

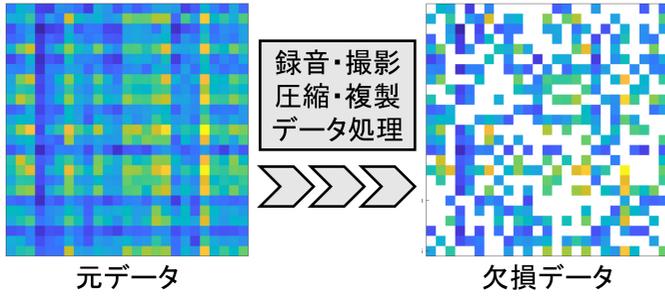
1. 研究背景

欠損値

データには諸要因によって欠損値が発生する

- 画像の白飛び/黒潰れ
- アンケートの未回答
- マイクの音割れ

欠損値を補完することでデータ品質を保ちたい



非負値行列因子分解 (nonnegative matrix factorization: NMF) [Lee, 1999]

非負制約付きの任意基底数 (K 本) による低ランク近似

$$\begin{array}{c}
 \text{非負値観測行列} \\
 \mathbf{X}^{(I \times J)} \\
 \begin{pmatrix} 1 & 2 & 0 & 0 & 1 \\ 1 & 3 & 1 & 2 & 2 \\ 0 & 0 & 3 & 5 & 3 \end{pmatrix} \\
 \begin{matrix} I \\ J \end{matrix}
 \end{array}
 \approx
 \begin{array}{c}
 \text{基底行列} \\
 \mathbf{A}^{(I \times K)} \\
 \begin{pmatrix} 1 & 0 \\ 1 & 1 \\ 0 & 3 \end{pmatrix} \\
 \begin{matrix} I \\ K \end{matrix}
 \end{array}
 \begin{array}{c}
 \text{係数行列} \\
 \mathbf{S}^{(K \times J)} \\
 \begin{pmatrix} 1 & 2 & 0 & 0 & 1 \\ 0 & 0 & 1 & 2 & 1 \end{pmatrix} \\
 \begin{matrix} K \\ J \end{matrix}
 \end{array}
 =
 \begin{array}{c}
 \text{近似行列} \\
 \widehat{\mathbf{X}}^{(I \times J)} \\
 \begin{pmatrix} 1 & 2 & 0 & 0 & 1 \\ 1 & 2 & 1 & 2 & 2 \\ 0 & 0 & 3 & 6 & 3 \end{pmatrix} \\
 \begin{matrix} I \\ J \end{matrix}
 \end{array}$$

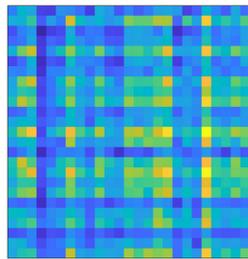
学習不要で基底行列と係数行列に分解近似する

2. NMFによる行列補完

NMFを用いたナイーブな行列補完 [Kitamura, 2014]

欠損要素を無視してNMFのコスト関数値を最小化

$$\begin{array}{l}
 \text{Minimize } \sum_{i,j} m_{ij} \mathcal{D}(x_{ij} | \sum_k a_{ik} s_{kj}) \\
 \text{s.t. } a_{ik}, s_{kj} \geq 0 \quad \forall i, j, k
 \end{array}$$



上記欠損データのNMFに基づく補完

低ランクかつ元データの基底数が既知の場合において高精度に補完可能

実際は...
ノイズによりフルランク化する欠損データから基底数の予測は困難

3. 提案手法

正則化付きNMF

正則化項の最小化のため、正則化項に沿った挙動を示す

コサイン類似度罰則項付きNMF [Iwase&Kitamura, 2022]

- コサイン類似度: 直交化するほどコスト値が小さくなる正則項

正則化付き行列補完NMF

コサイン類似度を用いた基底ベクトル同士の直交化

$$\begin{array}{l}
 \text{Minimize } \sum_{i,j} m_{i,j} \mathcal{D}(x_{i,j} | \sum_k a_{i,k} s_{k,j}) + \mu \sum_k \sum_{k'=k+1} \mathcal{D}_{\cos}(\mathbf{a}_k | \mathbf{a}_{k'}) \\
 \text{s.t. } a_{i,k}, s_{k,j} \geq 0 \quad \forall i, j, k
 \end{array}$$

コサイン類似度正則化項

コサイン類似度正則化項

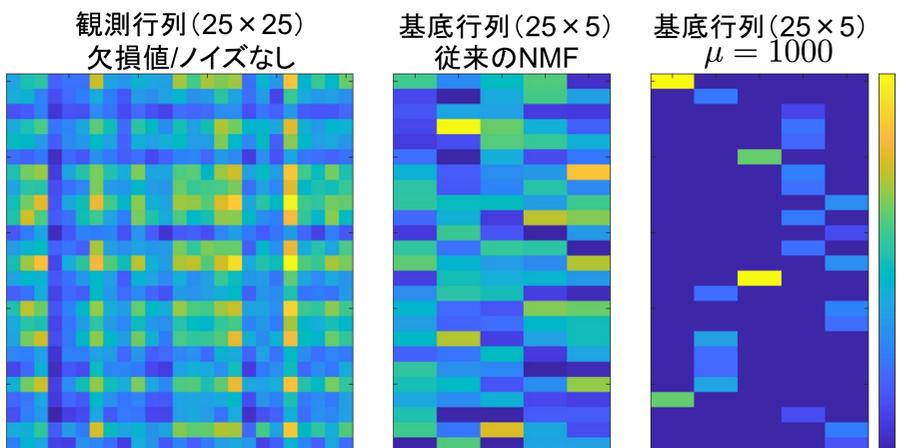
- 重み係数 μ で正則化項が最適化に与える影響の強さを調整する
- 基底ベクトル同士が直交に近づくほど値が小さくなる

$$\mu \sum_k \sum_{k'=k+1} \mathcal{D}_{\cos}(\mathbf{a}_k | \mathbf{a}_{k'}) = \mu \sum_k \sum_{k'=k+1} \frac{\sum_i a_{i,k} a_{i,k'}}{(\sum_i a_{i,k}^2)^{\frac{1}{2}} (\sum_i a_{i,k'}^2)^{\frac{1}{2}}}$$

重み係数

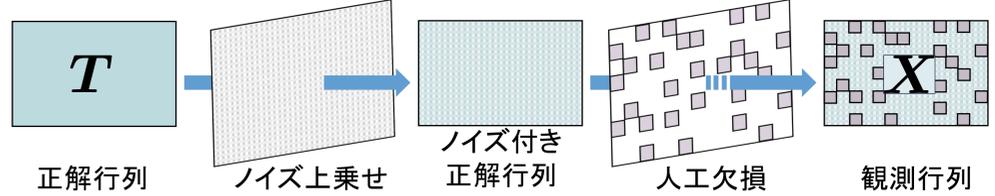
基底行列の直交化

- よりスパースになり直交に近づいている



4. 人工欠損行列の補完実験

乱数生成した人工欠損行列の補完実験

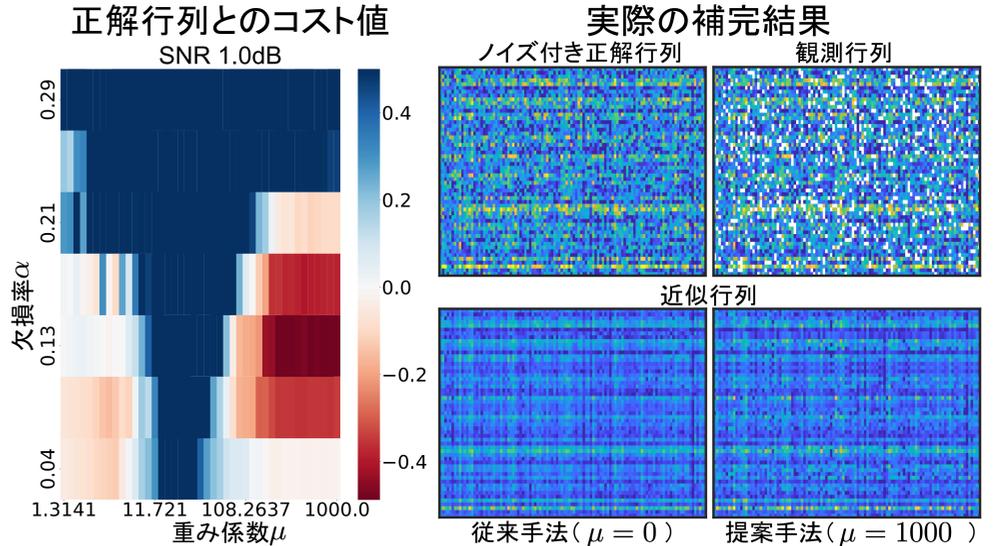


1. 指数乱数を用いたサイズ $I \times J$, ランク K の正解行列 S の生成
2. 所望のSNR [dB]と欠損率 α [%]に沿ったノイズと欠損値を生成
3. 観測行列を行列補完し補完精度を従来法と比較 → 観測行列 X

- 従来手法: KLNMF (KL距離に基づくコストを最小化するNMF)
- 評価値: 正解行列と補完行列間のKL距離の大きさ
- 欠損率 α , SNR, 重み係数 μ の様々な条件を検証

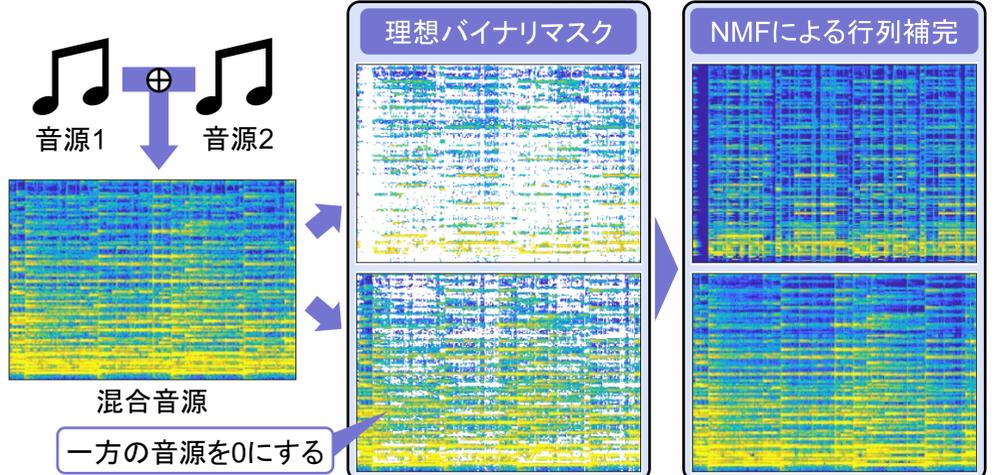
実験結果 (赤いほど補完精度向上)

欠損率10%前後において性能向上がみられる



5. スペクトログラムの補完実験

バイナリマスクスペクトログラムの補完実験



1. 2音源を混合し時間周波数領域へ変換 (STFT)
2. 各音源をもとに理想バイナリマスクをかけスペクトログラム分離
3. 分離スペクトログラムを行列補完し無補完時と比較

音源にはSiSEC2011 [Araki+, 2012]のbearlin-roadsを使用

音源1: "dev1_bearlin-roads_snip_85_99_acoustic_guit_main.wav" (ギター)

音源2: "dev1_bearlin-roads_snip_85_99_piano.wav" (ピアノ)

評価値: ひずみの改善量 (SAR improvement: SARi)

実験結果 (赤いほど補完精度向上)

- 音源1: 従来手法より改善するも無補完時には及ばず
- 音源2: 無補完時に比べひずみが1dB程度改善

