

# NMF vs PLCA: 多重音生成過程に対する 無限因子モデルと無限混合モデル

吉井 和佳 糸山 克寿 中村 栄太 (京大)  
後藤 真孝 (産総研)

第112回情報処理学会音楽情報科学研究会 (SIGMUS 112)

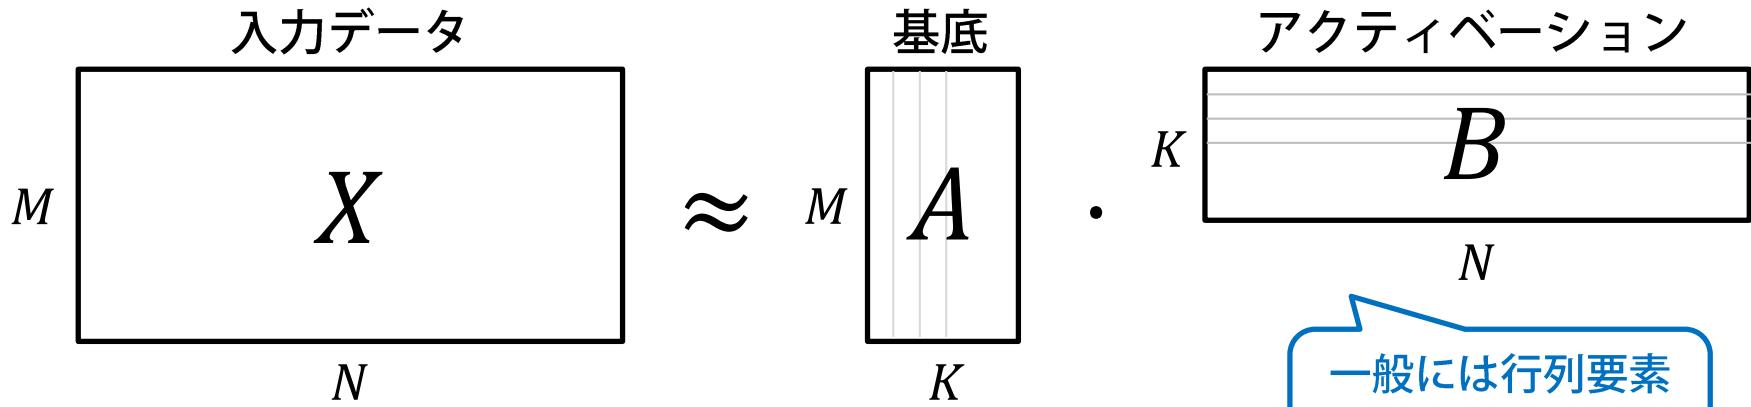
# 研究の背景

- 音楽音響信号の音源分離には行列因子分解が広く利用
  - 非負値行列分解 (nonnegative matrix factorization, NMF)
    - 画像処理分野で提案 [Lee@NIPS 2000]
    - 音楽音響信号の分離のために応用 [Smaragdis@WASPAA 2003]
  - 確率的潜在要素解析 (probabilistic latent component analysis, PLCA)
    - 自然言語処理分野で確率的潜在意味解析 (PLSA) が提案 [Hofmann@SIGIR 1999]
    - 音楽音響信号の分離のためにPLSAを拡張 [Smaragdis@NIPS 2006]
  - 確率モデルの定式化が可能
    - NMFもPLCAもある確率モデルの最尤推定として解釈可能
    - (ノンパラメトリック)ベイズモデルの定式化も可能

確率モデルを考えることで、手法の理論的な妥当性を議論できる！

# 行列因子分解 (matrix factorization)

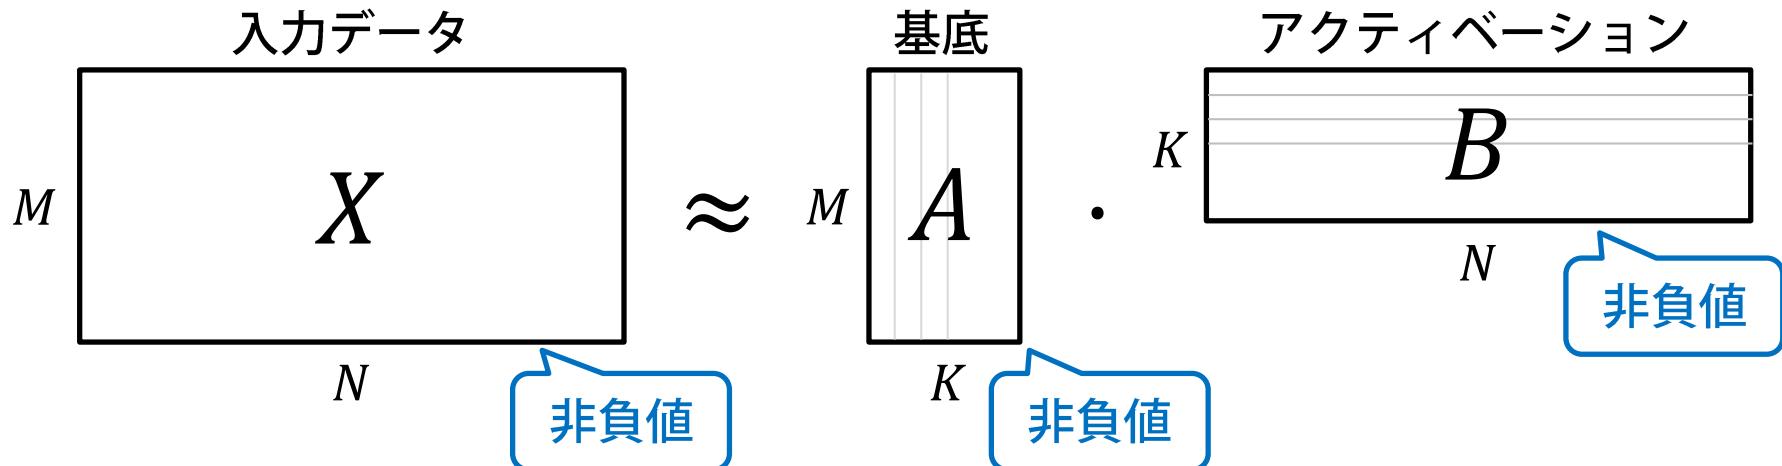
- ある行列を二つの行列の積で近似 (低ランク近似)
  - 行列に関する制約やコスト関数の違いでさまざまな変種が存在
    - 主成分分析 (PCA) : 基底が直交
    - 独立成分分析 (ICA) : 基底が独立



$K \ll M, N$  とすることにより、冗長性が除去され、データ  $X$  を構成する「基底」が教師なし学習できる

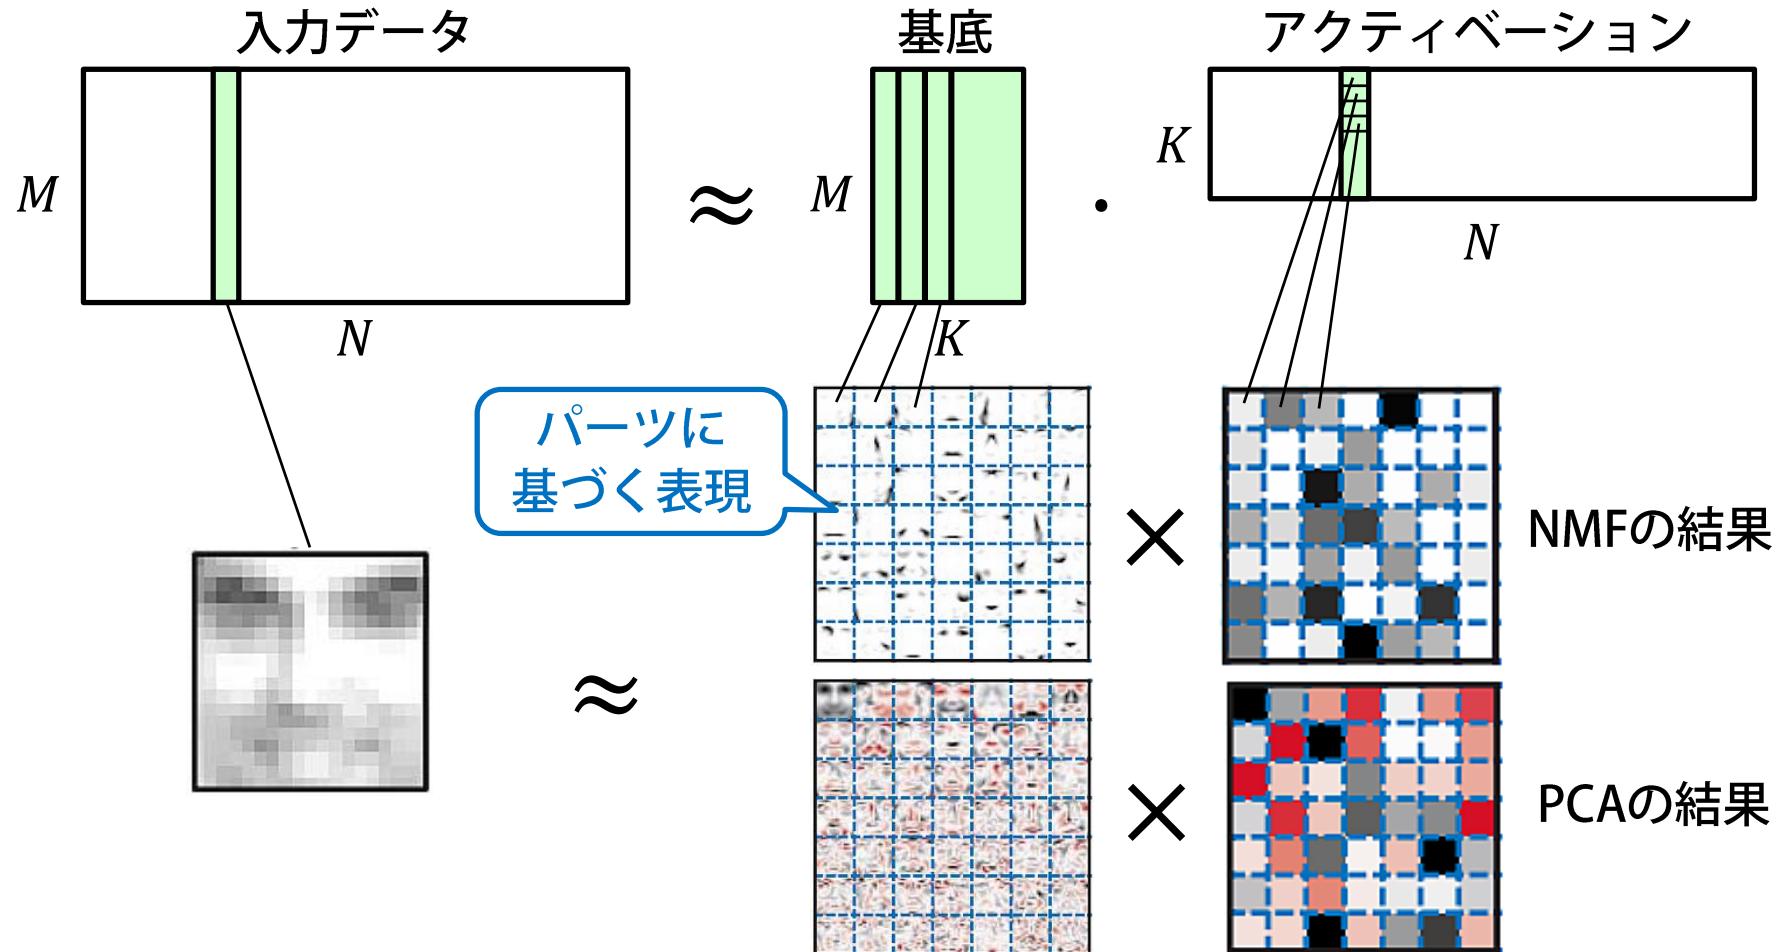
# 非負値制約に基づく行列分解

- ある非負値行列を二つの非負値行列の積で近似
  - 非負値行列因子分解 (NMF)
  - 確率的潜在成分解析 (PLCA)

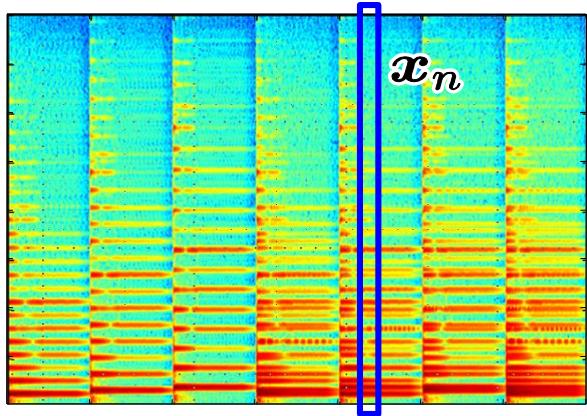
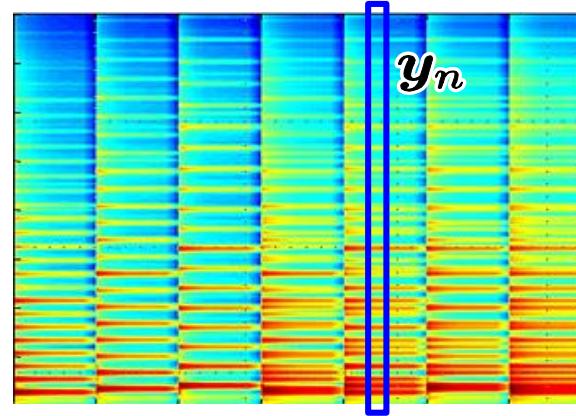
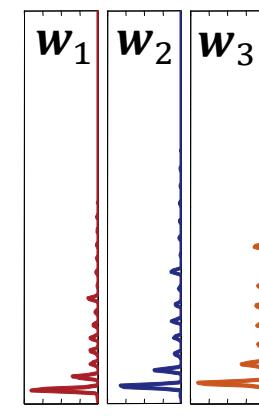


非負値制約により、基底の足し合わせのみで入力データを表現  
 → 「パーツ」に基づく分解表現

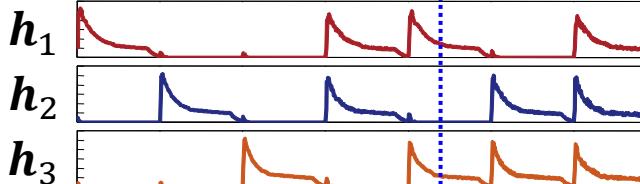
# NMF vs PCA



# 非負値行列因子分解 (NMF)

観測行列  $X$ 再構成行列  $Y = WH$ 基底ベクトル群  $W$ 

$$x_n \approx y_n = \sum_{k=1}^K h_{kn} w_k$$

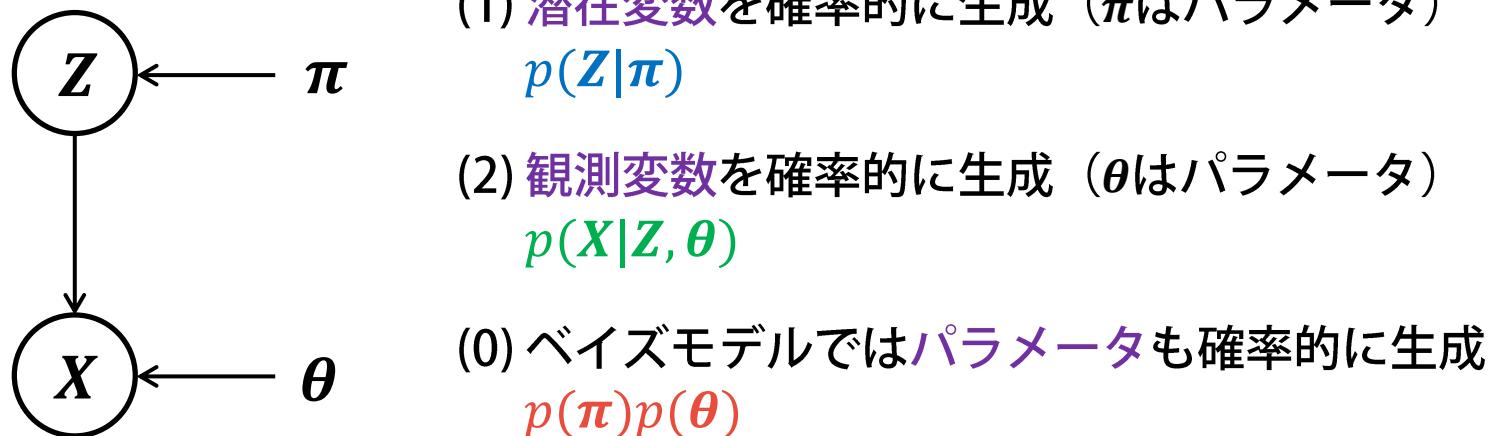
音量ベクトル群  $H$ 

疑問：コスト関数  $C(x_n|y_n)$  はどのように設計すればよいか？

確率モデル（観測データの生成過程）を考えることが重要！

# 潜在変数モデル

- 「観測変数」の背後に「潜在変数」が存在することを仮定
  - 現実の問題で利用される確率モデルはほとんどがこのタイプ
  - 段階的なデータの生成過程を表現



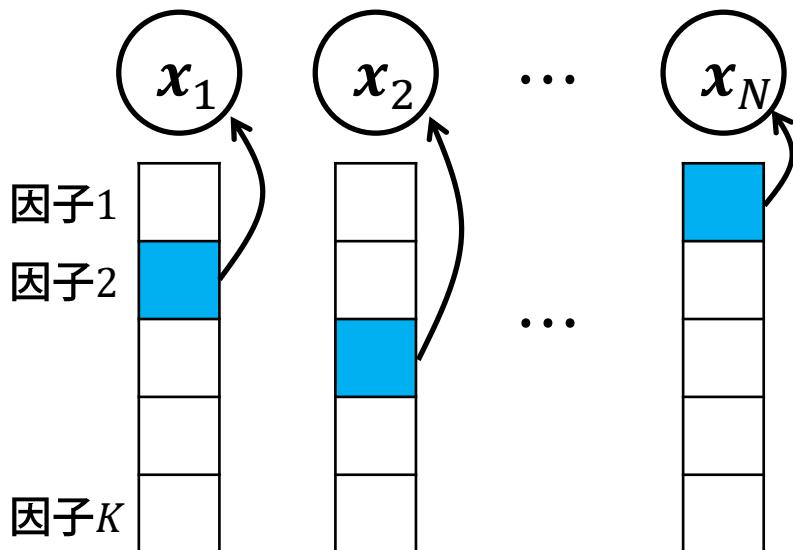
事後分布の計算が目標  $p(Z, \pi, \theta | X) = \frac{p(X, Z, \pi, \theta)}{p(X)} = \frac{p(X|Z, \theta)p(Z|\pi)p(\pi)p(\theta)}{p(X)}$

# 混合モデルと因子モデル

## 混合モデル (mixture model)

あるサンプルはいずれか一つの因子のみに依存する

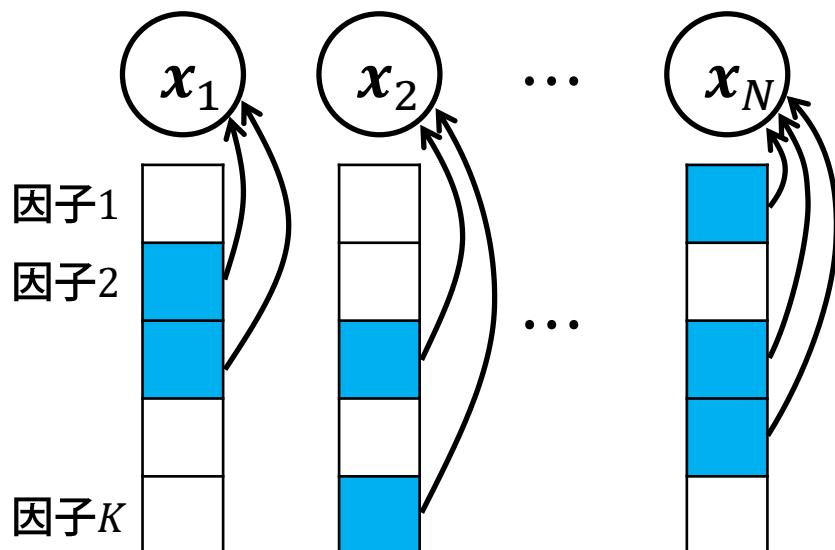
観測変数



潜在変数

## 因子モデル (factor model)

各サンプルは複数の因子の組み合わせで得られる



「分類」のための確率モデル

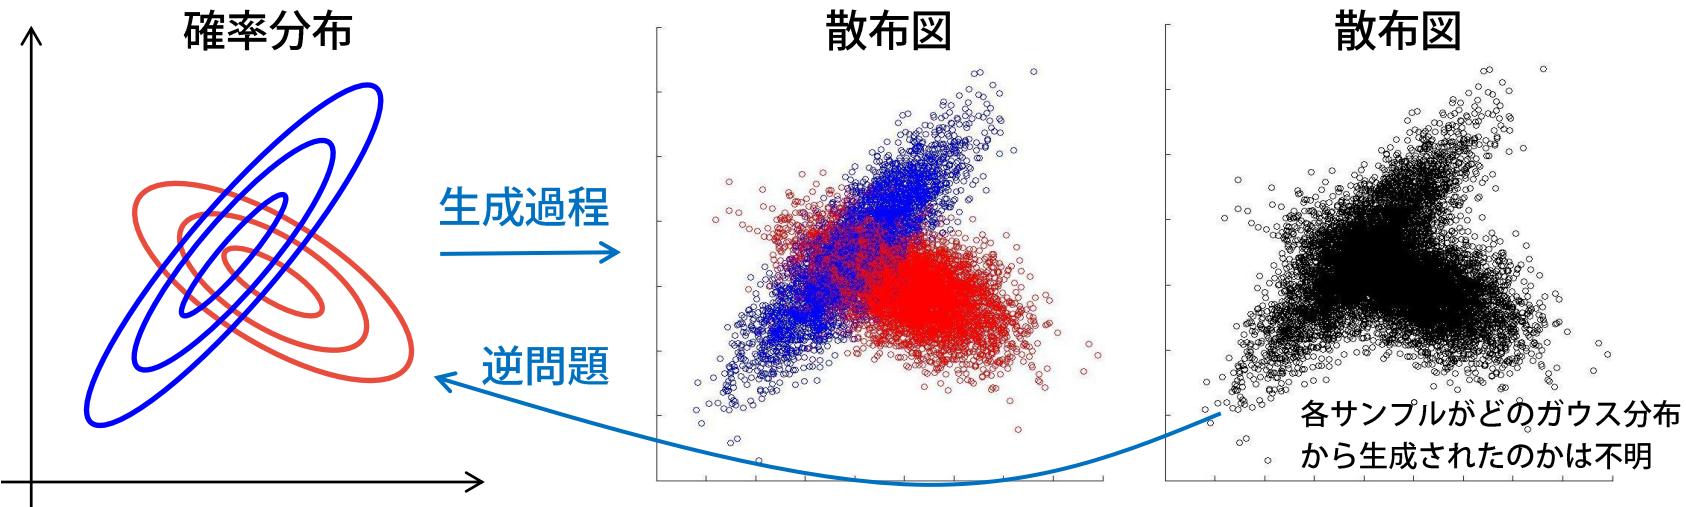
「分解」のための確率モデル

# 混合モデルの例

- 混合ガウスモデル (GMM)
  - K個のガウス分布を準備*
    - パラメータ:  $\theta = [(\mu_1, \Sigma_1), \dots, (\mu_K, \Sigma_K)]$
  - ガウス分布を確率的に選択してサンプルを生成
    - パラメータ:  $\pi = [\pi_1, \dots, \pi_K]$

$$x_n \sim \sum_{k=1}^K \pi_k N(\mu_k, \Sigma_k)$$

和が確率分布の外側  
→ 確率分布の足し合わせ



# 因子モデルの例

- 主成分分析 (PCA)・因子分析 (FA)

- $K$ 個の基底ベクトルを準備

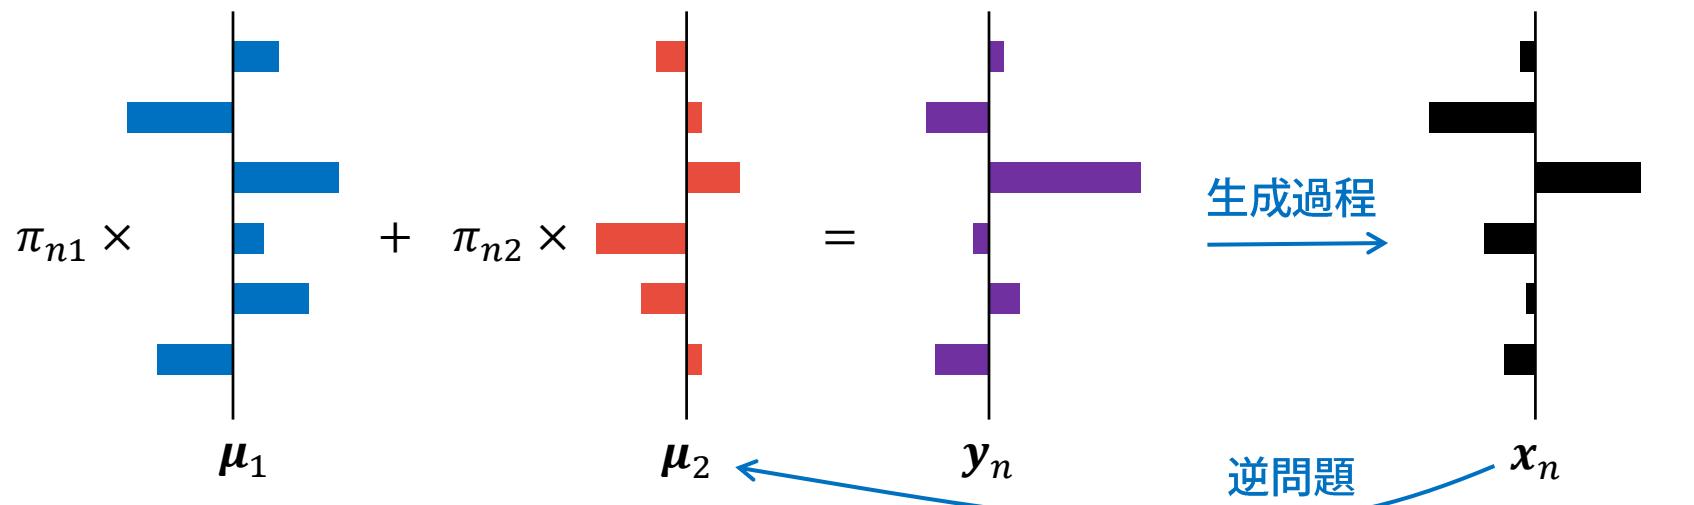
- パラメータ:  $\theta = [\mu_1, \mu_2, \dots, \mu_K]$

- 重み付きで足し合わせてからサンプルを生成

- パラメータ:  $\pi = [\pi_1, \dots, \pi_N]$

$$x_n \sim N\left(\sum_{k=1}^K \pi_{nk} \mu_k, \Sigma\right)$$

和が確率分布の内側  
→ 確率変数の足し合わせ



# 混合モデルと因子モデル

## 混合モデル (mixture model)

あるサンプルはいずれか一つの因子のみに依存する

$$x_n \sim \sum_{k=1}^K \pi_k N(\mu_k, \Sigma_k)$$

和が確率分布の外側  
→ 確率分布の足し合わせ

各サンプルを  
「分類する」ための確率モデル

## 因子モデル (factor model)

各サンプルは複数の因子の組み合わせで得られる

$$x_n \sim N\left( \sum_{k=1}^K \pi_{nk} \mu_k, \Sigma \right)$$

和が確率分布の内側  
→ 確率変数の足し合わせ

各サンプルを  
「分解する」ための確率モデル

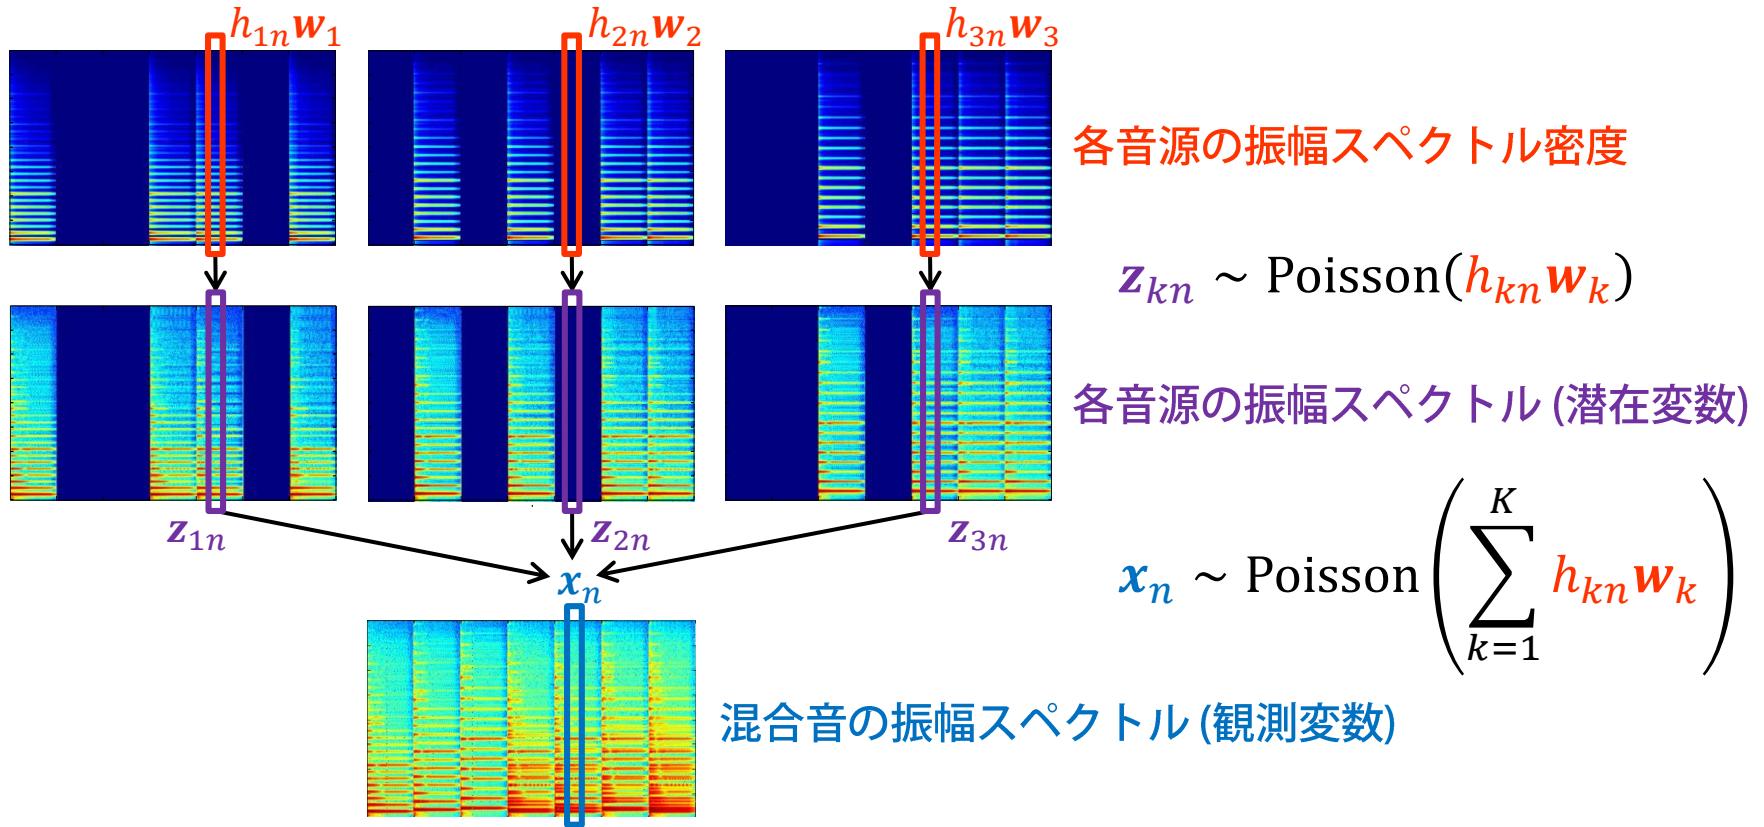
# 音源分離にはどちらを使う？

- 理論的には「因子モデル」が妥当 → NMF
  - 各フレームにおいて、混合音のスペクトル（「サンプル」）は、複数の音源信号のスペクトルが重畠することによって得られる
    - 各フレームが複数の音源に分解される
- 現実には「混合モデル」も提案 → PLCA
  - 何を「サンプル」ととらえるかがキモ
    - 各「サンプル」はいずれかの音源に分類される
    - 各フレームでは複数の音源が同時に存在できるようにしたい

何らかのトリックが必要

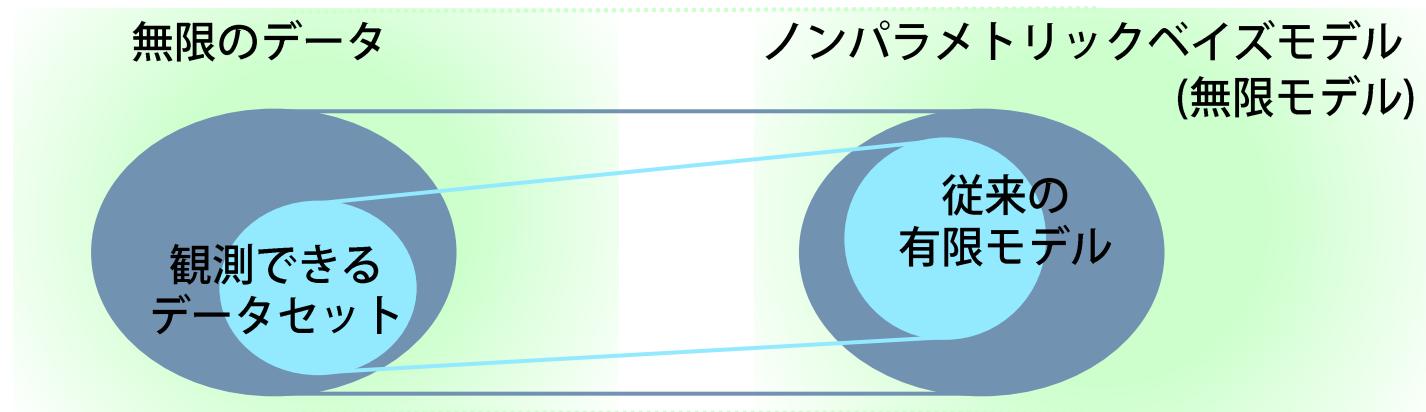
# NMFの確率モデル

- Kullback-Leibler NMF (KL-NMF) : ポアソン分布に基づく因子モデル



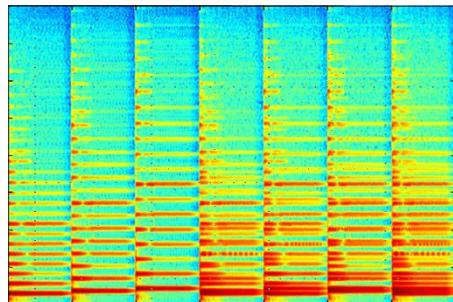
# NMFのノンパラメトリックベイズ拡張

- 無限個の基底をもつNMFを定式化可能
  - 観測データに合わせて「実効的な」基底数 $K^+$ が推定される
    - 無限にデータがあれば無限個の基底が必要
    - 手持ちデータが有限であれば、高々有限個の基底ですむ
- 因子モデルを無限化する際の主な方針は二つ
  - ガンマ過程 (gamma process) とベータ過程 (beta process)

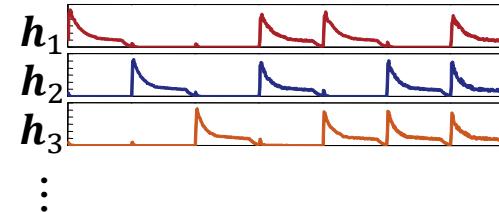
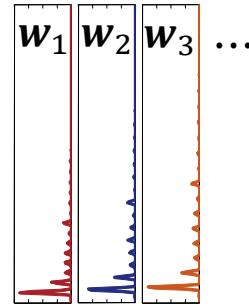


# Gamma Process NMF [Hoffman@ICML 2010]

- 無限個の基底に対する重みを導入してスパース学習
  - ガンマ過程 (GaP) : 無限次元の非負値ベクトルに対する事前分布



$\approx$

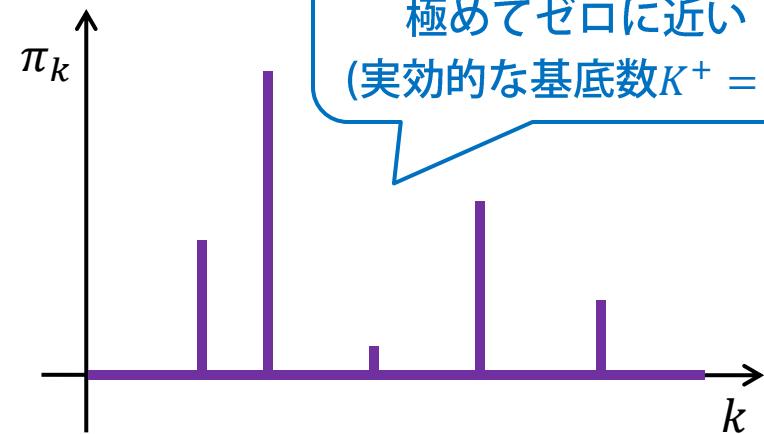


⋮

$$x_n \sim \text{Poisson} \left( \sum_{k=1}^{\infty} \pi_k h_{kn} w_k \right)$$

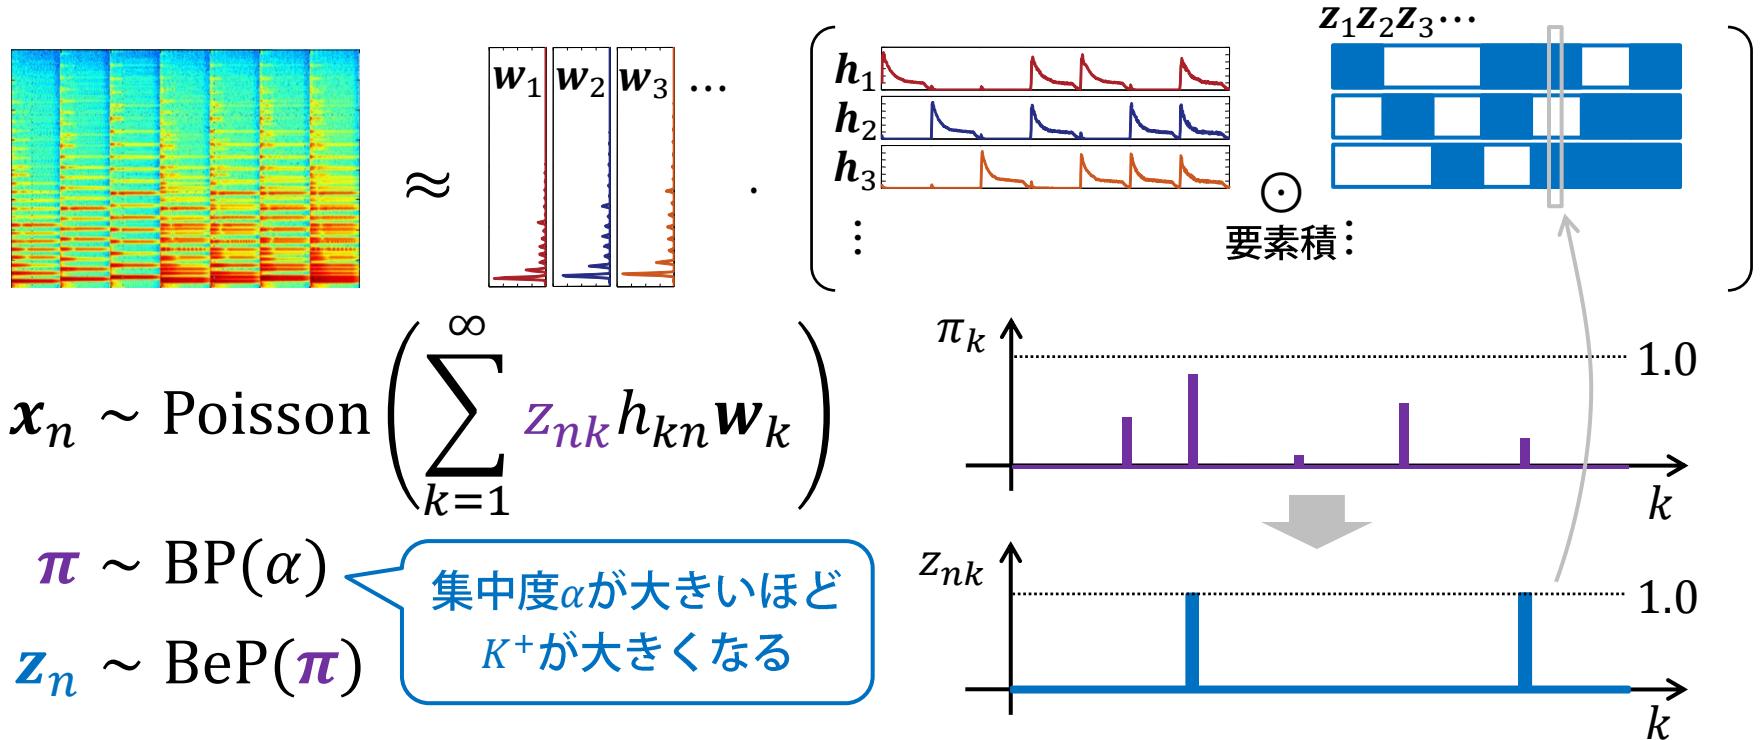
$$\pi \sim \text{GaP}(\alpha)$$

集中度 $\alpha$ が大きいほど  
 $K^+$ が大きくなる



# Beta Process NMF [Liang@NIPS Workshop 2014]

- 無限個のバイナリ変数を導入してスパース学習
  - ベータ過程 (BP) : 無限次元のコイントス確率ベクトルに対する事前分布
  - ベルヌイ過程 (BeP) : 無限次元のバイナリベクトルに対する事前分布



# ノンパラメトリックベイズNMFの問題

- 最大基底数での打ち切り近似が必要な解法しか提案されていない
  - 最初に十分に多くの基底を準備(例えば $K = 100$ )
  - 計算を反復するうちに不要になった基底を削除していく

## GaP-NMF

$K^+$ の推定には閾値処理が必要

$$x_n \sim \text{Poisson} \left( \sum_{k=1}^{\infty} \pi_k h_{kn} w_k \right)$$

本当は「非負値」ではなくて  
「正值」でないとダメ  
(ゼロは許容されない)

## BP-NMF

組み合わせ最適化は局所解が多い

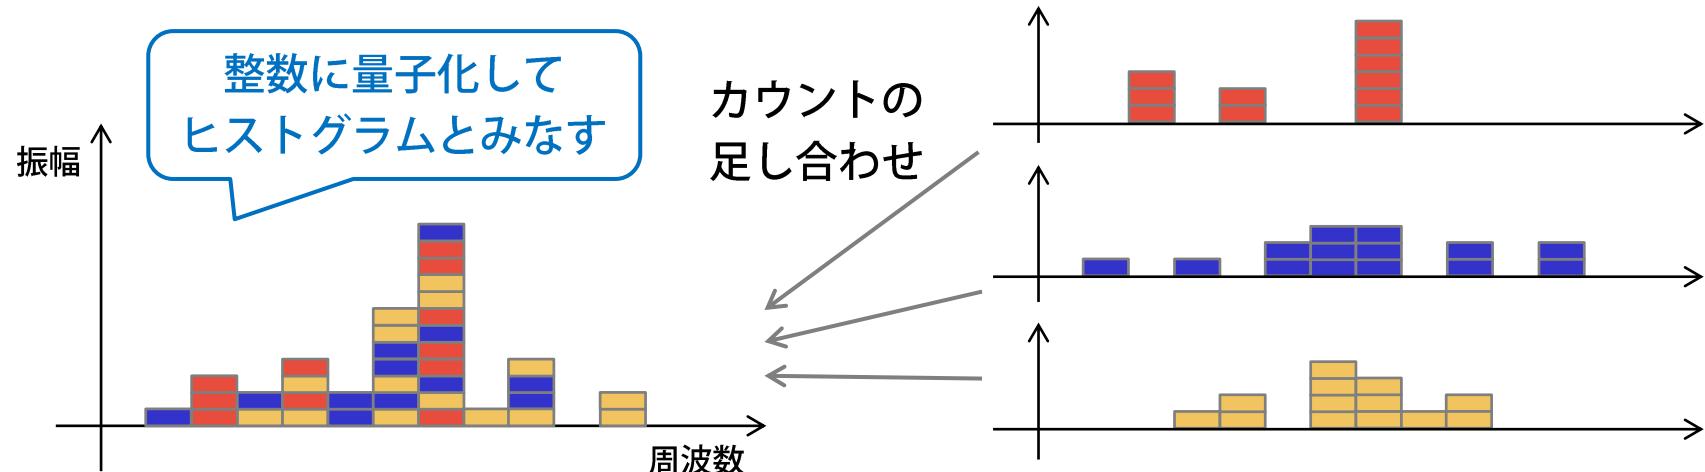
$$x_n \sim \text{Poisson} \left( \sum_{k=1}^{\infty} z_{nk} h_{kn} w_k \right)$$

基底数を $K$ とすると  
混合モデルでは $K$ 通りの可能性  
因子モデルでは $2^K$ 通りの可能性

# 混合モデルに基づく音源分離

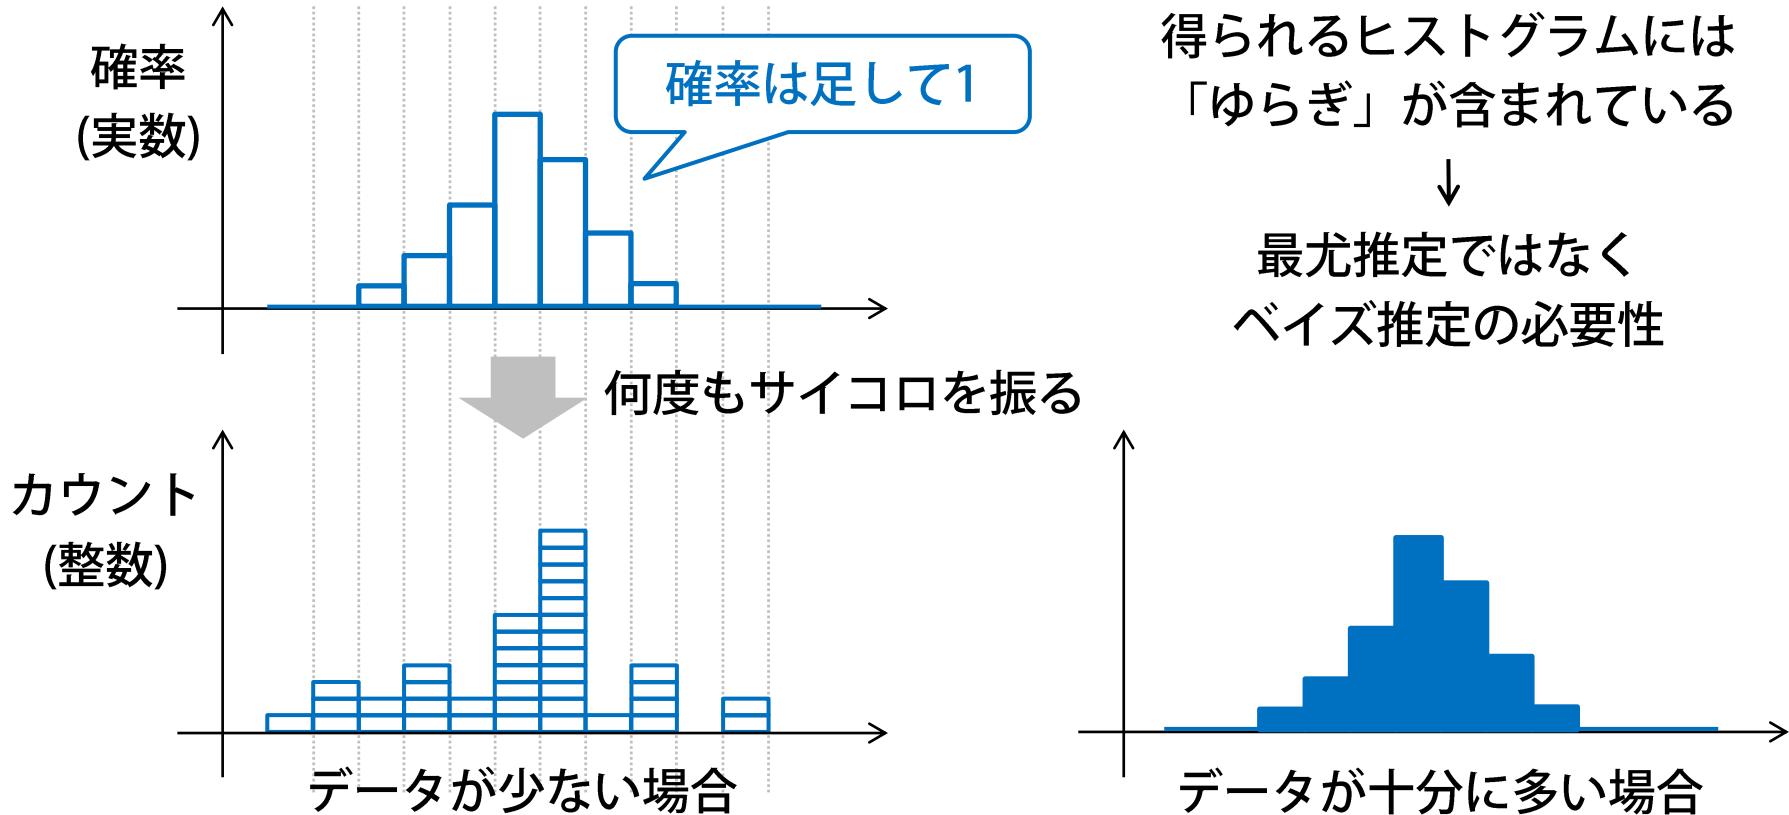
- 混合モデルを音源分離に使うにはトリックが必要
  - 各「サンプル」はいずれかの音源に分類される
  - 各フレームでは複数の音源が同時に存在できるようにしたい

混合音のスペクトル = 「サンプル」の集合  
 スペクトル全体としてみたときには、複数の音源が含まれる



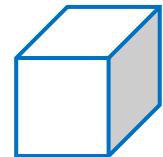
# 離散分布とヒストグラム

- ヒストグラムは離散分布(サイコロ)から確率的に生成されると解釈



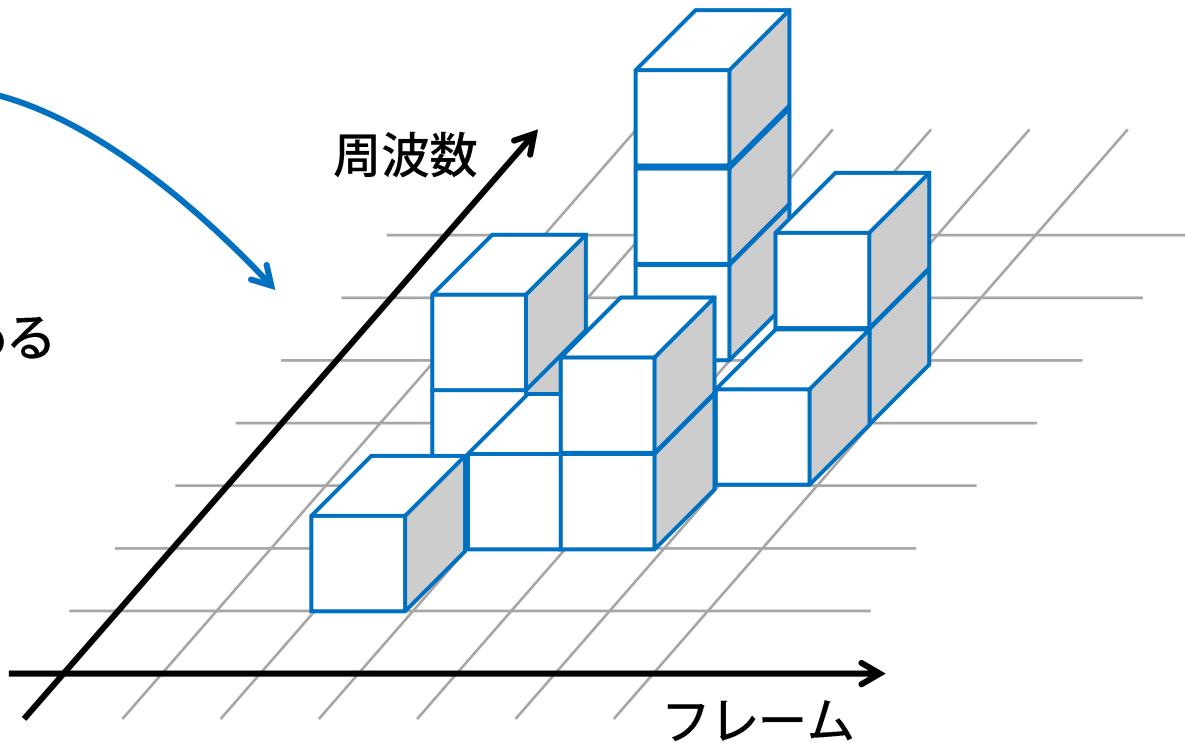
## 二次元平面上の離散分布

- 音量子 (sound quantum) を投げ入れると、平面内のどこかで止まる
  - 二次元平面はグリッドに分割されている



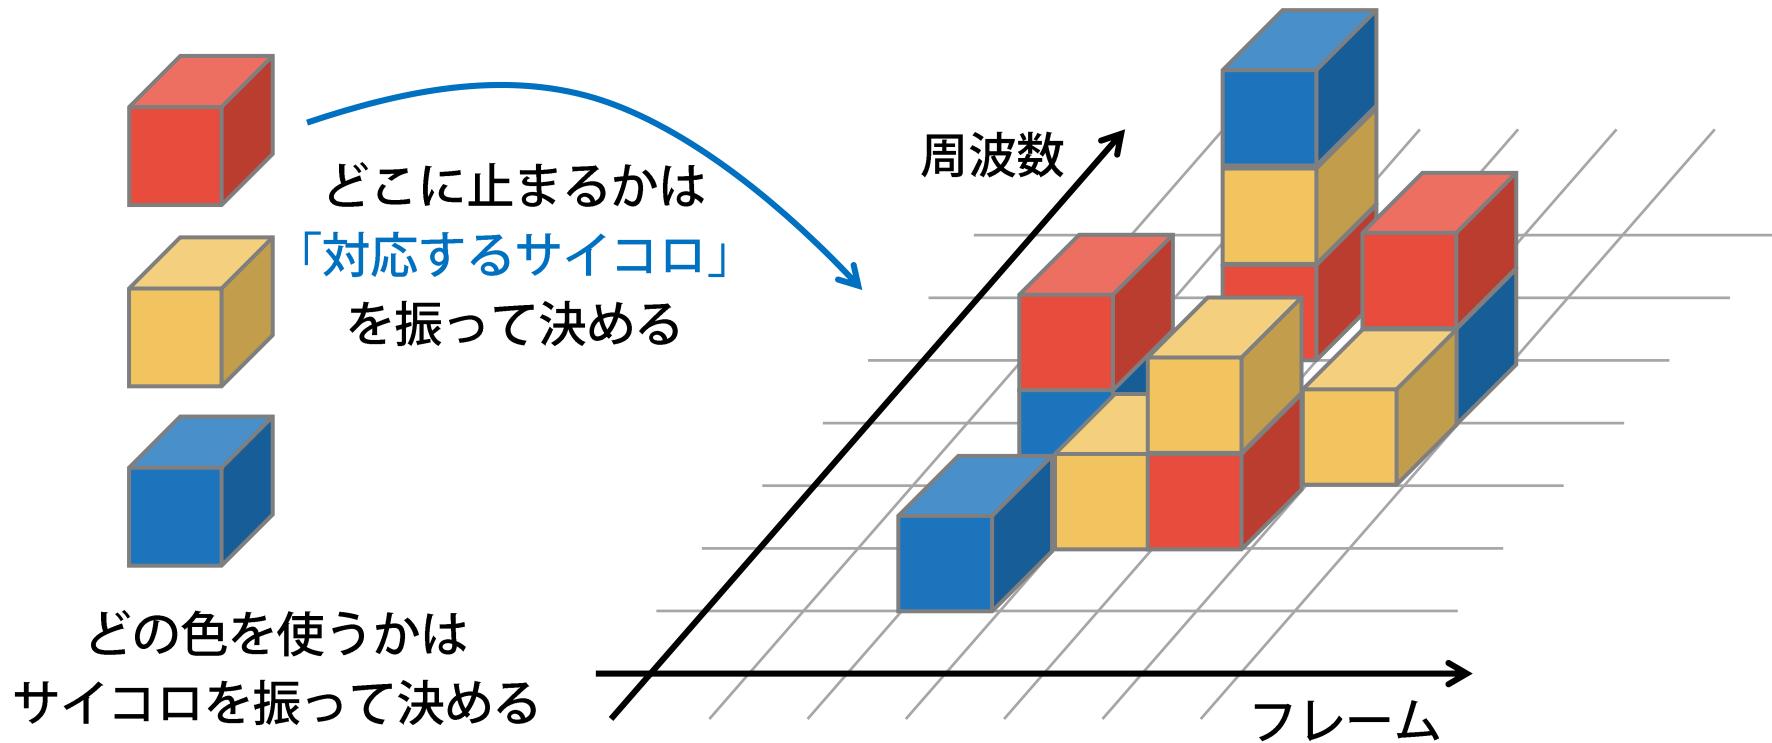
どこに止まるかは  
サイコロを振って決める

何度も投げ込むと  
積み重なって  
ヒストグラムとなる



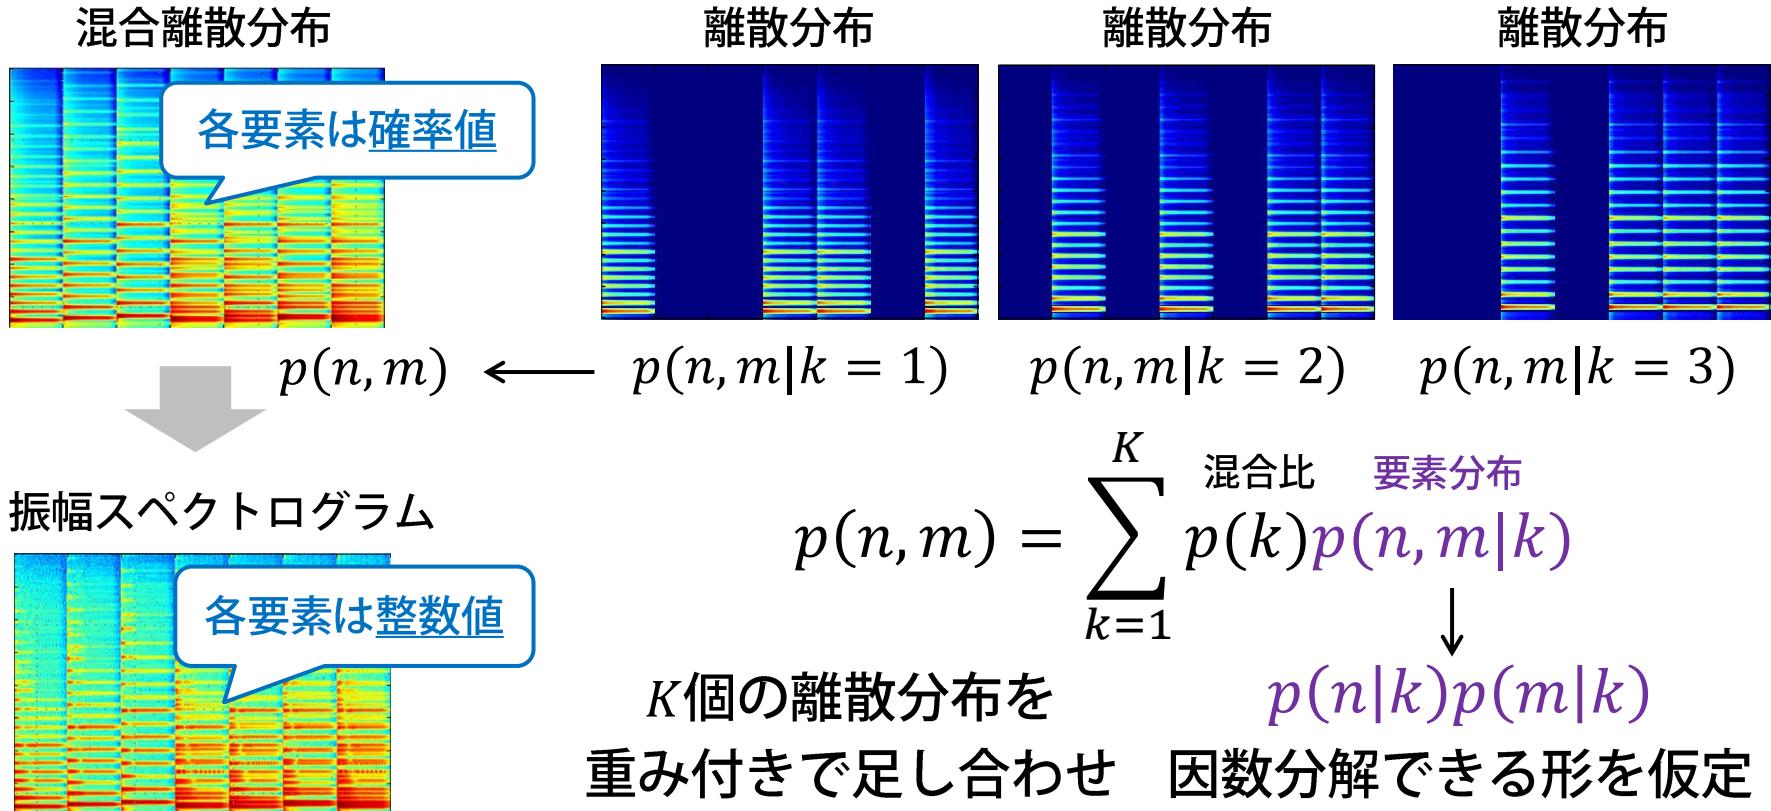
# 二次元平面上の混合離散分布

- 音量子 (sound quantum) を投げ入れると、平面内のどこかで止まる
  - 二次元平面はグリッドに分割されている



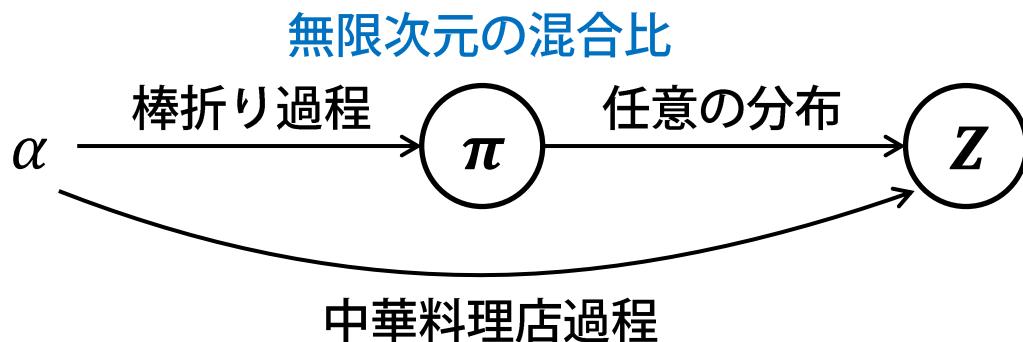
# 確率的潜在成分解析(PLCA)の確率モデル

- 二次元平面上の混合離散分布を定式化



# ノンパラメトリックベイス拡張

無限は扱えないので 打ち切り近似が必要	ガンマ過程 (GaP)	ベータ過程 (BP)	ディリクレ過程 (DP)
有限次元の 確率分布の極限	無限個の ガンマ分布	無限個の ベータ分布	無限次元の ディリクレ分布
棒折り過程 (stick-breaking process)	複雑	複雑	簡単
料理店表現 (restaurant representation)	複雑	インド料理過程 (IBP)	中華料理店過程 (CRP)

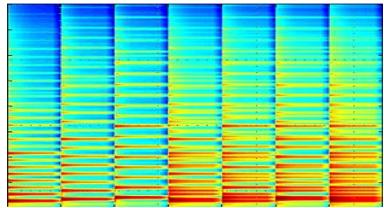


打ち切り近似を  
する必要がない

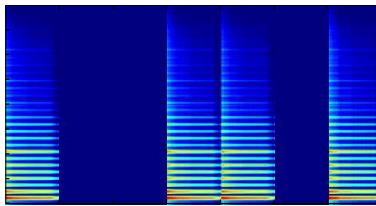
# Dirichlet Process PLCA

- 二次元混合離散分布の事前分布としてディリクレ過程を導入

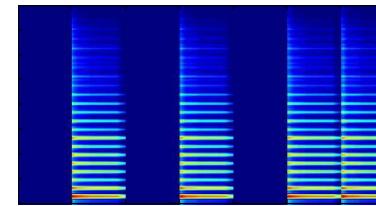
混合離散分布



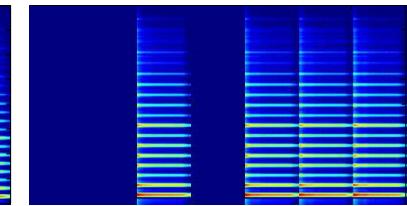
離散分布



離散分布

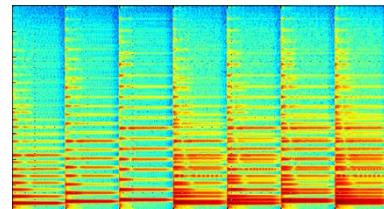


離散分布



$$p(n, m) \leftarrow p(n|1)p(m|1) \quad p(n|2)p(m|2) \quad p(n|3)p(m|3)$$

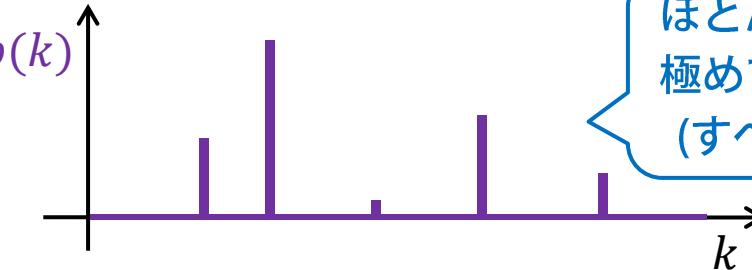
振幅スペクトログラム



$$p(n, m) = \sum_{k=1}^{\infty} p(k) p(n|k) p(m|k)$$

混合比 要素分布

ディリクレ過程  
 $p(k) \sim DP(\alpha)$



ほとんどの重みが  
極めてゼロに近い  
(すべて足すと1)

# 周辺化ギブスサンプリング

- 実効的な基底数  $K^+$  を増減させながらパラメータの推定が可能
  - 最大基底数で打ち切る近似が不要で効率的
  - 中華料理店過程のおかげで、 $p(k)$ を考えることが不要に
  - 事前分布の共役性のおかげで、 $p(n|k)$  と  $p(m|k)$  を考えることが不要に

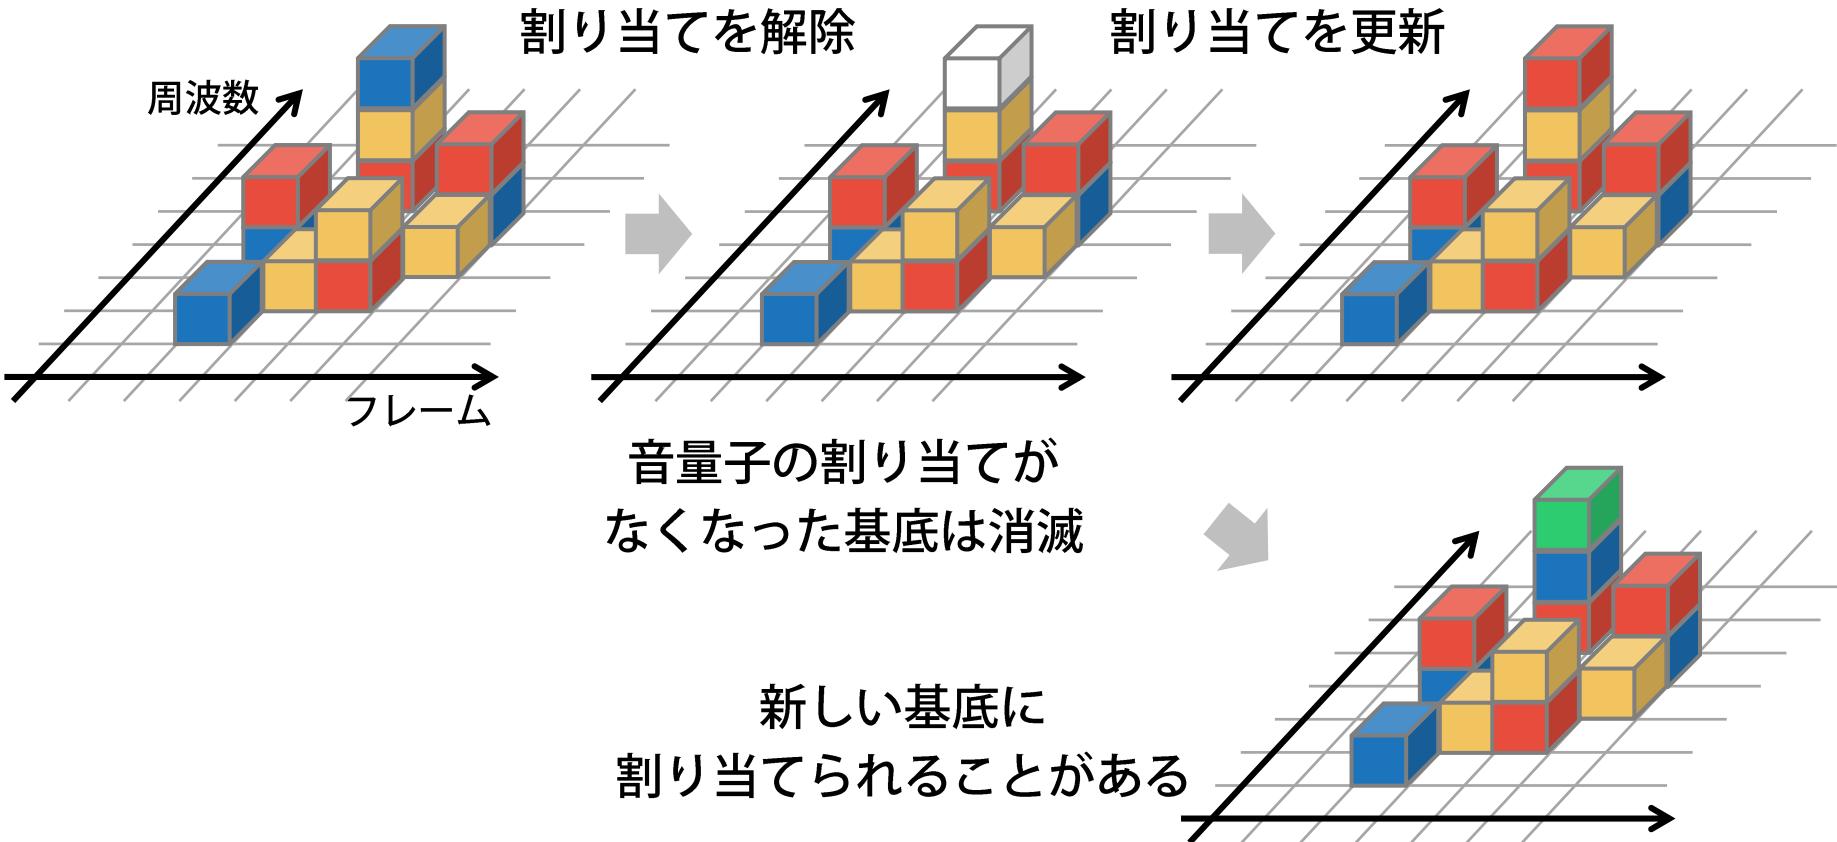
$$p(n, m) = \sum_{k=1}^{\infty} p(k)p(n|k)p(m|k)$$

ディリクレ過程 $p(k) \sim \text{DP}(\alpha)$	ディリクレ分布 $p(n k) \sim \text{Dirichlet}(\beta)$	ディリクレ分布 $p(m k) \sim \text{Dirichlet}(\gamma)$
--	--	---

本来求めたかった  $p(k)p(n|k)p(m|k)$  の代わりに何を求めればいいのか？

# 周辺化ギブスサンプリング

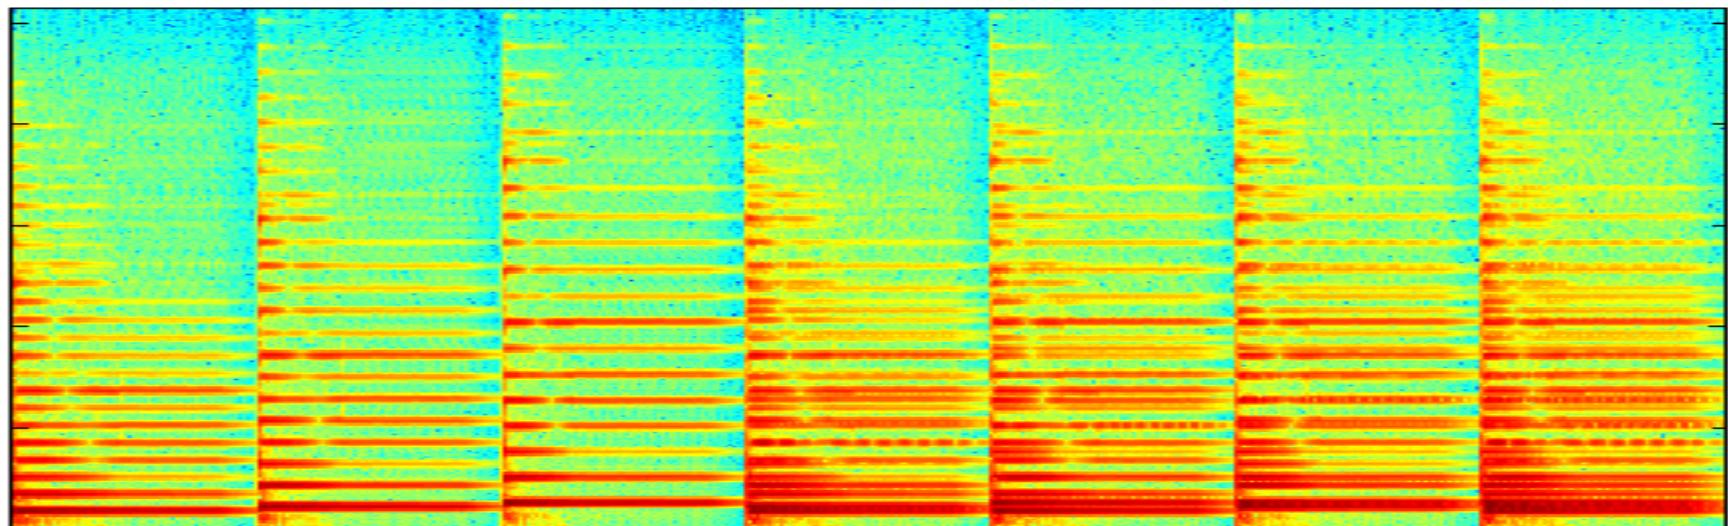
- 音量子の基底への割り当てを順番にサンプリング



# 実験

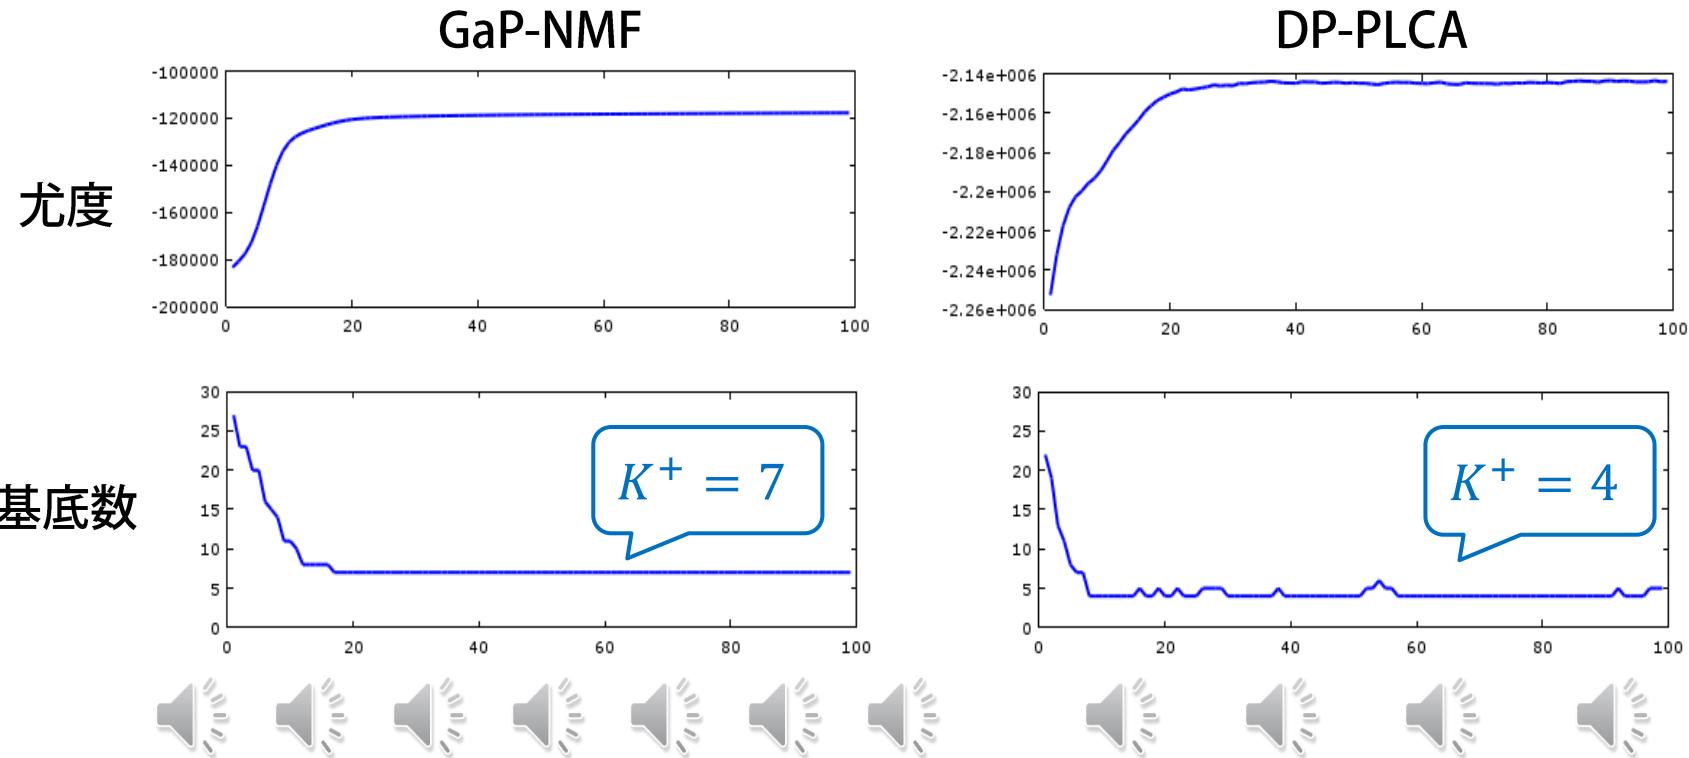
- 人工データに適用

- C, E, Gを組み合わせを変えながら同時発音 ( $1.2\text{ s} \times 7 = 8.4\text{ s}$ )
- 16 [kHz] 16 [bits]モノラル信号を、512点窓幅・160点シフトでFFT
- GaP-NMFとDP-PLCAを比較



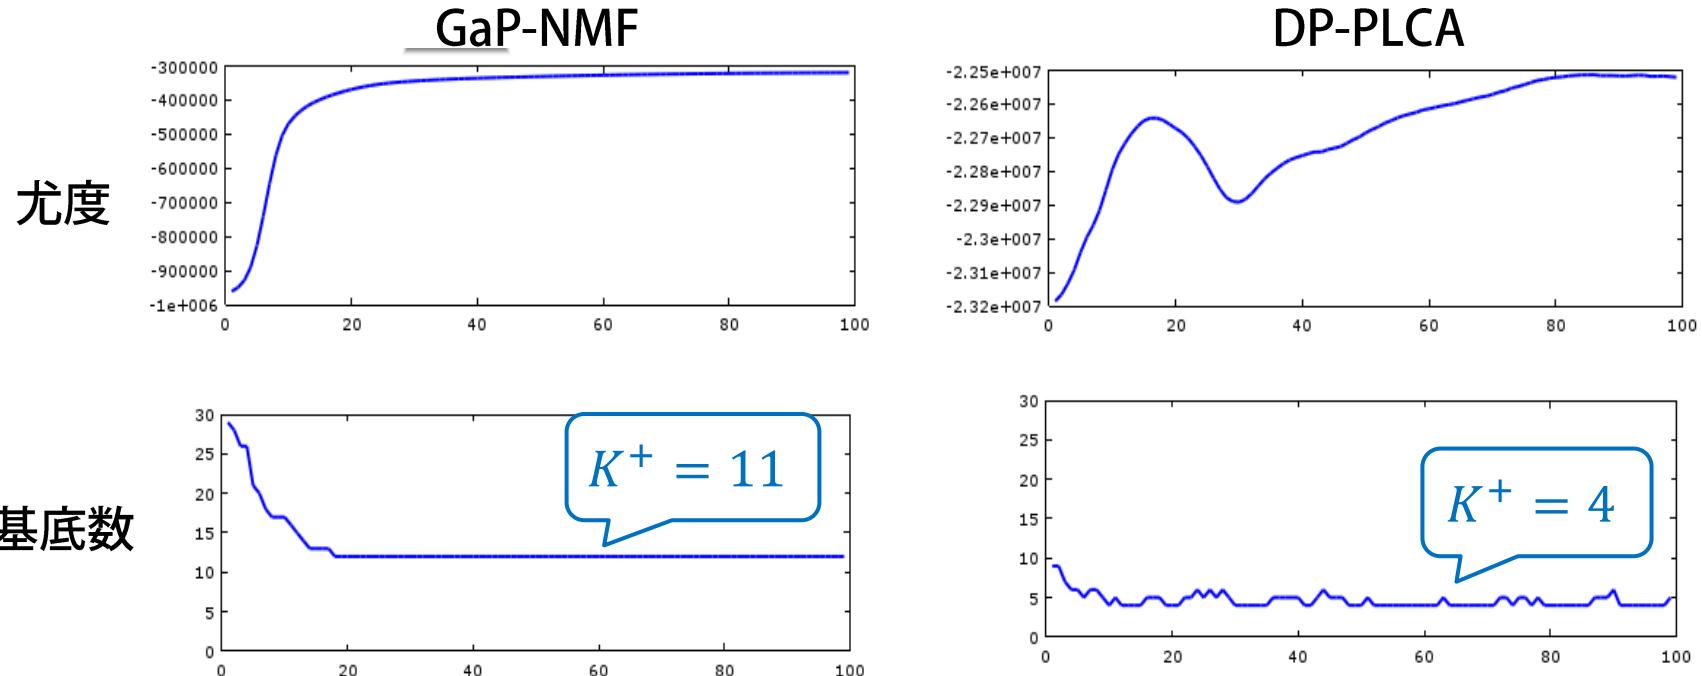
# 人工データ (平均振幅=1)

- DP-PLCA (Gibbs) は基底数を適切に推定
  - GaP-NMF (VB) は基底数を過剰に見積もってしまう傾向



# 人工データ (平均振幅=10)

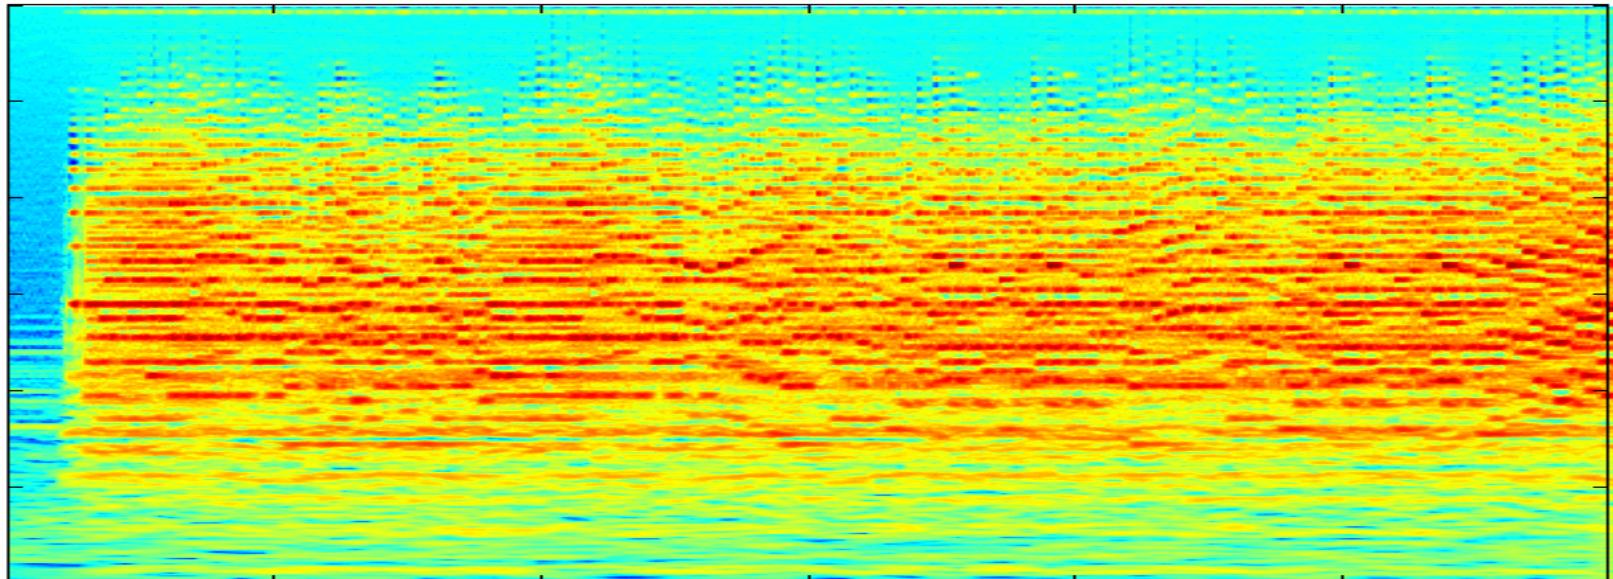
- DP-PLCA (Gibbs) は基底数を適切に推定
  - GaP-NMF (VB) は基底数を過剰に見積もってしまう傾向



# 実験

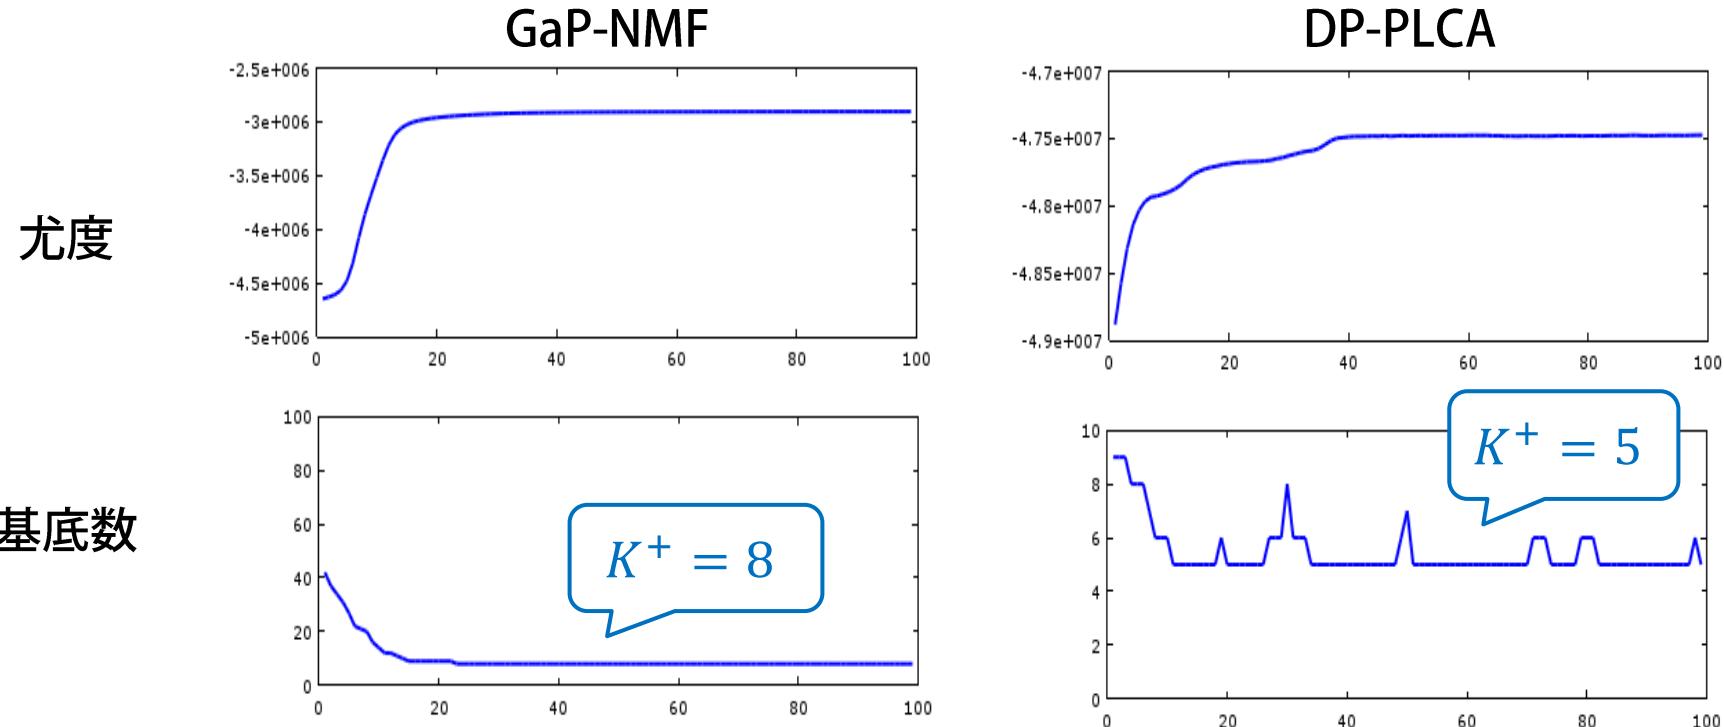
- 実データに適用

- MAPSデータベースのピアノ曲
- 44.1 [kHz] 16 [bits]モノラル信号を、連続ウェーブレット変換
- GaP-NMFとDP-PLCAを比較



# 実データ (平均振幅=1)

- データが非常に複雑でいずれも基底数を過小評価してしまう
  - DP-PLCA (Gibbs) の方がGaP-NMF (VB) より簡単なモデルを選択する傾向



# まとめと今後の課題

- ノンパラメトリックベイズ拡張されたNMFとPLCAを紹介・提案
  - 非負値行列因子分解 (NMF)
    - ガンマ過程に基づく拡張 (GaP-NMF)
      - 閾値処理に依存するが、基底数を過剰に見積もる傾向
    - ベータ過程に基づく拡張 (BP-NMF)
  - 確率的潜在成分解析 (PLCA)
    - ディリクレ過程に基づく拡張 (DP-PLCA)
      - 基底数推定に関しては良好な結果
- 今後の課題：「音量子」の概念に対する物理的な裏付け
  - KL-NMFおよびDP-PLCAとともに、振幅を量子化しておくことが前提
  - 量子化の最小単位をどう設定すべきか？(e.g., フォノン)

# 音声/音楽/音響信号処理の解説書が出ます！

明日を切り拓け！ 挑戦はここから始まる。

## 機械学習プロフェッショナルシリーズ（全29巻）

杉山 将（編集） A5判・予128～160頁・予定本体価格 2,500円～3,000円（税別）

- ・発展著しい機械学習技術の数学的な基礎理論、実用的なアルゴリズム、それらの活用法を簡潔丁寧に解説。
- ・ビッグデータ時代を牽引している若手・中堅の現役研究者が一堂に会した最強の執筆陣！
- ・手に取りやすいページ数で、大事な点をしっかりと押さえた必携書。
- ・データ解析分野に参入したい技術者・大学生向け。

超注目シリーズが  
2015年春より  
いよいよ刊行！

### 第4期刊行予定

ノンパラメトリックベイズ 一点過程と統計的機械学習の数理 佐藤 一誠・著	変分ベイズ学習 中島 伸一・著
グラフィカルモデル 渡辺 有祐・著	脳画像のパターン認識 神谷 之康・著

### 第5期刊行予定

バンディット問題と その解法アルゴリズム 中村 篤祥 / 本多 淳也・著	データアナリティクスにおけるプライバシ保護 佐久間 淳・著
強化学習 森村 哲郎・著	オンライン予測 畠埜 晃平 / 龍本 英二・著

### 第6期刊行予定

関係データ学習 石黒 勝彦 / 林 浩平・著	統計的自然言語処理 持橋 大地・著
統計的音響信号処理 亀岡 弘和 / 吉井 和佳・著	ロボットの運動学習 森本 淳・著

### 第7期刊行予定

道具としての情報幾何 津田 宏治・著	映像認識 篠田 浩一・著
統計的因果探索 清水 昌平・著	