

# 低ランク行列のベイズモデリング

中央大学大学院理工学研究科 黒澤 大樹

中央大学理工学部 酒折 文武

欠測を含む低ランク行列のモデリングは、ノイズを含む画像の補完や推薦アルゴリズムなど、様々な応用分野で活用されている。そして、低ランクモデリングをベイズ的に表現することで、より柔軟なモデリングや、欠測部分の予測分布に基づく推論などが可能となる。

いま、 $n \times p$  データ行列を  $X$  とする。この行列には観測されない欠測部分が含まれているとする。 $X$  は潜在的に低ランク構造をもつと仮定し、その低ランク行列を復元することが目的である。低ランク行列のベイズモデリングとしては、Ruslan & Andriy (2008) により提案された Bayesian Probabilistic Matrix Factorization (BPMF) がある。BPMF は、行列のランクにあたる  $r \ll \min(n, p)$  を所与として  $X = AB^T + \varepsilon$  という構造を仮定し、ギブスサンプリングにより行列復元を行う手法である。この手法において  $r$  の選択は本質的な問題であるが、適切な方法は提案されていない。

一方、Mazumder *et al.* (2010) では、

$$\text{minimize } \|L\|_*, \quad \text{subject to } \sum_{(i,j) \in \Omega} (X_{ij} - L_{ij})^2 \leq \delta \quad (1)$$

という凸最適化問題により、低ランク行列を復元する方法を提案している。ここで、 $\Omega \subset \{1, \dots, n\} \times \{1, \dots, p\}$  は  $X$  の観測要素のインデックス集合、 $\|L\|_*$  は  $L$  の特異値の和である核ノルムであり、 $\delta \geq 0$  は復元誤差の許容限界を制御するパラメータである。この最適化問題は、以下のラグランジュ型の目的関数の最小化問題

$$\text{minimize}_L \frac{1}{2} \|\mathcal{P}_\Omega(X) - \mathcal{P}_\Omega(L)\|_F^2 + \lambda \|L\|_* \quad (2)$$

で表現される。ここで、 $\mathcal{P}_\Omega, \mathcal{P}_{\Omega^\perp}$  はそれぞれ  $\Omega, \Omega^c$  の上への射影

$$\mathcal{P}_\Omega(Y)_{ij} = \begin{cases} Y_{ij} & (i, j) \in \Omega \\ 0 & (i, j) \in \Omega^c \end{cases}, \quad \mathcal{P}_{\Omega^\perp}(Y)_{ij} = \begin{cases} Y_{ij} & (i, j) \in \Omega^c \\ 0 & (i, j) \in \Omega \end{cases},$$

$\lambda \geq 0$  は核ノルムを制御するチューニングパラメータ、 $\|A\|_F$  はフロベニウスノルムである。 $\lambda$  を所与として、(2) はアルゴリズム soft-impute により反復的に解かれ、特異値をスパースにすることで低ランク行列を推定することができる。この推定量はまた、 $X_{ij} \sim N(L_{ij}, \sigma^2)$  *i.i.d.*、 $d_k \sim \text{EXP}(\lambda)$  とし、EM アルゴリズムと MAP 推定による推定量として表現することが可能である。ここで  $d_k$  ( $k = 1, \dots, r$ ) は  $L$  の第  $k$  特異値である。さらに、階層的ベイズモデルに拡張し、より適応的なモデルに拡張することもできる。

本研究では、こうした低ランクベイズモデリングにおけるハイパーパラメータおよび事前分布の選択法について提案し、比較・考察する。適応的なモデルの1つとして、次のモデルを提案する。

$$\text{minimize}_L \frac{1}{2} \|\mathcal{P}_\Omega(X) - \mathcal{P}_\Omega(L)\|_F^2 + \lambda \sum_{k=1}^r w_k d_k, \quad w_k = \left(\frac{1}{d_k^*}\right)^\gamma, \quad \gamma > 0.$$

また、CV や情報量規準などにより適切なチューニングパラメータを選択することを検討する。さらに実データに応用し、その有効性を検証する。結果は当日報告する。

## 参考文献

- [1] Mazumder R., Hastie T. & Tibshirani R. (2010). Spectral Regularization Algorithms for Learning Large Incomplete Matrices, *Journal of Machine Learning Research* 11, 2287-2322.
- [2] Ruslan S. & Andriy M. (2008). Bayesian Probabilistic Matrix Factorization using Markov Chain Monte Carlo, *Proceedings of the 25th international conference on Machine learning*, 880-887.