

第21回学習物理領域セミナー + 第73回DLAP

行列分解問題へのベイズ統計学的アプローチ



MLPhYs

2025/11/20

茨城大学 竹田 晃人

A 行列分解問題とその種類

B 行列分解問題とベイズ統計学
物理(統計物理)とのつながり


解説
部分

C スパース行列分解に対する変分ベイズ解析

D Hopfieldモデルに対する解析手法と行列分解問題との関係

独自の
研究


- 本研究の内容は、以下の方々との共同研究に基づきます。
川澄亮太氏(群馬大学), 玉井智貴氏, 遠藤優介氏((元)茨城大学)
- セミナー当日に使用したファイルから一部(著作権関係)を
削除していますので御了承ください。また, 細かい修正も行っています。



- 既知の観測行列 V から行列積を構成する未知の分解行列 A と B を決定
- 適切な問題設定の下で分解行列は観測行列の特徴量を含む
→ 機械学習の問題で重要 例えば 特異値分解(SVD)や主成分分析(PCA)も行列分解
- 機械学習の実問題でも頻出(例については後述)
- ニューラルネットワークとも関係


● 低ランク行列分解

- H が小さい場合 (V から少数の特徴量を抽出)
 - ※行列分解では一般に低ランク性を課すことが多い
- 特異値分解 (SVD) を使うことで低ランク近似が可能
- 原情報の圧縮に利用可能 (画像データの低次元圧縮等)



オートエンコーダ(自己符号器)

Hinton-Salakhutdinov (2006)



- 入力情報と出力情報が一致するように学習するニューラルネットワーク
- 中間層次元 (H) < 入力層次元 = 出力層次元 (L)
- 学習が進むと, 中間層には入力情報の次元圧縮情報が格納

→ 次元削減器

$$v = f(Ab)$$

出力層 (入力層) 非線形関数 復号器側結合重み 中間層

- $f(x) = x$ (線形関数)
- 入力情報を M 個使う

入力情報=出力情報(M 個, L 次元)

v_1, v_2, \dots, v_M

復号器側結合重み

A

中間層の情報(M 個, H 次元)


b_1, b_2, \dots, b_M

$$\begin{matrix} M \\ L \end{matrix} V \cong \begin{matrix} H \\ L \end{matrix} A \begin{matrix} M \\ H \end{matrix} B$$

低ランク行列分解はある種のオートエンコーダ


● 非負値行列分解

- V, A, B の成分が非負
- データが非負である場合（画素値，信号振幅，評価値…）の特徴抽出方法
- A, B を交互に求めるアルゴリズム（Lee-Seung (2000) 等）
- 音源分離，文書等のクラスタリング，バイオインフォマティクス等応用多数




● 行列補完問題

- V を全て観測できないが, V の未観測成分を知りたい
- V の観測可能成分のみから分解行列 A, B を計算(推定)し, それを基に V の未観測成分を補完
- 推薦システム(協調フィルタリング), 画像修復等にご利用可能



● スパース行列分解


- 片側の分解行列がスパース (ゼロ成分を多く含む)
- 観測行列の潜在的なスパース表現(B)とその基底(A , 辞書)を求める
スパース学習では重要, 神経科学でも重要(スパースコーディング)
- アルゴリズムは多数提案 (例: MOD, K-SVD, sparsePCA)



ベイズ推定の形式で分解行列の性質を調べる

分解行列解 A, B の事後分布 尤度(= V, A, B の関係) 事前分布

$$P(\mathbf{A}, \mathbf{B} | \mathbf{V}) \propto P(\mathbf{V} | \mathbf{A}, \mathbf{B}) P(\mathbf{A}) P(\mathbf{B})$$



- 尤度でよく使われる設定: V にガウスノイズ行列 E が加わる

$$P(\mathbf{V} | \mathbf{A}, \mathbf{B}) \propto \exp \left(-\frac{1}{\sigma^2} \|\mathbf{V} - \mathbf{AB}\|_{\text{FRO}}^2 \right) \quad \|\mathbf{X}\|_{\text{FRO}} = \sqrt{\sum_{ij} (X_{ij})^2} \quad \text{フロベニウスノルム}$$

- 事前分布に関する設定: 分解行列 A, B の性質を決定 (簡単なのはガウス分布)

目的 • 分解行列 A, B の推定

- ← 事後分布の最大解 (MAP解) を求める: **難しい**
- ← 周辺化事後分布を計算 (着目成分以外を積分し除く) し各行列要素を推定: **難しい**
 - ・ 上記のガウスノイズの尤度には, A, B の4次項 (4体相互作用) が入る
 - ・ 事前分布が複雑な形だと, さらに周辺分布を求めるのが困難

$$P(A_{ij} | \mathbf{V}) = \int d\mathbf{A}_{(ij \text{ 以外})} d\mathbf{B} P(\mathbf{A}, \mathbf{B} | \mathbf{V})$$

周辺化事後分布

• 行列分解問題の解の典型的な性質の解析

これらは簡単にはできない → 様々な解析技術が必要

ベイズ推定による行列分解の解析手法はいくつか知られている

(※ほぼ, ランダム系に対する統計力学的手法が由来)

(1) サンプリングによる手法 (マルコフ連鎖モンテカルロ等)

確率分布からのサンプリング

(2) レプリカトリック

自由エネルギーのランダム平均の手法

(3) 近似メッセージ伝搬法 (AMP)

Bethe近似法を発展させた局所物理量(周辺分布)の評価法


(4) Thouless-Anderson-Palmer (TAP) 方程式

元々はスピングラスの局所物理量・自由エネルギーの評価形式

(5) 変分ベイズ法

変分法による自由エネルギーの評価形式

- ◆ サンプリングによる手法（マルコフ連鎖モンテカルロ等）
 実際の分解行列解の求解を確率分布のサンプリングにより実施
 （ベイズ推定による分解行列解の解析的表現を最後まで求めない）



$$P(\mathbf{A}, \mathbf{B} | \mathbf{V}) \propto P(\mathbf{V} | \mathbf{A}, \mathbf{B}) P(\mathbf{A}) P(\mathbf{B})$$

分解行列解 \mathbf{A}, \mathbf{B} の事後分布 尤度(= $\mathbf{V}, \mathbf{A}, \mathbf{B}$ の関係) 事前分布

左辺の事後分布に従う具体的な分解行列 \mathbf{A}, \mathbf{B} をサンプリングにより生成

Salakhutdinov–Mnih (2008)

$$\begin{matrix} & M \\ L & \boxed{V} \\ & \text{観測行列} \end{matrix} = \begin{matrix} & H \\ L & \boxed{A} \\ & \text{分解行列} \end{matrix} \begin{matrix} & M \\ H & \boxed{B} \\ & \text{分解行列} \end{matrix} + \begin{matrix} & M \\ & \boxed{E} \\ & \text{ノイズ行列} \end{matrix}$$

階層的ベイズモデル

$$P(\mathbf{A}, \mathbf{B} | \mathbf{V}) \propto P(\mathbf{V} | \mathbf{A}, \mathbf{B}) P(\mathbf{A} | \boldsymbol{\mu}_A, \mathbf{C}_A) P(\mathbf{B} | \boldsymbol{\mu}_B, \mathbf{C}_B)$$

事後分布 尤度 事前分布 (パラメータ含む)

- 尤度 (ノイズ行列 E がガウス分布):

$$P(\mathbf{V} | \mathbf{A}, \mathbf{B}) \propto \exp \left(-\frac{1}{\sigma^2} \|\mathbf{V} - \mathbf{AB}\|_{\text{FRO}}^2 \right)$$

- 事前分布 (多次元ガウス分布, パラメータ付)

$$P(\mathbf{A} | \boldsymbol{\mu}_A, \mathbf{C}_A) = \prod_{i=1}^N \mathcal{N}(a_i | \boldsymbol{\mu}_A, \mathbf{C}_A^{-1})$$

$$P(\mathbf{B} | \boldsymbol{\mu}_B, \mathbf{C}_B) = \prod_{i=1}^N \mathcal{N}(b_i | \boldsymbol{\mu}_B, \mathbf{C}_B^{-1})$$

- 事前分布のパラメータ (平均と共分散行列) の分布 (ガウス–ウイシャート分布)

$$P(\boldsymbol{\mu}_A, \mathbf{C}_A) = \mathcal{N}(\boldsymbol{\mu}_A | \boldsymbol{\mu}_0, (\beta_0 \mathbf{C}_A)^{-1}) \mathcal{W}(\mathbf{C}_A | \mathbf{W}_0, \nu_0)$$

$$P(\boldsymbol{\mu}_B, \mathbf{C}_B) = \mathcal{N}(\boldsymbol{\mu}_B | \boldsymbol{\mu}_0, (\beta_0 \mathbf{C}_B)^{-1}) \mathcal{W}(\mathbf{C}_B | \mathbf{W}_0, \nu_0)$$

$$\boldsymbol{\mu}_A, \mathbf{C}_A \longrightarrow \boldsymbol{\mu}_B, \mathbf{C}_B \longrightarrow \mathbf{A} \longrightarrow \mathbf{B}$$

の順でサンプリングを繰り返す → 分解行列解 (マルコフ連鎖モンテカルロ法など)

応用例 (手法のテスト): Netflix の映画レーティング予測 (行列補完問題)

◆ レプリカトリック

行列分解問題を自由エネルギー形式に落とし、
ランダム平均をレプリカトリックにより実行し、分解行列解の典型的な性質を評価

Sakata-Kabashima (2013)

スパース行列分解の解の典型的な性能を調べる

$$\begin{array}{c} M \\ L \end{array} \begin{array}{c} \boxed{V} \\ = A_0 B_0 \end{array} = \begin{array}{c} L \\ H \end{array} \begin{array}{c} \boxed{A} \end{array} \begin{array}{c} H \\ M \end{array} \begin{array}{c} \boxed{B} \end{array}$$

The diagram illustrates the matrix decomposition $V = AB$. Matrix V is of size $L \times M$ and is represented by a blue box. Matrix A is of size $L \times H$ and is represented by a red box. Matrix B is of size $H \times M$ and is represented by an orange box with a sparse pattern of zeros. The dimensions L , M , and H are indicated by labels above and to the left of the respective matrices.

以下の最適化問題の求解でスパース行列分解を実施した場合の典型性能解析
(用意した分解行列解(埋め込み解) A_0, B_0 が実際に求めた解と一致するか?)

$$\min_{A, B} \|V - AB\|_{\text{FRO}}^2 \quad \text{subj. to} \quad \|A\|_{\text{FRO}}^2 = LH \quad \|B\|_0 = HM \theta$$

$$\|B\|_0 = \sum_{ij} \mathbf{1}(B_{ij} \neq 0)$$

行列 ℓ_0 ノルム
(非ゼロ成分数)

↑
非ゼロ成分
の割合

ベイズによる定式化と分配関数

$$\min_{A,B} \|A_0 B_0 - AB\|_{\text{FRO}}^2 \quad \text{subj. to} \quad \|A\|_{\text{FRO}}^2 = LH \quad \|B\|_0 = HM\theta$$

$$L \overset{M}{\underset{= A_0 B_0}{\boxed{V}}} = L \overset{H}{\boxed{A}} H \overset{M}{\underset{\begin{smallmatrix} 0 & & 0 \\ & 0 & \\ 0 & & 0 \end{smallmatrix}}{\boxed{B}}}$$

$$P(\underset{\text{事後分布}}{A, B} \mid A_0, B_0) \propto \underset{\text{尤度}}{P(A_0, B_0 \mid A, B)} \underset{\text{事前分布}}{P(A)P(B)}$$

- 尤度 (ボルツマン分布として設定, ゼロ温度で最適化問題)

$$P(A, B \mid A_0, B_0) \propto \exp\left(-\frac{\beta}{2H} \|AB - A_0 B_0\|_{\text{FRO}}^2\right)$$

- 事前分布 (A は正規化条件, B は非ゼロ成分数を固定する制約)

$$P(A) = \delta(\|A\|_{\text{FRO}}^2 - LH) \quad P(B) = \delta(\|B\|_0 - HM\theta)$$

- 分配関数（ベイズ統計学としては周辺尤度）

$$\begin{aligned}
 Z &= P(A_0, B_0) \\
 &= \int dA \int dB P(V|A, B) P(A) P(B) \\
 &= \int dA \int dB \exp\left(-\frac{\beta}{2H} \|AB - A_0 B_0\|_{\text{FRO}}^2\right) \delta(\|A\|_{\text{FRO}}^2 - LH) \delta(\|B\|_0 - HM\theta)
 \end{aligned}$$

$$\begin{matrix} & M \\ L & \boxed{V} \\ & = A_0 B_0 \end{matrix} = \begin{matrix} & H \\ L & \boxed{A} \end{matrix} \begin{matrix} & M \\ H & \boxed{B} \end{matrix}$$


- 最適化の解の典型的性質 → 復元成功相と失敗相の自由エネルギー比較
※自由エネルギーの正解行列 A_0, B_0 での平均操作の際にレプリカトリックが必要

- 自由エネルギーの解析から…

埋め込み解を取り出せる条件が議論可能

例：次元 M を増加 → 埋め込み解が取り出せる M の閾値が存在

（成功相が失敗相より自由エネルギーが低くなる）




◆ 近似メッセージ伝搬法 (AMP)


ベイズ行列分解のアルゴリズム (および性能評価法) をメッセージ伝搬法に基づき構成

分解行列 A, B の特定の行列要素の周辺分布を計算し, 行列要素を推定
(物理的には1体問題化のための計算手法)

- ・平均場近似 = 着目している変数以外を外場(平均場)として近似
- ・Bethe近似 = 近接サイトの影響まで厳密に計算し, それ以外の影響は外場(cavity場)
→ 相互作用がスパースな系で特に有効な近似
- ・メッセージ伝搬法 = Bethe近似に基づき, 周辺分布 (物理的には局所磁化等) を求めるアルゴリズム
- ・近似メッセージ伝搬法 (AMP)
= 密な相互作用を持つ系で, ガウス近似を利用しメッセージ伝搬法を精密化・高速化したもの




平均場近似
着目変数以外は
外場(平均場)
として表現



Bethe近似
着目変数の近接サイトまでは厳密
それ以外は外場 (cavity場)

Kabashima-Krzakala-Mézard-Sakata-Zdeborová (2016)

一般の行列分解の問題について, AMP (正確にはgeneralized AMP) で行列を分解する手法を提案



行列分解を表すファクターグラフ, このグラフ上をメッセージ伝搬

$$V = A B$$

$$V \text{ の分散 } V_{\mu l}^t = \frac{1}{N} \sum_j [c_{jl}(t) s_{\mu j}(t) + c_{jl}(t) \hat{f}_{\mu j}^2(t) + \hat{x}_{jl}^2(t) s_{\mu j}(t)]$$

$$V \text{ の期待値 } \omega_{\mu l}^t = \frac{1}{\sqrt{N}} \sum_j \hat{x}_{jl}(t) \hat{f}_{\mu j}(t) - g_{\text{out}}(\omega_{\mu l}^{t-1}, y_{\mu l}, V_{\mu l}^{t-1}) \\ \times \frac{1}{N} \sum_j [\hat{f}_{\mu j}(t) \hat{f}_{\mu j}(t-1) c_{jl}(t) + \hat{x}_{jl}(t) \hat{x}_{jl}(t-1) s_{\mu j}(t)]$$

$$B \text{ の分散 } (\Sigma_{il}^t)^{-1} = \frac{1}{N} \sum_{\mu} \left\{ -\partial_{\omega} g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) [\hat{f}_{\mu i}^2(t) + s_{\mu i}(t)] - g_{\text{out}}^2(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) s_{\mu i}(t) \right\}$$

$$B \text{ の期待値 } T_{il}^t = \Sigma_{il}^t \left\{ \frac{1}{\sqrt{N}} \sum_{\mu} g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) \hat{f}_{\mu i}(t) - \hat{x}_{il}(t) \frac{1}{N} \sum_{\mu} \hat{f}_{\mu i}^2(t) \partial_{\omega} g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) \right. \\ \left. - \hat{x}_{il}(t-1) \frac{1}{N} \sum_{\mu} s_{\mu i}(t) g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) g_{\text{out}}(\omega_{\mu l}^{t-1}, y_{\mu l}, V_{\mu l}^{t-1}) \right\}$$

$$A \text{ の分散 } (Z_{\mu i}^t)^{-1} = \frac{1}{N} \sum_l \left\{ -\partial_{\omega} g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) [\hat{x}_{il}^2(t) + c_{il}(t)] - g_{\text{out}}^2(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) c_{il}(t) \right\}$$

$$A \text{ の期待値 } W_{\mu i}^t = Z_{\mu i}^t \left\{ \frac{1}{\sqrt{N}} \sum_l g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) \hat{x}_{il}(t) - \hat{f}_{\mu i}(t) \frac{1}{N} \sum_l \hat{x}_{il}^2(t) \partial_{\omega} g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) \right. \\ \left. - \hat{f}_{\mu i}(t-1) \frac{1}{N} \sum_l c_{il}(t) g_{\text{out}}(\omega_{\mu l}^t, y_{\mu l}, V_{\mu l}^t) g_{\text{out}}(\omega_{\mu l}^{t-1}, y_{\mu l}, V_{\mu l}^{t-1}) \right\}$$

$$\hat{x}_{il}(t+1) = f_X(\Sigma_{il}^t, T_{il}^t), c_{il}(t+1) = f_c(\Sigma_{il}^t, T_{il}^t),$$

$$\hat{f}_{\mu i}(t+1) = f_F(Z_{\mu i}^t, W_{\mu i}^t), s_{\mu i}(t+1) = f_s(Z_{\mu i}^t, W_{\mu i}^t)$$

(細かい記号の定義は原論文を参照)

- AMPに状態発展法(State Evolution, SE)を組み合わせることで, 行列分解問題の典型性能解析が可能
→ スパース行列分解, 行列補完問題… 等様々な行列分解問題が解析できる

◆ Thouless–Anderson–Palmer(TAP)方程式

・スピングラスのThouless–Anderson–Palmer(TAP)形式(局所磁化の記述形式)による行列分解の解析

- ・AMPによる行列分解解析手法には問題が指摘(厳密ではなく近似)
- ・TAP自由エネルギーをPlefka–Georges–Yedidia(PGY)展開 = 相互作用係数展開で評価
→ AMPは展開の2次までの近似, 一般には3次以上も考慮する必要あり

※この方法で独立成分分析(ICA)を解析中 (Endo–Takeda, STATPHYS29)

Maillard–Krzakala–Mézard–Zdeborová (2022)

$B = A^T$ となる対称行列(以下の A がガウス型ランダム行列→ $A A^T$ がウイシャート行列)の行列分解問題

$$\begin{matrix} L & & & & \\ & L & & & \\ & & \mathbf{V} & & \\ & & & & \\ L & & & & \end{matrix} = \begin{matrix} & & H & & \\ & L & & & \\ & & \mathbf{A} & & \\ & & & & \\ & & H & & \end{matrix} \begin{matrix} & & & L & \\ & & & & \mathbf{A}^T \\ & & & & \\ & & & & \\ & & & & \end{matrix} + \begin{matrix} & & & & \\ & & & & \\ & & \mathbf{E} & & \\ & & & & \\ & & & & \end{matrix}$$

観測行列 分解行列 ノイズ行列
(ウイシャート行列)

ウイシャート行列のノイズ除去問題を解く

(厳密解が別な方法で得られる → Harish–Chandra–Itzykson–Zuber行列積分とブラウン運動の議論)

→ PGYの2次近似 (AMP) は厳密解から少しずれている

◆ 変分ベイズ法

変分自由エネルギー形式により, 分解行列解の統計的性質を変分法で評価

Ilin-Raiko (2010), Nakajima-Sugiyama (2011)

解析の流れ:

$$\begin{array}{c}
 \begin{array}{ccc}
 & M & \\
 L & \boxed{V} & \\
 & \text{観測行列} &
 \end{array}
 =
 \begin{array}{ccc}
 & H & \\
 L & \boxed{A} & H \\
 & \text{分解行列} &
 \end{array}
 \begin{array}{ccc}
 & M & \\
 & \boxed{B} & \\
 & \text{ノイズ行列} &
 \end{array}
 + \begin{array}{ccc}
 & & \\
 & \boxed{E} & \\
 & &
 \end{array}
 \end{array}$$

$$P(\mathbf{A}, \mathbf{B} \mid \mathbf{V}) \propto P(\mathbf{V} \mid \mathbf{A}, \mathbf{B}) P(\mathbf{A}) P(\mathbf{B})$$

分解行列解 \mathbf{A}, \mathbf{B} の事後分布 尤度(= $\mathbf{V}, \mathbf{A}, \mathbf{B}$ の関係) 事前分布



事後分布をそのままの形で \mathbf{A}, \mathbf{B} の推定に使うのは面倒
 → 事後分布 $P(\mathbf{A}, \mathbf{B} \mid \mathbf{V})$ を推定しやすい形に近似する

$$P(\mathbf{A}, \mathbf{B} | V) \propto P(V | \mathbf{A}, \mathbf{B}) P(\mathbf{A}) P(\mathbf{B})$$

Kullback-Leibler情報量を利用 (確率分布間の距離)
(物理的には自由エネルギーに対応)

$$\text{KL}(q(x) \parallel p(x)) = \int dx q(x) \log \frac{q(x)}{p(x)} \quad p(x), q(x) : \text{確率分布}$$

事後分布 $P(\mathbf{A}, \mathbf{B} | V)$ をよく近似する変分試行関数 $r(\mathbf{A}, \mathbf{B})$ を求めたい
→ 次の関数に関する最小化問題を解く必要がある

$$\arg \min_{r(\mathbf{A}, \mathbf{B})} \text{KL}(r(\mathbf{A}, \mathbf{B}) \parallel P(\mathbf{A}, \mathbf{B} | V))$$

$$\rightarrow \arg \min_{r(\mathbf{A}), r(\mathbf{B})} \text{KL}(r(\mathbf{A})r(\mathbf{B}) \parallel P(V | \mathbf{A}, \mathbf{B}) P(\mathbf{A}) P(\mathbf{B}))$$



\mathbf{A}, \mathbf{B} の試行関数は独立とする (近似している)

$$\begin{aligned} & \text{KL}(r(A)r(B) \parallel P(V|A, B)P(A)P(B)) \\ &= \int dA dB \, r(A)r(B) \log \frac{r(A)r(B)}{P(V|A, B)P(A)P(B)} \end{aligned}$$

変分関数の停留条件を求めることで、試行関数が満たす関係式を書く

$$\text{KL}((r(A) + \delta r(A))r(B)) - \text{KL}(r(A)r(B)) = 0$$

$$\longrightarrow r(A) = P(A) \exp \left(\int dB r(B) \log P(V|A, B) \right)$$

$$\text{KL}(r(A)(r(B) + \delta r(B))) - \text{KL}(r(A)r(B)) = 0$$

$$\longrightarrow r(B) = P(B) \exp \left(\int dA r(A) \log P(V|A, B) \right)$$

ここまでは一般的な尤度や事前分布

指数関数の中に試行関数を含む(行列要素の)多重積分が残る

以降は尤度と事前分布を以下のように仮定：

$$P(\mathbf{V}|\mathbf{A}, \mathbf{B}) = \frac{1}{\sqrt{(2\pi\sigma^2)^{LH}}} \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{V} - \mathbf{AB}\|_{\text{FRO}}^2\right) \quad \text{ノイズはガウス分布}$$

$$\left. \begin{aligned} P(\mathbf{A}) &= \frac{1}{\sqrt{(2\pi)^{LH}}} \exp\left(-\frac{1}{2} \text{Tr} \mathbf{AA}^T\right) = \prod_l \prod_h \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} a_{lh}^2\right) \\ P(\mathbf{B}) &= \frac{1}{\sqrt{(2\pi)^{MH}}} \exp\left(-\frac{1}{2} \text{Tr} \mathbf{BB}^T\right) = \prod_m \prod_h \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} b_{mh}^2\right) \end{aligned} \right] \quad \mathbf{A}, \mathbf{B} \text{はガウス事前分布}$$

前述の試行関数の条件にこれらを代入→各試行関数が多次元ガウス分布

$$r(\mathbf{A}) = P(\mathbf{A}) \exp\left(\int d\mathbf{B} r(\mathbf{B}) \log P(\mathbf{V}|\mathbf{A}, \mathbf{B})\right) \longrightarrow r(\mathbf{A}) \propto \exp\left(-\frac{1}{2} \text{Tr}(\mathbf{A} - \hat{\mathbf{A}}) \hat{\Sigma}_A^{-1} (\mathbf{A} - \hat{\mathbf{A}})^T\right) \quad \text{の形}$$

$$r(\mathbf{B}) = P(\mathbf{B}) \exp\left(\int d\mathbf{A} r(\mathbf{A}) \log P(\mathbf{V}|\mathbf{A}, \mathbf{B})\right) \longrightarrow r(\mathbf{B}) \propto \exp\left(-\frac{1}{2} \text{Tr}(\mathbf{B} - \hat{\mathbf{B}}) \hat{\Sigma}_B^{-1} (\mathbf{B} - \hat{\mathbf{B}})^T\right) \quad \text{の形}$$

試行関数の事後分布の平均と共分散行列 $\hat{A}, \hat{B}, \hat{\Sigma}_A, \hat{\Sigma}_B$ が満たす関係式を
試行関数の関係式より導出

$$P(V|A, B) = \frac{1}{\sqrt{(2\pi\sigma^2)^{LH}}} \exp\left(-\frac{1}{2\sigma^2} \|V - AB\|_{\text{FRO}}^2\right)$$

$$r(A) \propto \exp\left(-\frac{1}{2} \text{Tr}(A - \hat{A}) \hat{\Sigma}_A^{-1} (A - \hat{A})^T\right)$$

$$r(B) \propto \exp\left(-\frac{1}{2} \text{Tr}(B - \hat{B}) \hat{\Sigma}_B^{-1} (B - \hat{B})^T\right)$$

$$r(A) = P(A) \exp\left(\int dB r(B) \log P(V|A, B)\right)$$

$$r(B) = P(B) \exp\left(\int dA r(A) \log P(V|A, B)\right)$$

$$A \text{ の事後平均 } \hat{A} = \frac{1}{\sigma^2} V \hat{B} \hat{\Sigma}_A$$

$$B \text{ の事後平均 } \hat{B} = \frac{1}{\sigma^2} \hat{\Sigma}_B \hat{A}^T V$$

$$A \text{ の事後共分散 } \hat{\Sigma}_A = \sigma^2 \left(\hat{B} \hat{B}^T + M \hat{\Sigma}_B + \sigma^2 I_H \right)^{-1}$$

$$B \text{ の事後共分散 } \hat{\Sigma}_B = \sigma^2 \left(\hat{A}^T \hat{A} + L \hat{\Sigma}_A + \sigma^2 I_H \right)^{-1}$$

$\hat{A}, \hat{B}, \hat{\Sigma}_A, \hat{\Sigma}_B$ について閉じた式 \rightarrow 解くことで試行関数が求まり, 行列分解が可能

応用例: 変分ベイズ解を利用し, ノイズあり観測行列のランク推定の精度を特異値により議論

変分ベイズ法の形式で, スパース行列分解の性質を調べる

$$V = A B + E$$

スパース行列

ノイズ行列

- 分解行列の事前分布が両方ともガウス分布 (スパース行列分解ではない)
前述の通り, 変分ベイズ法を利用して分解行列が推定可能
- 分解行列の事前分布がガウス分布とラプラス分布
→ この場合はスパース行列分解問題になる
Kawasumi-KT (2018, 2023) 近似の下で, 分解行列解の表現を書き下せる
→ スパース行列分解アルゴリズムとして使える


$$P([a_{lh}] = \mathbf{A}) \propto \prod_{l=1}^L \prod_{h=1}^H \exp\left(-\frac{a_{lh}^2}{2}\right)$$

\mathbf{A} の事前分布 (ガウス)
→ ℓ_2 正則化


$$P([b_{hm}] = \mathbf{B}) \propto \prod_{h=1}^H \prod_{m=1}^M \exp\left(-\frac{|b_{hm}|}{k}\right)$$

\mathbf{B} の事前分布 (ラプラス)
→ ℓ_1 正則化

k : 正則化係数 (後で重要)



ガウス分布



ラプラス分布
(ゼロ付近の密度が高い)

事前分布をラプラス分布にする
= ℓ_1 正則化
このとき、推定変数をスパースにできる
(推定結果にゼロ成分を多く含ませることが可能)

理由: 事前分布の形状よりも幾何学的な考察が必要
(圧縮センシングなどが分かりやすい)

尤度と事前分布を以下のように仮定

$$P(V|A, B) = \frac{1}{\sqrt{(2\pi\sigma^2)^{LH}}} \exp\left(-\frac{1}{2\sigma^2} \|V - AB\|_{\text{FRO}}^2\right) \quad \text{ノイズはガウス分布}$$

$$P(A) = \frac{1}{\sqrt{(2\pi)^{LH}}} \exp\left(-\frac{1}{2} \text{Tr} AA^T\right) = \prod_l \prod_h \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} a_{lh}^2\right) \quad A \text{はガウス事前分布}$$

$$P(B) \propto \prod_m \prod_h \exp\left(-\frac{1}{k} |b_{mh}| \right)$$

B はラプラス事前分布

試行関数の条件は一般の分布で成り立つが

試行関数が多次元ガウス分布であることは言えない（試行関数の形は不明）


$$r(A) = P(A) \exp\left(\int dB r(B) \log P(V|A, B)\right) \longrightarrow r(A) \propto \exp\left(-\frac{1}{2} \text{Tr}(A - \hat{A}) \hat{\Sigma}_A^{-1} (A - \hat{A})^T\right) \quad \text{の形}$$

$$r(B) = P(B) \exp\left(\int dA r(A) \log P(V|A, B)\right) \longrightarrow r(B) \propto \exp\left(-\frac{1}{2} \text{Tr}(B - \hat{B}) \hat{\Sigma}_B^{-1} (B - \hat{B})^T\right) \quad \text{の形}$$

近似を置かないと解析が進まないので、以下の近似を置く

- 試行関数の成分独立性 (平均場近似) $r(A) = \prod_l \prod_h r_a(a_{lh})$ $r(B) = \prod_h \prod_m r_b(b_{hm})$
- 事後分布の共分散行列 ($H \times H$ 行列) は対角成分のみ持つ (分散成分のみ)
- ラプラス事前分布のパラメータ (ℓ_1 正則化係数) について,
 $k \rightarrow \infty$ を仮定し, $1/k$ 展開 (1次まで)

$$P(B) \propto \prod_m \prod_h \exp\left(-\frac{1}{k} |b_{mh}| \right) \simeq 1 - \frac{1}{k} \sum_{mh} |b_{mh}| + O\left(\frac{1}{k^2}\right)$$



※ $r(B)$ の1次, 2次モーメントを計算したいが, B の多重積分ができない
→ 平均場近似と $1/k$ 展開で1個の積分まで落ちる

$$r(B) = P(B) \exp\left(\int dA r(A) \log P(V|A, B)\right)$$

※ 展開により確率分布が ill-defined になる可能性があるので注意が必要 → 後の話とも関係

以上の試行分布の仮定と事前分布の近似を,
試行分布の一般的な関係式に代入し, 事後平均と事後分散を計算

$$r(A) = P(A) \exp\left(\int d\mathbf{B} r(\mathbf{B}) \log P(V|A, \mathbf{B})\right) \quad r(\mathbf{B}) = P(\mathbf{B}) \exp\left(\int dA r(A) \log P(V|A, \mathbf{B})\right)$$

Kawasumi-KT (2018)

A の事後平均

$$\bar{a}_{lh} = \sum_{h'=1}^H \sum_{m=1}^M v_{lm} (\hat{\Sigma}_{\mathbf{A}l}^{-1})_{hh'} \bar{b}_{h'm}$$

A の事後分散

$$(\Sigma_{\mathbf{A}l})_{hh} = \sigma^2 (\hat{\Sigma}_{\mathbf{A}l}^{-1})_{hh}$$

B の事後平均

$$\bar{b}_{hm} = \sum_{h'=1}^H \sum_{l=1}^L v_{lm} (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{hh'} \bar{a}_{lh'} - \frac{1}{kZ_B} \sum_{h'=1}^H \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h} \text{erf}(\omega_{h'm})$$

B の事後分散

$$(\Sigma_{\mathbf{B}m})_{hh} = \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{hh} - \frac{1}{kZ_B} \sum_{h'=1}^H \sqrt{\frac{2}{\pi \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h'}}} \{ \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h} \}^2 \exp(\omega_{h'm})$$

$$- \left(\frac{1}{kZ_B} \right)^2 \left\{ \sum_{h'=1}^H \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h} \text{erf}(\omega_{h'm}) \right\}^2$$

1/k展開による
補正項

前ページで定義していない変数

$$\omega_{hm} := \frac{1}{\sqrt{2\sigma^2(\hat{\Sigma}_{B_m}^{-1})_{hh}}} \sum_{h'=1}^H \sum_{l=1}^L v_{lm}(\hat{\Sigma}_{B_m}^{-1})_{hh'} \bar{a}_{lh'}$$

$$(\hat{\Sigma}_{A_l})_{hh'} := \sigma^2 \delta_{hh'} + \sum_{m=1}^M ((\Sigma_{B_m})_{hh} \delta_{hh'} + \bar{b}_{hm} \bar{b}_{h'm})$$

$$(\hat{\Sigma}_{B_m})_{hh'} := \sum_{l=1}^L ((\Sigma_{A_l})_{hh} \delta_{hh'} + \bar{a}_{lh} \bar{a}_{lh'})$$

$$S_B := \sum_{h=1}^H \sum_{m=1}^M \left\{ \sqrt{\frac{2\sigma^2(\hat{\Sigma}_{B_m}^{-1})_{hh}}{\pi}} \exp(-\omega_{hm}^2) + \left(\sum_{h'=1}^H \sum_{l=1}^L v_{lm}(\hat{\Sigma}_{B_m}^{-1})_{hh'} \bar{a}_{lh'} \right) \text{erf}(\omega_{hm}) \right\}$$

$$Z_B = 1 - \frac{S_B}{k}$$

行列 B の(近似)事後分布に関する正規化因子
以降の話で重要

$$A \text{ の事後平均} \quad \bar{a}_{lh} = \sum_{h'=1}^H \sum_{m=1}^M v_{lm} (\hat{\Sigma}_{\mathbf{A}l}^{-1})_{hh'} \bar{b}_{h'm}$$

$$A \text{ の事後分散} \quad (\Sigma_{\mathbf{A}l})_{hh} = \sigma^2 (\hat{\Sigma}_{\mathbf{A}l}^{-1})_{hh}$$

$$B \text{ の事後平均} \quad \bar{b}_{hm} = \sum_{h'=1}^H \sum_{l=1}^L v_{lm} (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{hh'} \bar{a}_{lh'} - \frac{1}{kZ_B} \sum_{h'=1}^H \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h} \text{erf}(\omega_{h'm})$$

$$B \text{ の事後分散} \quad (\Sigma_{\mathbf{B}m})_{hh} = \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{hh} - \frac{1}{kZ_B} \sum_{h'=1}^H \sqrt{\frac{2}{\pi \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h'}}} \{ \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h} \}^2 \exp(\omega_{h'm})$$

$$- \left(\frac{1}{kZ_B} \right)^2 \left\{ \sum_{h'=1}^H \sigma^2 (\hat{\Sigma}_{\mathbf{B}m}^{-1})_{h'h} \text{erf}(\omega_{h'm}) \right\}^2$$


1/k展開による
補正項



- 青い部分は全て kZ_B を分母に含む
- これらの項がない場合 ($kZ_B \rightarrow \infty$) は, B の事前分布が **一様分布** の場合
 ─────────→ 青い部分は **ラプラス分布による補正項**
- $kZ_B \rightarrow 0$ では補正項の寄与が大きくなる → 以降の話と関係

前記の解を
逐次代入型アルゴリズムとして
数値実験で評価

- スパース正解行列 B の
非ゼロ成分比は0.5
- ラプラス分布のパラメータ k は
固定し, 様々な値で実験

特定の k の値で
ラプラス事前分布による
スパース行列の再構成が
ガウス事前分布より良好






- B がスパース行列となるには, B の分布の正規化因子である Z_B がほぼ0となるような k を選べばよい
- 十分大きな k では $Z_B \rightarrow 1$ となる (このとき $kZ_B \rightarrow \infty$)

最適な k の値付近で, B の復元結果を可視化 (B : 5×50 行列)



用意した
スパース正解行列 B



ラプラス事前分布で
求めた B



ガウス事前分布で
求めた B



ラプラス事前分布で求めた B は, 用意したスパース行列に近い(が, 少し余計な成分が見える)

※ 行列サイズが大きくなると, 誤差が大きくなってしまう...

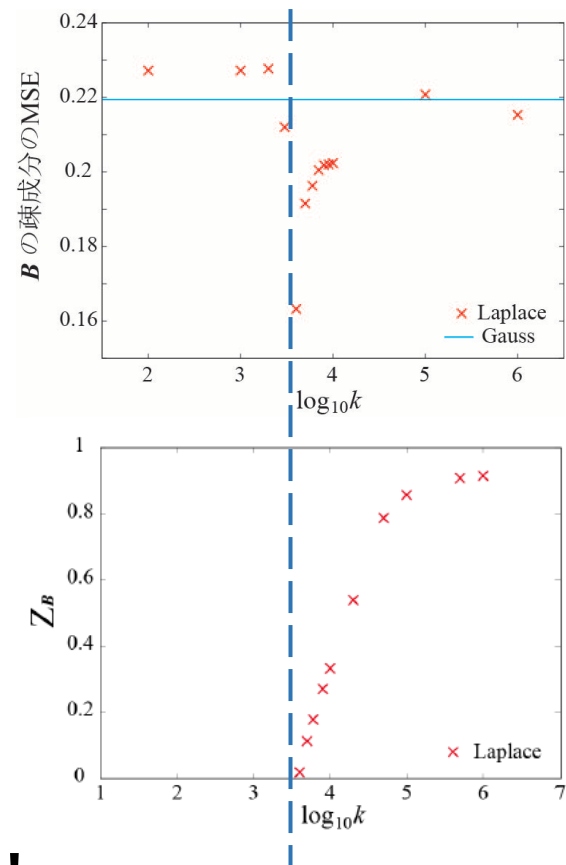
事前分布のパラメータ k の適切な値
= Z_B (近似事後分布の正規化因子) の k に関する零点
(実験からの知見, 理論的には理由は明確ではない)

問題点:

与えられた行列 V に対し, Z_B のゼロ点は解析的には不明
行列分解の数値実験を行わないと, Z_B のゼロ点の位置は不明

➡ 最適な k を知るには, k を変えて実験する必要あり, 面倒!

➡ スパース行列の解を数値的に求めながら,
最適な k を適応的に探索することを考える



スパース行列分解のアルゴリズム実行時に,
ラプラス分布のパラメータ (正則化係数) k を以下のように更新

$$k^{(n)} = (1 - \varepsilon)k^{(n-1)} + \varepsilon S_B^{(n-1)}$$

括弧付き添字: アルゴリズムの更新ステップ数

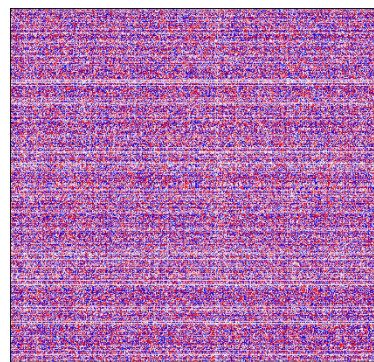
ε : 忘却係数 \rightarrow アルゴリズムを収束させるためのパラメータ ($0 < \varepsilon < 1$)

ε は小さく取る, 大きすぎるとアルゴリズムが不安定化

k が収束すれば, ステップ数 $n \rightarrow \infty$ のときに $k \approx S_B$


$Z_B = 1 - \frac{S_B}{k}$ なので, このとき $Z_B \rightarrow 0$ となりラプラス分布による補正項が効く

元の行列と分解行列解との比較例 ($L = 500, M = 500, H$ (中間次元) $= 30, B$ の非ゼロ成分比 $= 0.2$)




V


A
(用意した
正解)





B
(用意した
正解)



A
(求めた
分解行列)



B
(求めた
分解行列)




行列サイズが大きくても


用意した正解と分解行列がほぼ一致, 差はほとんどない → 適応的な k の決定の結果

スパース行列復元のアルゴリズムの性質

Kawasumi-KT (2023)



スパース性が高い領域では
正解スパース行列がほぼ復元できている




反復アルゴリズムを続けると
ある点で誤差がほぼゼロになる (ただし収束が遅い)

既存手法との比較:

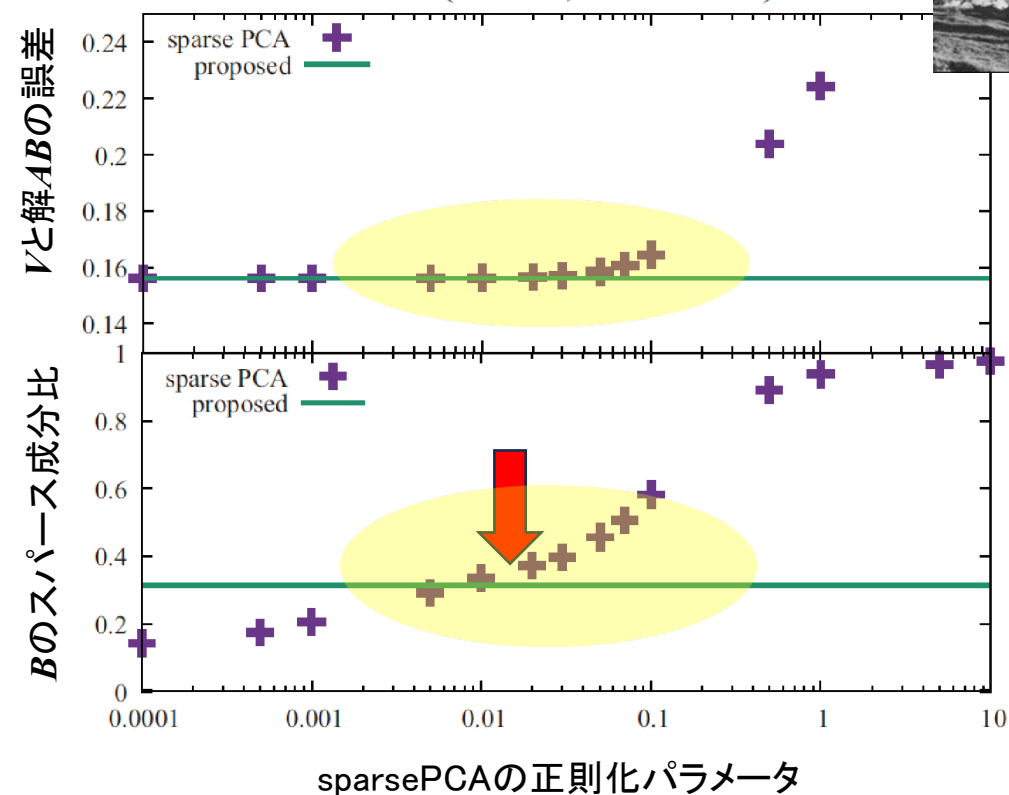
sparsePCA (Mairal et al. (2009)): $\min_{A,B} (\|V - AB\|_{\text{FRO}}^2 + \tilde{\alpha} \|B\|_1)$ を解くアルゴリズム

Kawasumi-KT (2023)

(A) 人工データ: 正解として与えた行列 A, B の求解



(B) 実画像のスパース行列分解



Tree:
The USC-SIPI
Image Database


スパース性が高い領域で正解行列の再現性が高い
sparsePCAと同程度かそれ以上

積 AB の誤差が最低の領域内で
 B のスパース性が高い解を得ている？



既存手法 (sparsePCA) との比較 ($H = 40$)

Kawasumi-KT (2023)


Tree





Moon surface



Aerial



Clock



どの画像でも
同じ傾向が見える

以上の画像データはThe USC-SIPI Image Databaseより引用

変分ベイズ法で行列分解問題が解けていることが分かった
解の性質とアルゴリズムの動的挙動が解析的に知りたい…
→ スパース行列分解の変分ベイズ解は複雑なので面倒？

まず事前分布がガウス分布である行列分解モデルから

Nakajima-Sugiyama (2011)

$$\hat{A} = \frac{1}{\sigma^2} V \hat{B} \hat{\Sigma}_A$$

$$\hat{B} = \frac{1}{\sigma^2} \hat{\Sigma}_B \hat{A}^T V$$

$$\hat{\Sigma}_A = \sigma^2 \left(\hat{B} \hat{B}^T + M \hat{\Sigma}_B + \sigma^2 I_H \right)^{-1}$$

$$\hat{\Sigma}_B = \sigma^2 \left(\hat{A}^T \hat{A} + L \hat{\Sigma}_A + \sigma^2 I_H \right)^{-1}$$

$\hat{A}, \hat{B} : A, B$ の事後平均

$\hat{\Sigma}_A, \hat{\Sigma}_B : A, B$ の事後共分散

逐次代入で解くと分解行列解が得られる → 行列分解アルゴリズムとして利用可能

Hopfieldモデル

複数のニューロンの状態



$$\begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_L \end{bmatrix}$$

想起パターン



$$\begin{bmatrix} \xi_1^{(1)} \\ \xi_2^{(1)} \\ \vdots \\ \xi_L^{(1)} \end{bmatrix} \begin{bmatrix} \xi_1^{(2)} \\ \xi_2^{(2)} \\ \vdots \\ \xi_L^{(2)} \end{bmatrix} \dots \begin{bmatrix} \xi_1^{(H)} \\ \xi_2^{(H)} \\ \vdots \\ \xi_L^{(H)} \end{bmatrix}$$

一致するか
評価

行列分解

復元行列 \hat{A} (変分ベイズ解)
(←ニューロン)

$$\begin{bmatrix} \hat{A}_1 & \dots & \hat{A}_h & \dots & \hat{A}_H \end{bmatrix}$$

原行列 A (正解行列)
(←想起パターン)

$$\begin{bmatrix} A_1 & \dots & A_h & \dots & A_H \end{bmatrix}$$

一致するか
評価

Hopfieldモデル(連想記憶モデル)と行列分解を上のように対応

- 正解行列の特定のベクトル → 想起したいパターン
- 復元行列の特定のベクトル → ニューロンの状態

Hopfieldモデルの古典的解析手法を行列分解に応用できるか？

- Amit-Gutfreund-Sompolinsky (1985, 1987), 自由エネルギー形式, 想起可能性
- Shiino-Fukai (1993) → 学習則ベース, 想起可能性
- Amari-Maginu (1988) → 学習則ベース, 想起ダイナミクス

$$\hat{A} = \frac{1}{\sigma^2} V \hat{B} \hat{\Sigma}_A$$

$$\hat{B} = \frac{1}{\sigma^2} \hat{\Sigma}_B \hat{A}^T V$$

$$\hat{\Sigma}_A = \sigma^2 \left(\hat{B} \hat{B}^T + M \hat{\Sigma}_B + \sigma^2 \mathbf{I}_H \right)^{-1}$$

$$\hat{\Sigma}_B = \sigma^2 \left(\hat{A}^T \hat{A} + L \hat{\Sigma}_A + \sigma^2 \mathbf{I}_H \right)^{-1}$$

これらは行列要素に依存する量 → 行列分解の性質を表す大域的な量の性質が知りたい

連想記憶における信号雑音分離との類似性を利用

→ 上記を連則記憶の学習則とみなし, 信号(埋め込んだ正解行列)と雑音成分に分けたい

信号成分 → 正解との重なり

(正解行列と分解行列との
h 番目のベクトルの重なり)

$$\mu_h = \sum_{l=1}^L a_{lh} \hat{a}_{lh}$$

$$v_h = \sum_{m=1}^M b_{hm} \hat{b}_{hm}$$

雑音成分 → ガウス雑音

(正解行列と分解行列との
異なる行/列のベクトルの重なり)

$$\sum_{l=1}^L a_{lh'} \hat{a}_{lh} \sim N(0, \sigma_{ah'}^2)$$

$$\sum_{m=1}^M b_{h'm} \hat{b}_{hm} \sim N(0, \sigma_{bh'}^2) \quad (h' \neq h)$$

A, B ともガウス事前分布の場合の変分ベイズ解は
信号雑音分離仮説が正しければ, 次を満たすと予想. (変数8個の関係式)

Tamai-Kawasumi-KT, STATPHYS28

・正解との重なり

$$\mu_h = LM \frac{\hat{\Sigma}_{Ah}}{\sigma^2} (\nu_h + M \mu_h \hat{\Sigma}_{Bh})$$

$$\nu_h = LM \frac{\hat{\Sigma}_{Bh}}{\sigma^2} (\mu_h + L \nu_h \hat{\Sigma}_{Ah})$$

・干渉ノイズ分散

$$\sigma_a^2 = \left(LM \frac{\hat{\Sigma}_{Ah}}{\sigma^2} \right)^2 \left(\sigma_b^2 + \left(\frac{\hat{\Sigma}_{Bh}}{L} \right)^2 \sigma_a^2 \right)$$

$$\sigma_b^2 = \left(LM \frac{\hat{\Sigma}_{Bh}}{\sigma^2} \right)^2 \left(\sigma_a^2 + \left(\frac{\hat{\Sigma}_{Ah}}{M} \right)^2 \sigma_b^2 \right)$$

・共分散行列の
対角成分

$$\hat{\Sigma}_{Bh} = \frac{\sigma^2 / (LM)}{(1/L)(\sigma^2 / (LM)) + L \hat{\Sigma}_{Ah} + \rho_A}$$

$$\hat{\Sigma}_{Ah} = \frac{\sigma^2 / (LM)}{(1/M)(\sigma^2 / (LM)) + M \hat{\Sigma}_{Bh} + \rho_B}$$




・ h 列/ h 行ベクトルの
正規化定数

$$\rho_A = \left(LM \frac{\hat{\Sigma}_{Ah}}{\sigma^2} \right)^2 \left(\nu_h^2 + (H-1)\sigma_b^2 + 2 \frac{\hat{\Sigma}_{Bh}}{L} \mu_h \nu_h + \frac{\sigma^2}{M} \rho_B \right)$$




$$\rho_B = \left(LM \frac{\hat{\Sigma}_{Bh}}{\sigma^2} \right)^2 \left(\mu_h^2 + (H-1)\sigma_a^2 + 2 \frac{\hat{\Sigma}_{Ah}}{M} \mu_h \nu_h + \frac{\sigma^2}{L} \rho_A \right)$$

簡約式を逐次的に解くことで、簡約式の解となる重なり μ_h, ν_h の値を調べる. (μ_h, ν_h の重なりの初期値を変更)
実際の行列分解実験と比較: 簡約式(赤線—), 数値実験(青線—)

低ノイズ
($\sigma \rightarrow$ 小)



高ノイズ
($\sigma \rightarrow$ 大)



収束後の積 $\mu_h \nu_h$ が1に近ければ収束解は用意した正解行列に近い

- μ_h, ν_h の初期値 $\sim 1 \rightarrow$ 正解行列付近に収束, 簡約式は分解行列解の性質をほぼ正しく記述
- μ_h, ν_h の初期値 $\sim 0 \rightarrow$ 正解行列から遠くに収束 \rightarrow 行列が回転 (成分が混合) し正解から離れる

これまでの解析は変分ベイズ解を用いたが, 自由エネルギーから出発することも可能

変分ベイズ自由エネルギーを事後平均, 事後共分散 $\hat{A}, \hat{B}, \hat{\Sigma}_A, \hat{\Sigma}_B$ で表現

$$\begin{aligned} 2f = & \frac{\|\mathbf{V} - \hat{\mathbf{B}}\hat{\mathbf{A}}^T\|_{\text{FRO}}^2}{\sigma^2} - L \log |\hat{\Sigma}_A| - M \log |\hat{\Sigma}_B| + \text{Tr}(\hat{\mathbf{A}}^T \hat{\mathbf{A}} + L \hat{\Sigma}_A) + \text{Tr}(\hat{\mathbf{B}}^T \hat{\mathbf{B}} + M \hat{\Sigma}_B) \\ & - \frac{1}{\sigma^2} \text{Tr} \hat{\mathbf{A}}^T \hat{\mathbf{A}} \hat{\mathbf{B}}^T \hat{\mathbf{B}} + \frac{1}{\sigma^2} \text{Tr}(\hat{\mathbf{A}}^T \hat{\mathbf{A}} + L \hat{\Sigma}_A)(\hat{\mathbf{B}}^T \hat{\mathbf{B}} + M \hat{\Sigma}_B) \end{aligned}$$

大域的変数を導入し, 自由エネルギーをこれらで表現しなおす

・正解行列と
推定行列の重なり

$$\mu_h = \frac{1}{L} \sum_{l=1}^L a_{lh} \hat{a}_{lh} \quad \nu_h = \frac{1}{M} \sum_{m=1}^M b_{hm} \hat{b}_{hm}$$

・干渉ノイズ

$$\sigma_{Ahh'}^2 = \left(\frac{1}{L} \sum_{l=1}^L a_{lh'} \hat{a}_{lh} \right)^2 \quad \sigma_{Bhh'}^2 = \left(\frac{1}{M} \sum_{m=1}^M b_{h'm} \hat{b}_{hm} \right)^2$$

・正規化因子

$$\rho_{ah} = \frac{1}{L} \sum_{l=1}^L \hat{a}_{lh}^2 \quad \rho_{bh} = \frac{1}{M} \sum_{m=1}^M \hat{b}_{hm}^2 \quad e_h = \frac{1}{LM} \sum_{l=1}^L \sum_{m=1}^M \varepsilon_{lm} \hat{a}_{lh} \hat{b}_{hm}$$

得られた自由エネルギーから, 導入した変数間の関係式を導出 (状態方程式)

$$\mu_h = \frac{M}{\sigma^2} \hat{\Sigma}_{Ah} \nu_h \left(1 - M \frac{\hat{\Sigma}_{Ah} \hat{\Sigma}_{Bh}}{\sigma^2} \right)^{-1} \quad \sigma_{ah'h}^2 = \frac{1}{2} \left(\frac{M \hat{\Sigma}_{ah}}{\sigma^2} \right)^2 \sigma_{bh'h}^2 \left(1 \pm \sqrt{1 + \frac{4}{L \hat{\Sigma}_{ah}} \left(\frac{\sigma^2}{M \sigma_{bh'h}^2} \right)^2} \right) + \frac{\hat{\Sigma}_{ah}}{L}$$

$$\nu_h = \frac{L}{\sigma^2} \hat{\Sigma}_{Bh} \mu_h \left(1 - L \frac{\hat{\Sigma}_{Ah} \hat{\Sigma}_{Bh}}{\sigma^2} \right)^{-1} \quad \sigma_{bh'h}^2 = \frac{1}{2} \left(\frac{L \hat{\Sigma}_{bh}}{\sigma^2} \right)^2 \sigma_{ah'h}^2 \left(1 \pm \sqrt{1 + \frac{4}{M \hat{\Sigma}_{bh}} \left(\frac{\sigma^2}{L \sigma_{ah'h}^2} \right)^2} \right) + \frac{\hat{\Sigma}_{bh}}{M}$$

$$\hat{\Sigma}_{Ah} = \frac{\sigma^2}{\sigma^2 + M \hat{\Sigma}_{Bh} + M \rho_{Bh}} \quad \rho_{Ah} = \mu_h^2 + \frac{M}{\sigma^2} (\hat{\Sigma}_{Ah})^2 \nu_h^2 + \left(\frac{L - H + 1}{L} \hat{\Sigma}_{Ah} + \sum_{h' \neq h} \sigma_{Ah'h}^2 \right)$$

$$\hat{\Sigma}_{Bh} = \frac{\sigma^2}{\sigma^2 + L \hat{\Sigma}_{Ah} + L \rho_{Ah}} \quad \rho_{Bh} = \nu_h^2 + \frac{L}{\sigma^2} (\hat{\Sigma}_{Bh})^2 \mu_h^2 + \left(\frac{M - H + 1}{M} \hat{\Sigma}_{Bh} + \sum_{h' \neq h} \sigma_{Bh'h}^2 \right)$$

$$e_h = \hat{\Sigma}_{Bh} \mu_h^2 + \frac{1}{\alpha} \hat{\Sigma}_{Ah} \nu_h^2 + \sigma^2 \frac{\hat{\Sigma}_{Ah} \hat{\Sigma}_{Bh}}{\sigma^2 - M \hat{\Sigma}_{Ah} \hat{\Sigma}_{Bh}} - \frac{L + M}{2} \frac{\hat{\Sigma}_{Ah} \hat{\Sigma}_{Bh}}{\sigma^2 - M \hat{\Sigma}_{Ah} \hat{\Sigma}_{Bh}} \sum_{h' \neq h} \sqrt{\sigma_{Ah'h}^2 \sigma_{Bh'h}^2} \quad (\alpha = M / L)$$

信号雑音分離による簡約式と対応付けられそうだが, 若干ずれている
→ どの程度差異があるか数値的に検証の必要あり

$$V = A B$$

(A) 行列分解問題の種類を紹介

(B) 行列分解問題とベイズ統計学との関連性を紹介

ベイズ推定を通じ、様々な統計力学的手法が解析に利用できる

(C) ラプラス事前分布の下でのスパース行列分解を解析

幾つかの近似の下で、変分ベイズ法での解析解の表式が得られる → アルゴリズム
正規化因子の零点から正則化係数を決めると、スパース行列が精度良く復元（理由？）

(D) ガウス事前分布下での行列分解の変分ベイズ解析解の性質を

Hopfield模型の信号雑音分離法を援用し解析

正解行列との初期重なりが高い → 簡約式での解の記述が妥当（重なりが低いとずれる？）

今後も調べるべき点はありそう…