

# ガウス過程回帰モデルの次元圧縮法

赤穂 昭太郎 大学統計教員育成センター 特任教授


## 1. 確率分布パラメータの多変量解析法

確率分布のパラメータ(例えば正規分布の期待値・分散パラメータ)が多数得られたときに、それらの共通する低次元構造を抽出する問題を考える。

この問題の応用先として、転移学習やセンサフュージョンなどが挙げられる[1,2].

通常の主成分分析(PCA)で次元圧縮して射影すると、負の分散が現れたり、またユークリッド距離で分布距離を測ることが妥当でない場合がある。

これまで、情報幾何学における平坦双対空間の構造を用いて有限パラメータをもつ指数分布族[3]やその混合分布[4]などについての定式化を行ってきた。ここでは、新たに無限次元指数分布族であるガウス過程回帰(GPR)についての定式化を行った結果[5]を報告する。



## 2. 主要な結果


事前分布を共有するGPR(入力点は共有していなくてよい)集合が与えられたとする。

このとき、(無限次元の)GPRの e-PCA  $M_e^*$ (下記参照)は、入力点の和集合からなる有限次元ガウス分布の e-PCA  $M_e$  のアフィン写像  $M_e^* = L(M_e)$  として得られる。つまり、無限次元の問題を有限次元の問題に帰着して解くことができる。

## 3. 言葉と記号の定義

- $i$  番目のGPRの入力点集合  $X^i \in R^{d \times N_i}, X = \bigcup_{i=1}^K X^i$
- $X$  を含む任意個数(実質無限個)の検査点集合  $X^* \in R^{d \times N^*}$
- $X^*$  上のガウス分布の空間  $S^*$ ,  $X$  上のガウス分布の空間  $S$
- $X^*$  上の事前分布を共有するGPRの導くガウス分布の空間  $T^* \subseteq S^*$ ,
- $i$  番目のGPRの  $S^*$  での自然パラメータ  $(\theta_i^*, \Theta_i^*)$ ,  $S$  でのパラメータ  $(\theta_i, \Theta_i)$
- ePCA: 自然パラメータで表現された データ点集合  $\{\xi_i \in \Xi\}_{i=1, \dots, K}$  に対し、

基底  $\{u_j \in \Xi\}_{j=0, \dots, m}$  の張る平坦(自己平行)部分多様体  $M_e = \{\sum_j w_j u_j \in \Xi \mid w_j \in R\}$  で、 $\sum_i KL(\xi_i, \sum_j w_{ij} u_j)$  を最小にするもの cf. 期待値パラメータに対して双対的に同様の部分多様体 mPCA も定義できる。




## 4. 証明の概略

以下の3つの補題から示される

1.  $(\theta, \Theta) \in S$  から  $(\theta^*, \Theta^*) \in T^*$  への自然パラメータ間のアフィン変換 が具体的に構成できる(注: 自然パラメータは期待値と共分散の非線形関数)
2.  $S$  上の任意の2点間の KL ダイバージェンスと対応する  $T^*$  の KL ダイバージェンスは一致する
3.  $M_e^* \subset T^*$  (注: 一般にアフィン部分空間上の点の ePCA がその空間内に含まれるとは限らない)

## 5. 数値実験の結果

人工データを用いた提案手法(GP-ePCA)の実験結果とほかの手法との比較s (GP: 転移なし, ICM: Intrinsic Coregional Method, HBGP: 階層ベイズGP)



## 6. 今後の課題

1. 事前分布を共有しない場合への拡張
2. 学習やハイパーパラメータ推定にかかる計算量の削減(スパース化など通常のカーネル法・GPの方法は流用可能)

## 参考文献

- [1] 赤穂 昭太郎, 渡辺 一帆, 岡田 真人 (2010). 指数型分布族の空間におけるデータ解析法について, 統計数理, 58(2), 167-183
- [2] Hino, H., Akaho, S., & Murata, N. (2022). Geometry of EM and related iterative algorithms. Information Geometry, 1-39.
- [3] Akaho, S. (2004, July). The e-PCA and m-PCA: Dimension reduction of parameters by information geometry. In 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541) (Vol. 1, pp. 129-134). IEEE.
- [4] Akaho, S. (2008). Dimension Reduction for Mixtures of Exponential Families. In ICANN (1) (pp. 1-10).
- [5] Ishibashi, H., & Akaho, S. (2022). Principal component analysis for Gaussian process posteriors. Neural Computation, 34(5), 1189-1219.