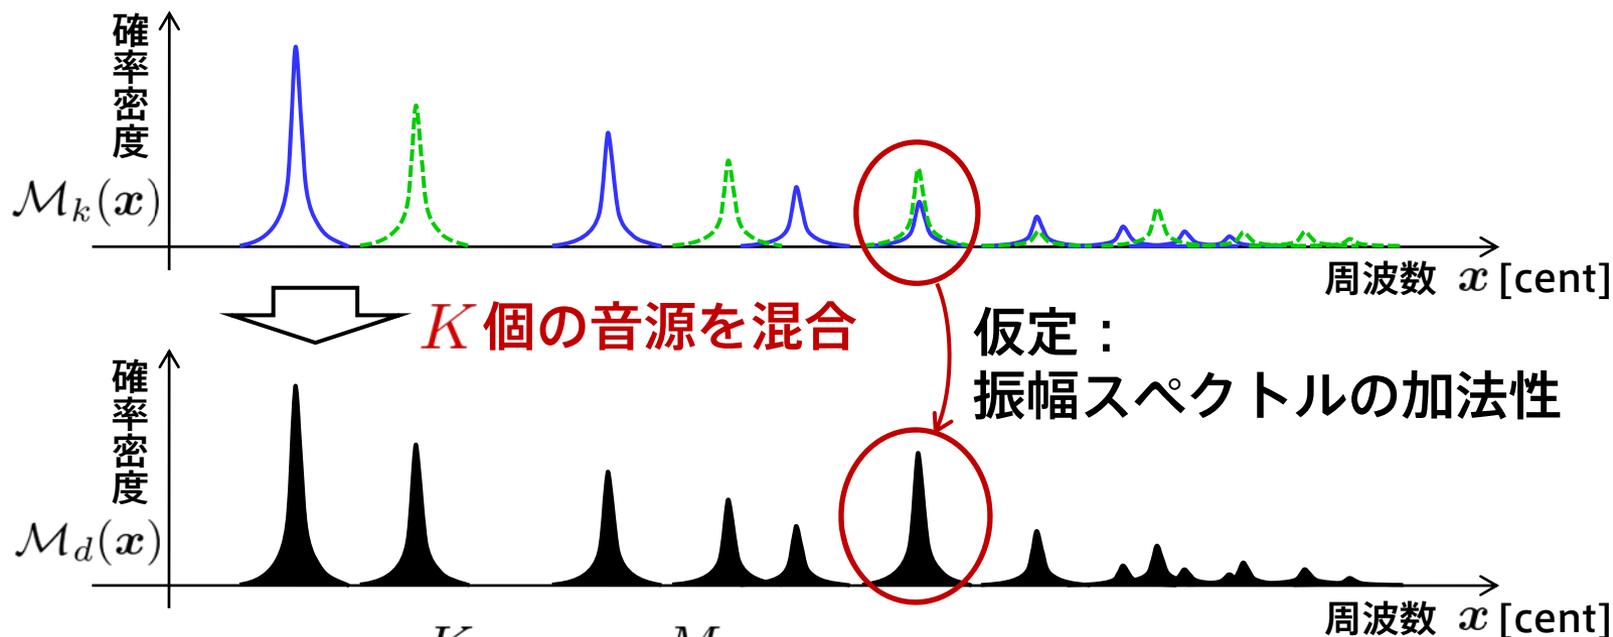
- 音源の調波構造を有限混合ガウス分布で表現
  - PreFEst [後藤1999,2004]
  - Harmonic Clustering [亀岡ら2004]



$$\mathcal{M}_k(\boldsymbol{x}) = \sum_{m=1}^M \tau_{km} \mathcal{N}(\boldsymbol{x} | \mu_k + o_m, \Lambda_k^{-1})$$

# 複数音源に対する確率分布

- 音源の重畳を**ネスト型**有限混合ガウス分布で表現
  - 単一音源に対する混合ガウス分布を混合する



$$\mathcal{M}_d(\boldsymbol{x}) = \sum_{k=1}^K \pi_{dk} \sum_{m=1}^M \tau_{km} \mathcal{N}(\boldsymbol{x} | \boldsymbol{\mu}_k + \boldsymbol{o}_m, \boldsymbol{\Lambda}_k^{-1})$$

フレーム  $d$  における  
音源  $k$  の混合比

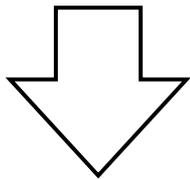
音源  $k$  における  
倍音  $m$  の混合比

# 本研究のポイント(1)

- 音源の重畳をネスト型無限混合ガウス分布で表現
  - 音源数  $K$ ・倍音数  $M$  を無限大に発散 = 森羅万象
  - 観測データは森羅万象のほんの一部という考え方

ネスト型有限混合ガウス分布

$$\mathcal{M}_d(\mathbf{x}) = \sum_{k=1}^K \pi_{dk} \sum_{m=1}^M \tau_{km} \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k + \mathbf{o}_m, \boldsymbol{\Lambda}_k^{-1})$$



フレーム  $d$  における  
音源  $k$  の混合比

音源  $k$  における  
倍音  $m$  の混合比

ネスト型無限混合ガウス分布

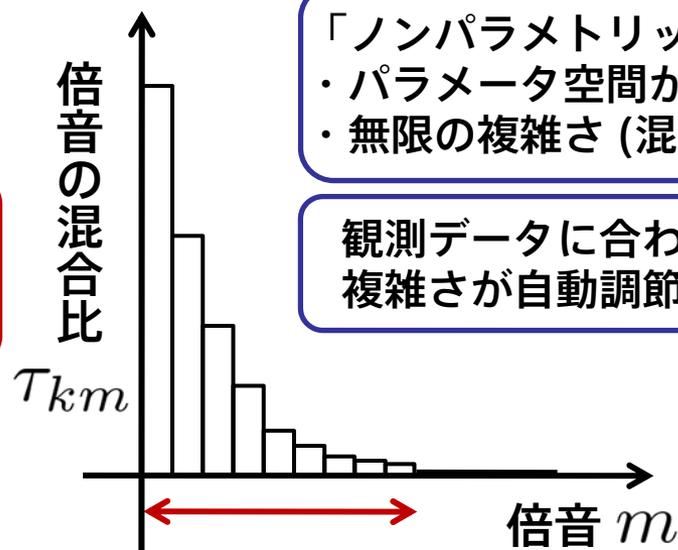
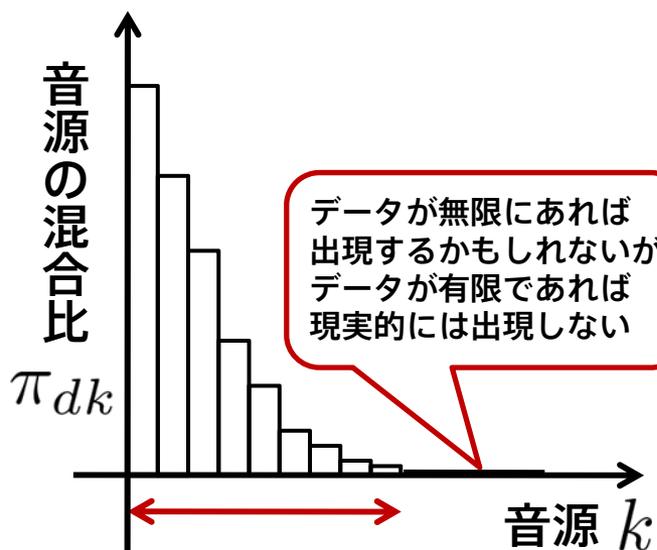
$$\mathcal{M}_d(\mathbf{x}) = \sum_{k=1}^{\infty} \pi_{dk} \sum_{m=1}^{\infty} \tau_{km} \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k + \mathbf{o}_m, \boldsymbol{\Lambda}_k^{-1})$$

無限個の音源・倍音があるにせよ、有限の観測データ中に現れるのは「現実的には」高々有限個の音源・倍音だけではないのか？

# ノンパラメトリックベイズ

- 適切な事前分布を導入してスパースな解に誘導
  - 無限個ある混合比が満たして欲しい性質
    - ごく一部(有限個)がある程度以上大きい
    - その他(無限個)は極めて小さい(ほぼゼロ)

$$\mathcal{M}_d(\mathbf{x}) = \sum_{k=1}^{\infty} \pi_{dk} \sum_{m=1}^{\infty} \tau_{km} \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k + \mathbf{o}_m, \boldsymbol{\Lambda}_k^{-1})$$

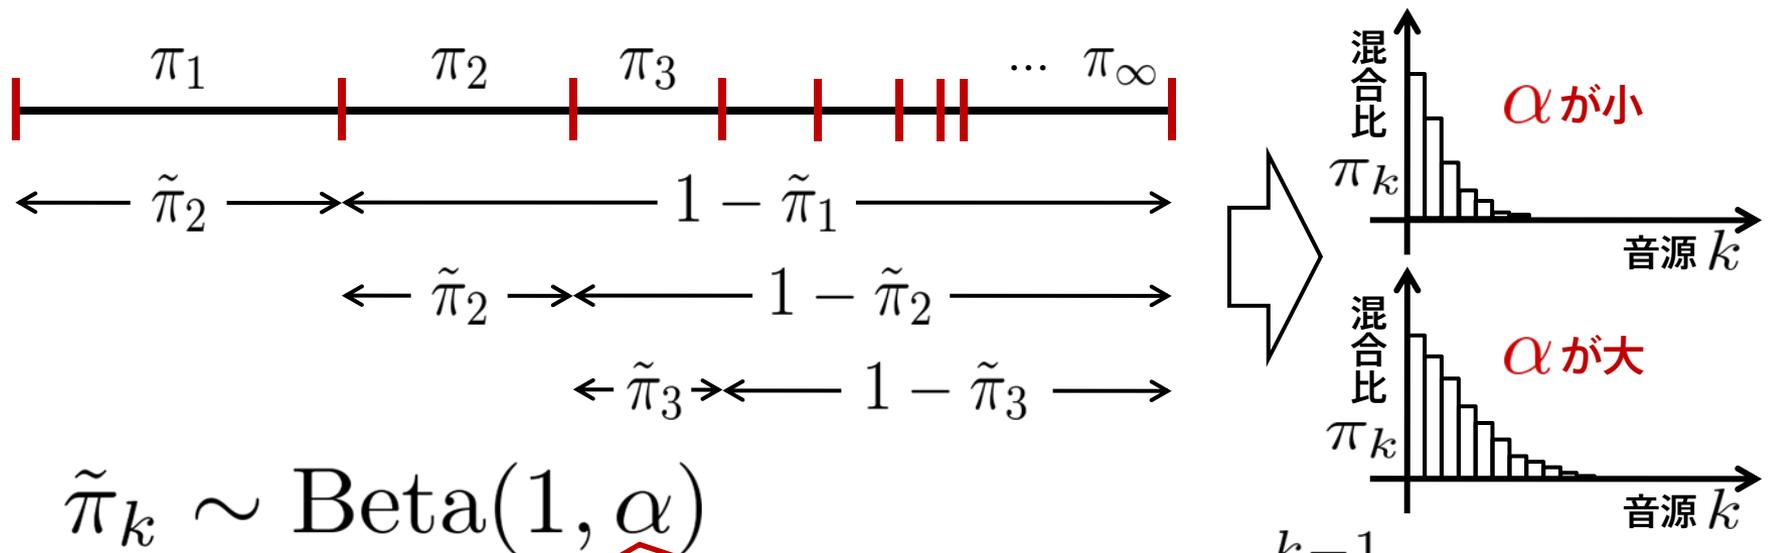


「ノンパラメトリック」の意味：  
• パラメータ空間が固定されていない  
• 無限の複雑さ(混合数)を考える

観測データに合わせて「実際のな」  
複雑さが自動調節される！

# 事前分布の構成法

- ディリクレ過程 (Dirichlet Process: DP)
  - 無限個の混合比に対する事前分布として利用可能
  - 棒折り過程 (Stick-Breaking Construction)
    - 長さ1の棒を無限に再帰的に折りとっていく
    - どのくらいの比で折りとるかを超パラメータ  $\alpha$  で制御



$$\tilde{\pi}_k \sim \text{Beta}(1, \alpha)$$

平均的には  $1 : \alpha$  で折りとる  
→  $\alpha$  を大きくするほど、残す棒の長さが長くなる  
→ 実際的な混合数が大きくなる (heavy-tailed)

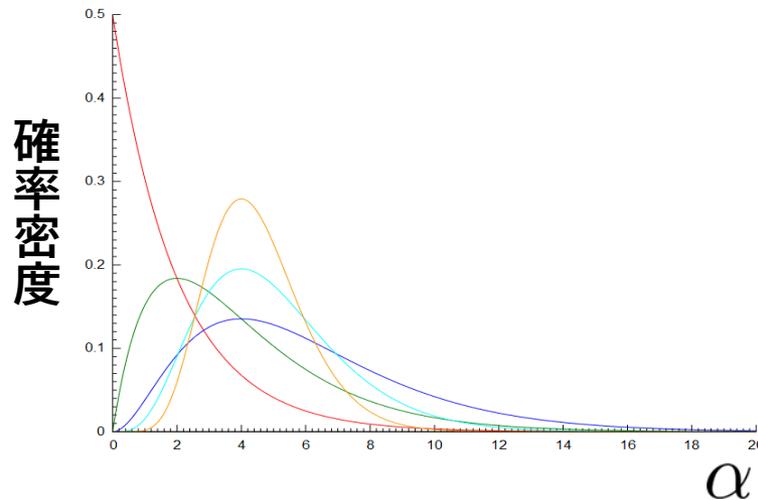
$$\pi_k = \tilde{\pi}_k \prod_{k'=1}^{k-1} (1 - \tilde{\pi}_{k'})$$

# 本研究のポイント(2)

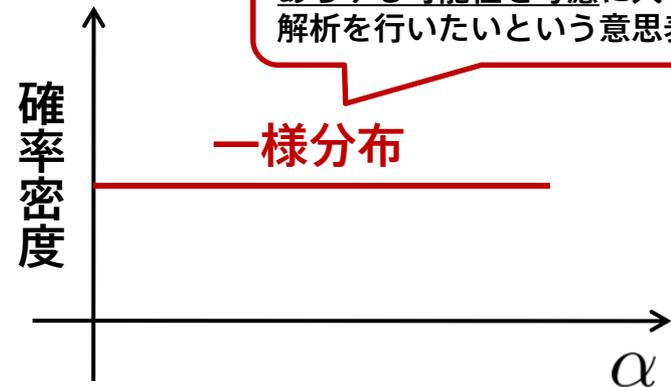
- 超パラメータに対して超事前分布を設定
  - 超事前分布は一様分布(ほぼ無情報)とする
  - 超パラメータ  $\alpha$  の手動設定の困難さを解消
    - 本来未知なのだから不確実性を適切に取り扱うべき

事前分布  $\tilde{\pi}_k \sim \text{Beta}(1, \alpha)$

超事前分布  $\alpha \sim \text{Gam}(a, b)$



ガンマ分布の一般的な形状

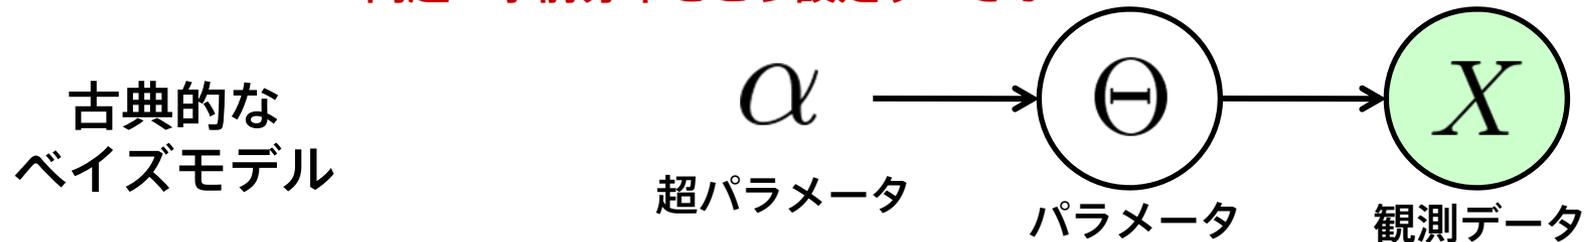


$a = 1, b = 0$  のとき

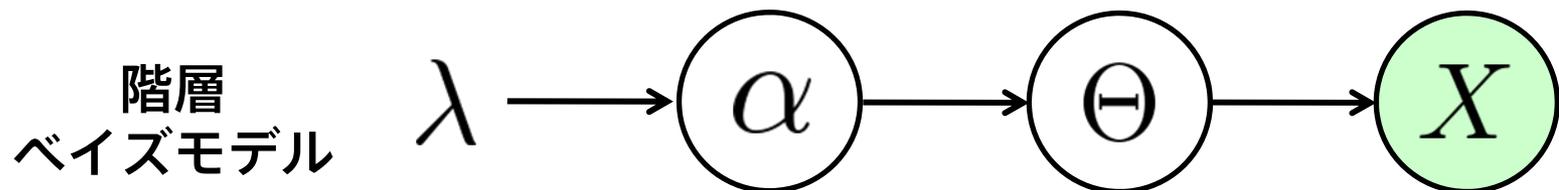
# 階層ベイズモデル

- 超パラメータに対して超事前分布を設定
  - パラメータだけでなく超パラメータも未知なので不確実性を適切に取り扱うのが自然

問題：事前分布をどう設定すべきか



不確実性を考慮して  
超パラメータを  
確率変数として扱う



新たな問題：超事前分布をどう設定すべきか

無情報事前分布：事前知識が特にない時に利用  
事後分布に影響をほとんど与えない曖昧な分布

# 本研究の位置付け

- 混合モデルに基づく基本周波数解析法の究極形
  - 本研究の原点：後藤・亀岡らの調波構造モデル
  - 本研究の貢献：
    - ノンパラメトリックベイズ化（無限混合モデル+ベイズ推定）
    - 超事前分布を導入した階層ベイズモデル

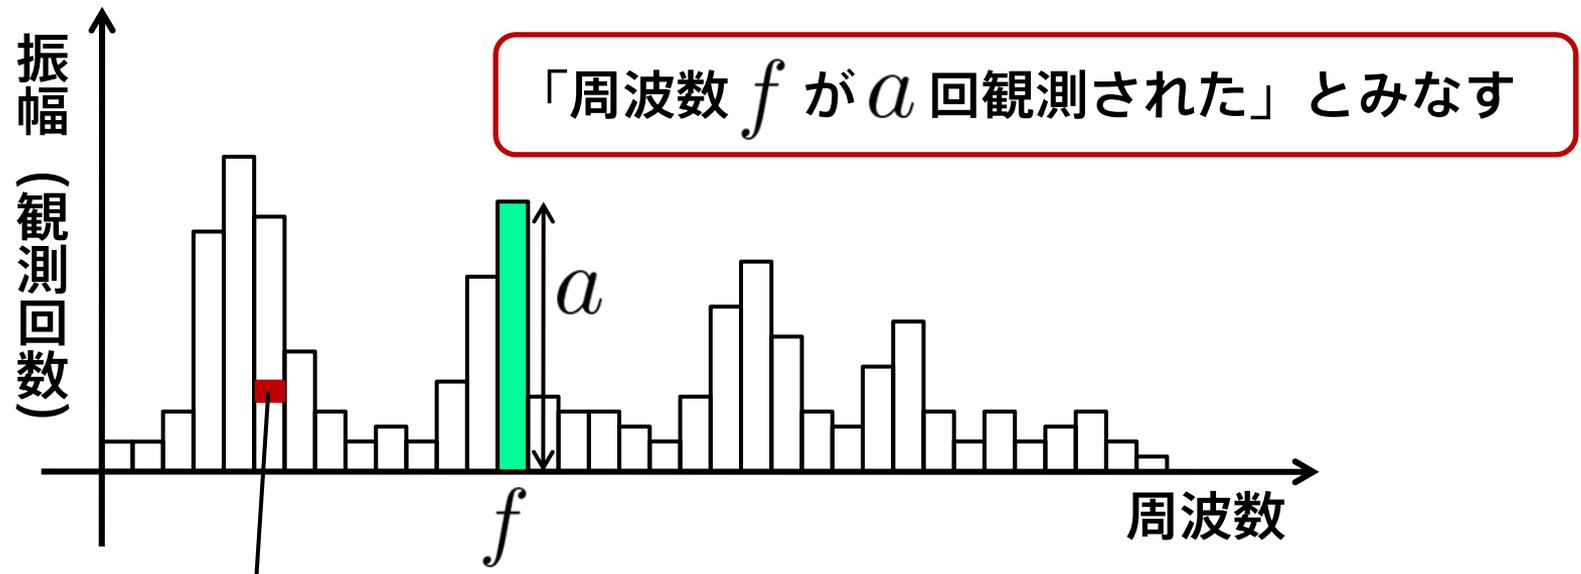
	従来研究	本研究
音源数	固定（事前に指定）	無限（指定不要）
倍音数	固定（事前に指定）	無限（指定不要）
音源の混合比に対する事前分布	——	階層ディリクレ過程 +無情報超事前分布 (チューニング不要)
倍音の混合比に対する事前分布	ディリクレ分布 (チューニング必要)	ディリクレ過程 +無情報超事前分布 (チューニング不要)
学習方法	MAP推定	ベイズ推定

# 無限潛在的調波配分法

Infinite Latent Harmonic Allocation (iLHA)

# 観測変数と潜在変数

- 各フレームの振幅スペクトル=ヒストグラム
  - さまざまな周波数を大量に観測したと考える
  - 各周波数ビンごとに観測回数をカウント
    - 各周波数の生成は独立であると仮定



**観測変数**  $\mathcal{X}_{dn}$ : フレーム  $d$  において  $n$  番目に観測された周波数

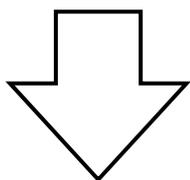
**潜在変数**  $\mathcal{Z}_{dn}$ :  $\mathcal{X}_{dn}$  がどの音源・倍音から生成されたか  
( $KM$  = 無限個の候補から 1 つ選ぶ)

# 本研究のポイント

- 音源の重畳をネスト型無限混合ガウス分布で表現
  - 音源数  $K$ ・倍音数  $M$  を無限大に発散 = 森羅万象
  - 観測データは森羅万象のほんの一部という考え方

ネスト型有限混合ガウス分布

$$\mathcal{M}_d(\mathbf{x}) = \sum_{k=1}^K \pi_{dk} \sum_{m=1}^M \tau_{km} \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k + \mathbf{o}_m, \boldsymbol{\Lambda}_k^{-1})$$



フレーム  $d$  における  
音源  $k$  の混合比

音源  $k$  における  
倍音  $m$  の混合比

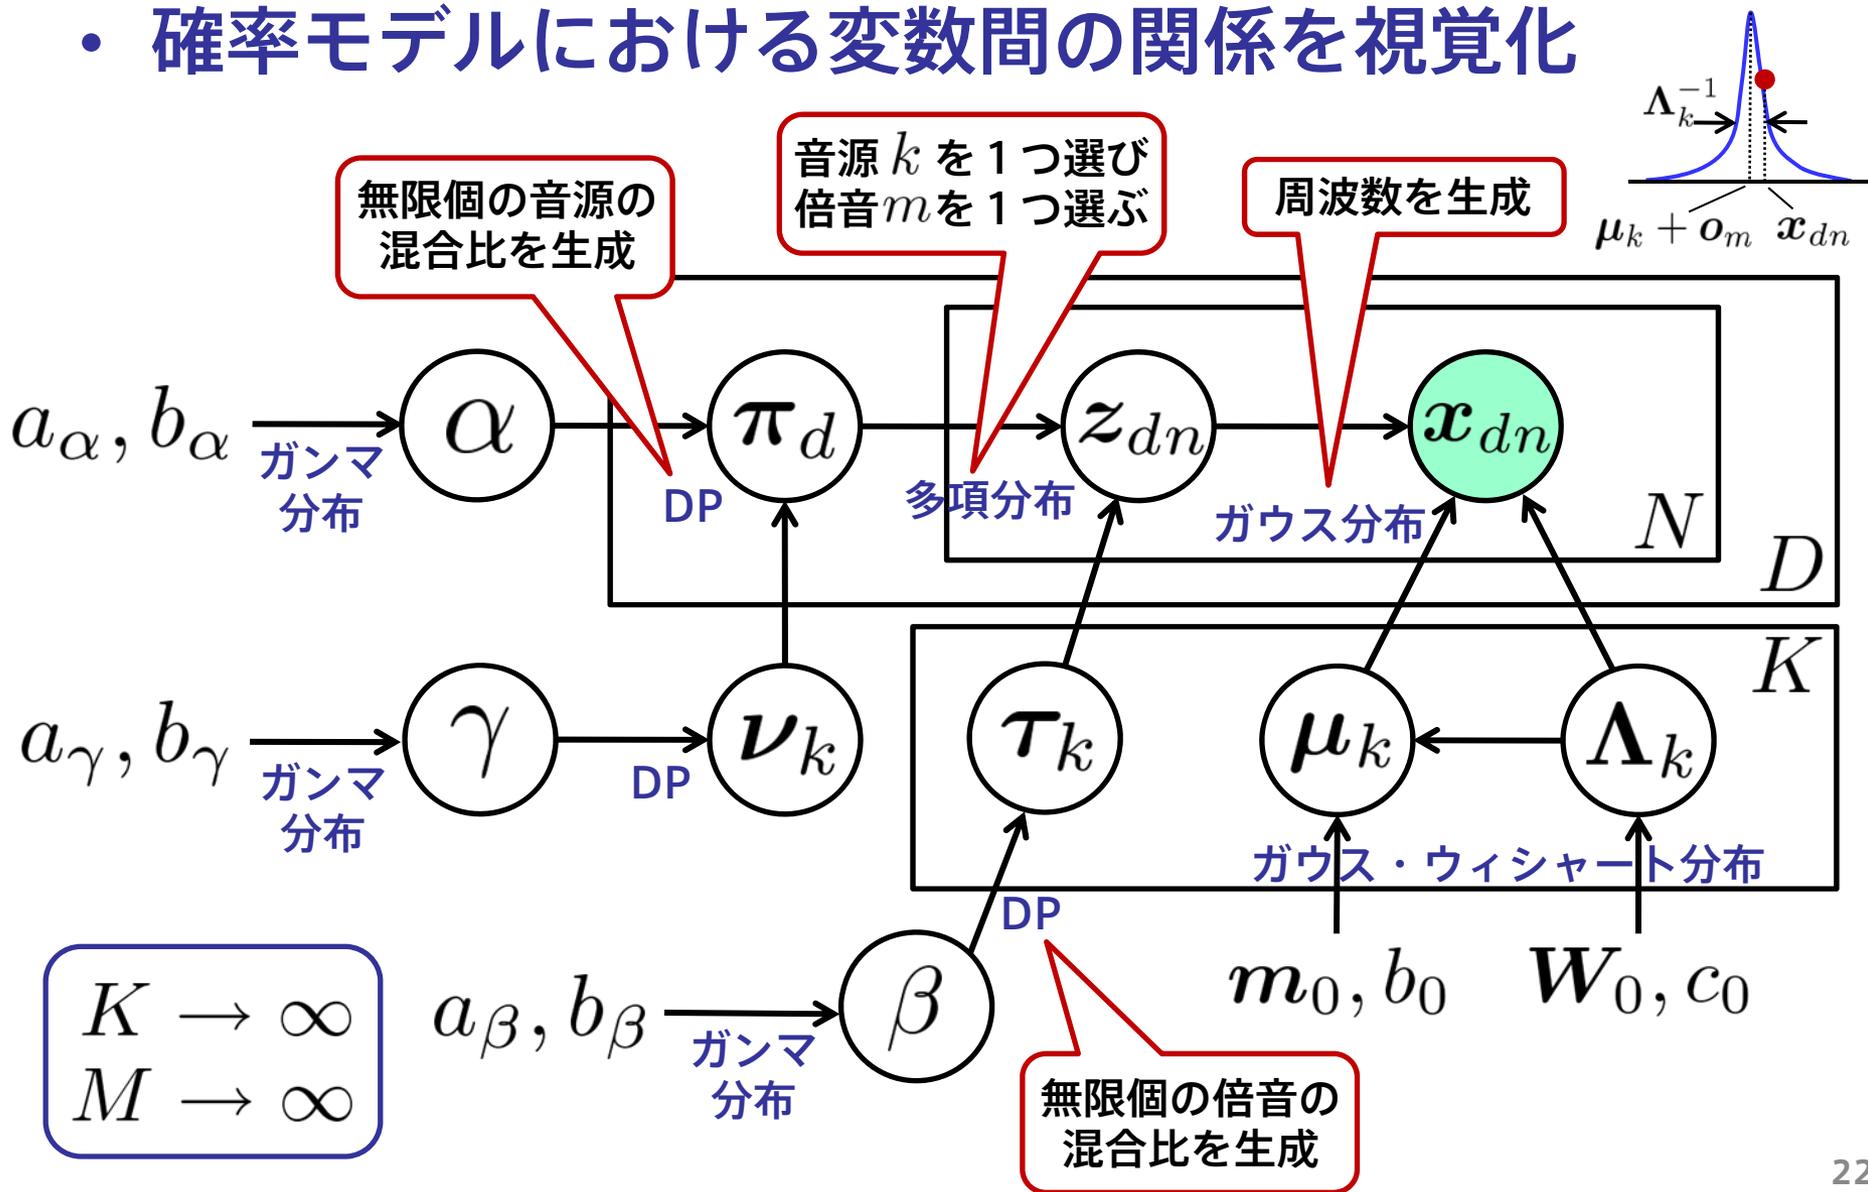
ネスト型無限混合ガウス分布

$$\mathcal{M}_d(\mathbf{x}) = \sum_{k=1}^{\infty} \pi_{dk} \sum_{m=1}^{\infty} \tau_{km} \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k + \mathbf{o}_m, \boldsymbol{\Lambda}_k^{-1})$$

無限個の音源・倍音があるにせよ、有限の観測データ中に現れるのは「現実的には」高々有限個の音源・倍音に限られる

# グラフィカル表現

- 確率モデルにおける変数間の関係を視覚化



# 確率モデルの定式化

- 同時分布

$$p(\mathbf{X}, \mathbf{Z}, \boldsymbol{\pi}, \boldsymbol{\tau}, \boldsymbol{\mu}, \boldsymbol{\Lambda}) = p(\mathbf{X}|\mathbf{Z}, \boldsymbol{\mu}, \boldsymbol{\Lambda})p(\mathbf{Z}|\boldsymbol{\pi}, \boldsymbol{\tau})p(\boldsymbol{\pi})p(\boldsymbol{\tau})p(\boldsymbol{\mu}, \boldsymbol{\Lambda})$$

- 尤度関数

$$p(\mathbf{X}|\mathbf{Z}, \boldsymbol{\mu}, \boldsymbol{\Lambda}) = \prod_{dnkm} \mathcal{N}(\mathbf{x}_{dn} | \boldsymbol{\mu}_k + \mathbf{o}_m, \boldsymbol{\Lambda}_k^{-1})^{z_{dnkm}} \quad \text{ガウス分布}$$

$$p(\mathbf{Z}|\boldsymbol{\pi}, \boldsymbol{\tau}) = \prod_{dnkm} (\pi_{dk}\tau_{km})^{z_{dnkm}} \quad \text{多項分布}$$

- 事前分布

$$\left. \begin{aligned} p(\boldsymbol{\pi}) &= \prod_d \text{Dir}(\boldsymbol{\pi}_d | \alpha \boldsymbol{\nu}) \propto \prod_{dk} \pi_{dk}^{\alpha \nu_k - 1} \\ p(\boldsymbol{\tau}) &= \prod_k \text{Dir}(\boldsymbol{\tau}_k | \beta \boldsymbol{\nu}) \propto \prod_{km} \tau_{km}^{\beta \nu_m - 1} \end{aligned} \right\} \text{ディリクレ分布}$$

$$p(\boldsymbol{\mu}, \boldsymbol{\Lambda}) = \prod_k \mathcal{N}(\boldsymbol{\mu}_k | \mathbf{m}_0, (b_0 \boldsymbol{\Lambda}_k)^{-1}) \mathcal{W}(\boldsymbol{\Lambda}_k | \mathbf{W}_0, c_0) \quad \text{ガウス・ウィシャート分布}$$

# 確率モデルの定式化

**同時分布**  $p(\mathbf{X}, \mathbf{Z}, \boldsymbol{\pi}, \boldsymbol{\tau}, \boldsymbol{\mu}, \boldsymbol{\Lambda}, \boldsymbol{\alpha}, \boldsymbol{\nu}, \boldsymbol{\gamma}, \boldsymbol{\beta})$   
 $= p(\mathbf{X}|\mathbf{Z}, \boldsymbol{\mu}, \boldsymbol{\Lambda})p(\mathbf{Z}|\boldsymbol{\pi}, \boldsymbol{\tau})p(\boldsymbol{\pi}|\boldsymbol{\alpha}, \boldsymbol{\nu})p(\boldsymbol{\nu}|\boldsymbol{\gamma})p(\boldsymbol{\tau}|\boldsymbol{\beta})p(\boldsymbol{\mu}, \boldsymbol{\Lambda})p(\boldsymbol{\alpha})p(\boldsymbol{\gamma})p(\boldsymbol{\beta})$

## 尤度関数

$$p(\mathbf{X}|\mathbf{Z}, \boldsymbol{\mu}, \boldsymbol{\Lambda}) = \prod_{dnkm} \mathcal{N}(\mathbf{x}_{dn} | \boldsymbol{\mu}_k + \mathbf{o}_m, \boldsymbol{\Lambda}_k^{-1})^{z_{dnkm}} \quad \text{ガウス分布}$$

$$p(\mathbf{Z}|\boldsymbol{\pi}, \boldsymbol{\tau}) = \prod_{dnkm} (\pi_{dk}\tau_{km})^{z_{dnkm}} \quad \text{多項分布}$$

## 事前分布

$$\pi_d \sim \text{InfDir}(\boldsymbol{\alpha}\boldsymbol{\nu}) \quad \boldsymbol{\nu} \sim \text{Stick}(\boldsymbol{\gamma}) \quad \text{階層ディリクレ過程}$$

無限次元のディリクレ分布(DP)      棒折り過程(DP)

$$\tau_k \sim \text{Stick}(\boldsymbol{\beta}) \quad \text{ディリクレ過程}$$

棒折り過程(DP)

$$p(\boldsymbol{\mu}, \boldsymbol{\Lambda}) = \prod_k \mathcal{N}(\boldsymbol{\mu}_k | \mathbf{m}_0, (b_0\boldsymbol{\Lambda}_k)^{-1}) \mathcal{W}(\boldsymbol{\Lambda}_k | \mathbf{W}_0, c_0) \quad \text{ガウス・ウィシャート分布}$$

## 超事前分布

$$\boldsymbol{\alpha} \sim \text{Gam}(a_\alpha, b_\alpha) \quad \boldsymbol{\gamma} \sim \text{Gam}(a_\gamma, b_\gamma)$$

$$\boldsymbol{\beta} \sim \text{Gam}(a_\beta, b_\beta)$$

# 確率モデルの学習

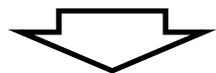
## • 周辺化変分ベイズ法 (Collapsed VB)

### – 変分ベイズ法(VB)を洗練させた手法

- 解析的に計算可能な部分を周辺化して変数を削減
- 変分事後分布を因子分解できる形に限定して最適化

同時分布

$$p(\mathbf{X}, \mathbf{Z}, \pi, \tau, \mu, \Lambda, \alpha, \nu, \gamma, \beta) \\ = \underline{p(\mathbf{X}|\mathbf{Z}, \mu, \Lambda)} \underline{p(\mathbf{Z}|\pi, \tau)} \underline{p(\pi|\alpha, \nu)} \underline{p(\nu|\gamma)} \underline{p(\tau|\beta)} \underline{p(\mu, \Lambda)} p(\alpha) p(\gamma) p(\beta)$$



尤度関数と事前分布の間で共役性が成立 → 積分消去可能!

周辺分布

$$p(\mathbf{X}, \mathbf{Z}, \alpha, \nu, \gamma, \beta) \\ = p(\mathbf{X}|\mathbf{Z}) p(\mathbf{Z}|\alpha, \nu, \beta) p(\nu|\gamma) p(\alpha) p(\gamma) p(\beta)$$

求めたいもの: 真の事後分布

$$p(\mathbf{Z}, \alpha, \nu, \gamma, \beta | \mathbf{X})$$

変分事後分布(因子分解できる形に限定)

$$q(\mathbf{Z}, \alpha, \nu, \gamma, \beta)$$

できる限り真の事後分布に近づくように  
変分EMアルゴリズムで反復最適化

$$= q(\alpha) q(\nu) q(\gamma) q(\beta) \prod_{dn} q(\mathbf{z}_{dn})$$

# 評価実験

## • 実験条件

### – 使用データ：RWC研究用音楽データベース

- RWC-MDB-J-2001：ジャズ音楽 から6曲
- RWC-MDB-C-2001：クラシック音楽 から2曲
- ギター曲・ピアノ曲の冒頭23秒

### – 周波数解析

- ガボールウェーブレット変換
- 周波数分解能：10 [cent]
- フレームシフト幅：16 [ms]

### – 正解データ

- MIDIをもとに手動で同期・修正したもの
- HTCの研究[亀岡ら2007]と大体同じ

### – 評価尺度

- フレームレベルのF値 (再現率と適合率の調和平均)

# 実験結果

- iLHAが自動的に最適な性能を発揮
  - 人手チューンした従来手法と同等程度の性能を達成
  - HTCのような時間方向のモデル化で改善の余地あり

	チューンした 事前分布 + MAP推定	チューンした 事前分布 + MAP推定	無情報事前分布 + ベイズモデル	無情報超事前分布 + 階層ノンパラ ベイズモデル
	PreFEst	HTC	LHA	iLHA
Jazz No.1 📢	75.8	79.0	70.7	<b>82.2</b>
Jazz No.2 📢	<b>78.5</b>	78.0	69.1	77.9
Jazz No.6 📢	70.4	<b>78.3</b>	49.8	71.2
Jazz No.7 📢	83.0	<b>86.0</b>	70.2	85.5
Jazz No.8 📢	<b>85.7</b>	84.4	55.9	84.6
Jazz No.9 📢	85.9	<b>89.5</b>	68.9	84.7
Classic No.30 📢	76.0	<b>83.6</b>	81.4	81.6
Classic No.35 📢	72.8	76.0	58.9	<b>79.6</b>
合計	79.4	<b>82.0</b>	65.8	81.7

# おわりに

- 従来の基本周波数解析法の究極形を提案
  - 本研究の原点
    - ネスト型有限混合ガウスモデルのMAP推定[後藤・亀岡ら]
  - 本研究の貢献
    - **ノンパラメトリックベイズ**
      - ネスト型無限混合ガウスモデルのベイズ推定
    - **階層ベイズモデル**
      - 無情報超事前分布の導入による完全自動化
- 音楽情報処理技術の新しい方向性
  - 最新の機械学習技術の積極的導入
  - 古典的な統計的学習理論からの脱出
  - 計算音楽学 (Computational Musicology)
    - 計算言語学 (Computational Linguistics) のアナロジ