

# 多層パーセプトロンを用いた複数時系列データの効率的な共有潜在空間推定への取り組み

大山まりほ†

†お茶の水女子大学人間文化創成科学研究科理学専攻

小林一郎‡

‡お茶の水女子大学 基幹研究院自然科学系

## 1 はじめに

唇の動き、音声発話、顔の表情、しぐさなど複数かつ高次元の時系列データの対応関係を捉えることは重要である。それらの対応を考える際、異なる次元を持つ各データを共有する空間上に射影し次元を揃えて比較可能にする必要がある。本研究では、ガウス過程に従う高次元の時系列データを対象にした、潜在空間上での次元圧縮を行う手法である Gaussian Process Latent Variable Models(GPLVM)を次元圧縮に用い、潜在空間を推定する。GPLVMにはEMアルゴリズムが用いられており、計算量が膨大で実用化は難しい。そのため、EMアルゴリズムの代わりに多層パーセプトロン(MLP:Multilayer Perceptron)を組み込み、非線形識別を可能にし、精度の向上且つ計算量の削減を実現する。実用を目指したより効率的な潜在空間識別モデルの構築を行う。本提案手法をGPLVM, Shared Gaussian Process Latent Variable Models(sharedGPLVM)に導入し、効果を実証する。また、本提案手法を用いて2つの時系列データを共有する潜在空間へ圧縮を行い、対応関係の学習を行う。

## 2 潜在空間への次元圧縮

### 2.1 GPLVM

本研究では、GPLVM[1]を用いてガウス過程で表現される高次元の時系列データを潜在空間に圧縮する。GPLVMとは、確率的主成分分析にガウス過程を導入したものである。GPLVMを使用した次元圧縮のアルゴリズムをAlgorithm 1に示す。

---

#### Algorithm 1 GPLVM

---

**Require:**  $X, Y, K, T$

Initialize  $X$  through PCA.

**for**  $T$  iterations **do**

Optimise  $\log p(Y, X, \alpha, \beta, \gamma)$  with respect to the parameters of  $K$  using scaled conjugate gradients.

Select a new  $X$  using the parameters of  $K$ .

**end for**

---

GPLVMにはEMアルゴリズムが用いられており、精

---

An Approach to Efficient Learning for Corresponding Relation between Multiple Time-series Data Using Multilayer Perceptron

†Mariho OYAMA(g1220509@is.ocha.ac.jp)

‡Ichiro KOBAYASHI(koba@is.ocha.ac.jp)

†,‡Advanced Sciences, Graduate School of Humanities and Sciences, Ochanomizu University

度の保証がされていない。そのため収束判定を行うためにMLPを組み込み、収束判定をするアルゴリズムを作成した。そのアルゴリズムをAlgorithm 2に示す。

---

#### Algorithm 2 GPLVM with MLP

---

**Require:**  $X, Y, K$

Initialize  $X$  through PCA.

**while** Gradient  $\log p(Y, X, \alpha, \beta, \gamma, M) \leq$  **do**

Select a new  $X$  through feed forward MLP.

Optimise  $\log p(Y, X, \alpha, \beta, \gamma, M)$  with respect to the parameters of  $K$  and the synaptic weights of MLP using scaled conjugate gradients.

**end while**

---

まず主成分分析(Principal component analysis:PCA)を用いて $Y$ を圧縮し、 $X$ の初期値を設定する。そして $X, Y$ それぞれをガウス過程に従っていると仮定した正規化を行う。次にMLPを用いる。 $Y$ を入力、 $X$ を出力として結合荷重を求め、 $X$ と $Y$ の対応関係を学習させておく。その後、式(1)で表される $\log p(Y, X; \alpha, \beta, \gamma)$ が最大となるよう、カーネル関数のパラメータ $\alpha, \beta, \gamma$ とMLPの結合荷重 $w$ の更新を行い、 $X$ を再設定する。結合荷重の更新とカーネルのパラメータの更新を式(1)の勾配が収束するまで繰り返すことで $X$ が更新され、高次元の $Y$ に対して低次元の潜在空間 $X$ が求まる。

$$\log p(Y, X|\alpha, \beta, \gamma) = \log p(Y|X, \alpha, \beta, \gamma) + \frac{1}{2} \sum_i X_i^2 + \frac{1}{2} \sum_j w_j^2 \quad (1)$$

### 2.2 sharedGPLVM with MLP

対応関係の取得を行うために2つの観測空間で1つの潜在空間を共有することで、2つの観測空間の関係を学習することの出来るsharedGPLVM[2]を用いる。

sharedGPLVMは大別して学習(共有する潜在空間の構築)とマッピング(取得された潜在空間を通じた2つの時系列データの対応)の2つの段階に分けられる。本研究では学習フェーズに着目している。アルゴリズムをAlgorithm3に示す。

## 3 実験

### 3.1 GPLVM with MLP

構築したアルゴリズムの正当性を検証するために、Ek[2]においてsharedGPLVMの検証用で使用されてい

**Algorithm 3** sharedGPLVM with MLP:learning

**Require:**  $X, X_Y, X_Z, Y, Z, K_Y, K_Z$

Initialize  $X_Y, X_Z$  through PCA.

Initialize  $\phi_Y, \phi_Z$ .

Calculate  $X$  using  $X_Y$  and  $X_Z$ .

Calculate  $p(Y, Z|X, \phi_Y, \phi_Z)$ .

**while** Gradient  $\log p(Y, Z|X, \phi_Y, \phi_Z) \leq \epsilon$  **do**

Select a new  $X'_Y, X'_Z$  using the parameter of  $K_Y, K_Z$  through feed forward MLP.

Optimise  $\log p(Y, Z|X, \phi_Y, \phi_Z)$  with respect to the parameters of  $K_Y, K_Z$  and the synaptic weights of MLP using scaled conjugate gradients.

Calculate  $X'$  using  $X'_Y$  and  $X'_Z$ .

**end while**

たのと同じサンプルプログラムを作成し，動作結果を比較した．三角関数3式を基底としてガウス分布に従う重みをかけ足し合わせ，ノイズを付加，20次元の観測データ  $Y$  を作成し，3次元の潜在空間  $X$  に圧縮する．作成した  $Y$  は図1の左図のようになった．基底である曲線(図1:右)に近い形が出力されるのが理想である．

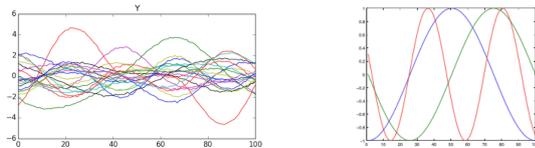


図1: 左: 観測データ  $Y$  右:  $Y$  の基底

GPLVM により得られた結果を図2に示す．右は GPLVM, 左が GPLVM に MLP を組み込んだものである．

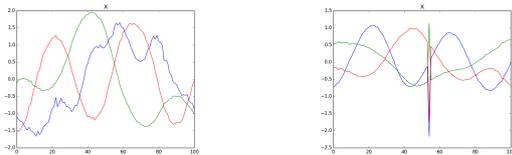


図2: 左: MLP 有 右: MLP 無

また，処理時間はそれぞれ以下の表のようになった．

表1: elapsed time

original GPLVM	GPLVM with MLP
5872.89[sec]	25.27[sec]

**3.2 sharedGPLVM with MLP**

前節に作成した 20 次元の観測データ  $Y$  に加え，同様に 30 次元の観測データ  $Z$  を作成する．観測データ  $Y$

と  $Z$  を共有する 3 次元の潜在空間  $X$  に圧縮する．結果は図3のようになった．また，MLP を用いていない従来手法の sharedGPLVM を用い，繰り返し回数  $T = 10$  と， $T = 10000$  で実験を行った結果を図??に示す．

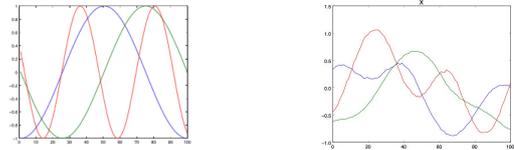


図3: 左:  $Y, Z$  の基底 右: 共有の潜在空間  $X$

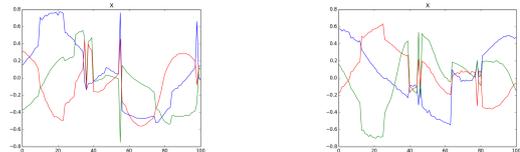


図4: 左: MLP 無 ( $T=10$ ) 右: MLP 無 ( $T=10000$ )

**4 まとめと今後の課題**

本研究は，ガウス過程に従う高次元の時系列データを対象にし，GitHub 上で公開されているソースコード\*を参考に，GPLVM を用いて低次元の潜在空間に圧縮する手法について考察した．また，従来の手法を効率と精度の2つの面で改良する手法として，我々は EM アルゴリズムを使用する代わりに，非線形最適化手法である多層パーセプトロンを導入する手法を提案した．本提案手法により，計算時間を大幅に短縮することに成功した．さらに，複数の時系列データの対応関係を取得することが出来る sharedGPLVM にも本手法を導入し，sharedGPLVM においても精度よく効率的な潜在空間の推定が出来ることを確認した．計算量の削減においても，GPLVM と同様に大幅に削減していると考えられる．いずれの手法も，従来のアルゴリズムでは，最適な繰り返し回数を求めることができず，図2や図4のように値が飛んでいる部分や，失敗する例も散見された．今後の課題としては，従来手法との比較を行っていきたいと考えている．

**参考文献**

- [1] Neil D.Lawrence, "Gaussian Process Latent Variable Models for Visualisation of High Dimensional Data", 2004.
- [2] Carl Henrik Ek, "Shared Gaussian Process Latent Variable Models", (PhD thesis), Oxford Brookes University, 2009.
- [3] 持橋大地, "ガウス過程の基礎と教師なし学習", 統計数理研究所公開講座資料, 2015.

\*<http://github.com/jameshensman>