4M-03

共有する潜在空間への異なる時系列データの次元圧縮に関する一考察

大山まりほ† 小林一郎‡
† お茶の水女子大学人間文化創成科学研究科理学専攻 ‡ 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．ガウス過程に従う高次元の時系列データを対象にし，潜在空間上での次元圧縮を行う手法として，Lawrence[1] によって Gaussian Process Latent Variable Models(GPLVM) が提案された．GPLVM を基盤として潜在空間でのデータの系列方向においてもガウス過程を仮定し，GPLVM の性能をさらに上回る時系列データの潜在状態を推定する手法として，Wang ら [2] によって Gaussian Process Dynamic Models(GPDM) が提案されている．また，Ek ら [3] によって複数の時系列データの対応関係として，2 つの時系列データが共有する潜在空間を GPLVM を介して推定する Shared Gaussian Process Latent Variable Models(sharedGPLVM) が提案されており，この手法は Disney のアニメーションキャラクターの動作生成にも適用されている [4]．さらには，GPDM を基盤として Chen ら [5] は動作の分類が可能な Switching Gaussian Process Dynamic Models(switchingGPDM) を提案している．これら GPLVM を基礎とする手法において，本研究では GPDM を対象にし，複数の時系列データの対応関係を考え，潜在状態の推定に非線形識別器である多層パーセプトロン (Multilayer perceptron:MLP) を用い，推定精度を向上させることに取り組む．

2 共有する潜在空間への異なる時系列データの次元圧縮

2.1 sharedGPDM

複数かつ高次元の対応する時系列データを共有の潜在空間に圧縮するために GPDM を拡張した sharedGPDM を考える．sharedGPDM のグラフィカルモデルを図 1 に示す．

2.2 GPDM

GPDM とは，時系列データに関する確率的主成分分析にガウス過程を導入したものである．GPDM のアルゴリズムを Algorithm1 に示す．$\boldsymbol{\phi}_X$,$\boldsymbol{\phi}_Y$ はいずれも $\boldsymbol{X}$,$\boldsymbol{Y}$ のカーネル関数のパラメータである．

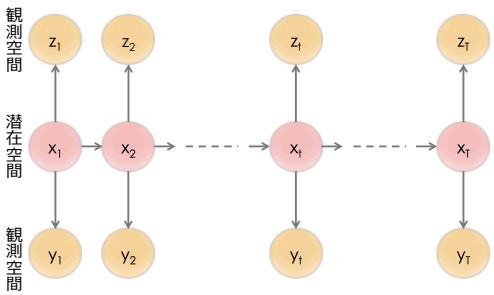


図 1: sharedGPDM のグラフィカルモデル

Algorithm 1 GPDM

Require: $\boldsymbol{X}$,$\boldsymbol{Y}$,$\boldsymbol{K}$

Initialize $\boldsymbol{X}$ through PCA.
for t = 1 to T **do**
  while Mean squared error ≥ ε **do**
    Select a new $\boldsymbol{X}$ using the MLP algorithm.
    Optimise (1) with respect to the parameters of $\boldsymbol{K}$ using SCG.
    $\boldsymbol{X}_{opt}$ ⇐ optimise $p(\boldsymbol{Y}|\boldsymbol{X}, \boldsymbol{\phi}_X^{t-1}, \boldsymbol{\phi}_Y)$ with respect to $\boldsymbol{X}$ using MLP.
  end while
  $\{\boldsymbol{X}^{(r)}\}_{r=1}^{R}$ ⇐ generate R samples from $p(\boldsymbol{X}|\boldsymbol{Y}, \boldsymbol{\phi}_X^{t-1}, \boldsymbol{\phi}_Y)$ using Mean prediction.
  $\boldsymbol{\phi}_X^t$ ⇐ optimise (6) with respect to $\boldsymbol{\phi}_X$ using SCG.
  for k = 1 to d **do**
    $w_k \Leftarrow \sqrt{N(\boldsymbol{y}_{:,k}^T(\frac{1}{R}\Sigma_{r=1}^{R}\boldsymbol{K}_Y^{-1})\boldsymbol{y}_{:,k})^{-1}}$
  end for
end for

観測データ全体を $\boldsymbol{Y}$，圧縮先の潜在空間上のデータ全体を $\boldsymbol{X}$ とする．主成分分析 (Principal component analysis:PCA) を用いて $\boldsymbol{Y}$ を圧縮し，$\boldsymbol{X}$ の初期値を設定する．GPDM は大きく 3 つの段階に分けることができる．まず GPLVM[1] を用いて時刻 t における観測データ $y_t \in \boldsymbol{Y}$ をそれぞれ潜在空間 $x_t \in \boldsymbol{X}$ に圧縮を行う．この場合潜在空間 $\boldsymbol{X}$ のダイナミクスについては考慮されていない．次に，GPLVM を用いて作られた $\boldsymbol{X}$ と mean prediction[2] を用いて $\boldsymbol{X}$ のサンプリングを行う．この $\boldsymbol{X}$ のサンプルは次の段階で確率を計算する際の近似に用いる．最後に，対数尤度が高くなるよう $\boldsymbol{X}$ のカーネル関数のパラメータを変更する．この 3 つの段階を一

A Study on Dimension Reduction of Different Time-series Data onto Shared Latent Space
†Mariho OHYAMA(g1220509@is.ocha.ac.jp)
‡Ichiro KOBAYASHI(koba@is.ocha.ac.jp)
†,‡Advanced Sciences,Graduate School of Humanities and Sciences,Ochanomizu University

Copyright ©2017 Information Processing Society of Japan.
All Rights Reserved.

定回数 T 回繰り返すことで時系列情報を考慮した潜在空間 X が得られる．

2.2.1 GPLVM with MLP

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．本研究では，GPLVM に MLP を導入することで精度の向上を図る．GPLVM with MLP の概要図を図 2 に示す．

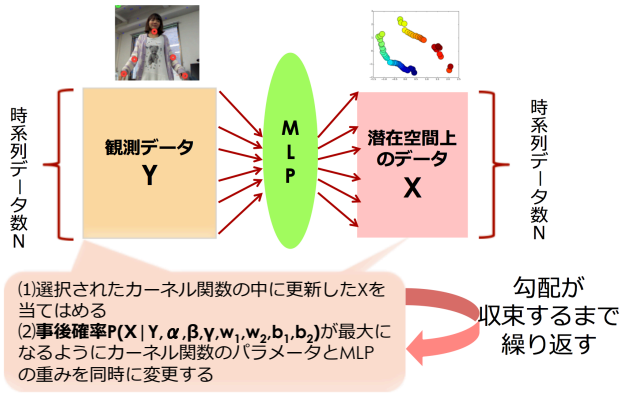


図 2: GPLVM with MLP の概要図

まず $\boldsymbol{X}$，$\boldsymbol{Y}$ 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，$\boldsymbol{Y}$ を入力，$\boldsymbol{X}$ を出力として結合荷重を求め，$\boldsymbol{X}$ と $\boldsymbol{Y}$ の対応関係を学習させる．その後，以下の式 (1) で表される $p(\boldsymbol{Y}|\boldsymbol{X},\boldsymbol{\phi_Y})$ の対数尤度が最大となるよう式 (2) で表されるカーネル関数のパラメータ $\boldsymbol{\phi_Y}$=$\{\alpha_Y, \beta_Y, \gamma_Y\}$ を更新する．次に，SCG(Scaled Conjugate Gradient) を用いて MLP の結合荷重の更新を行い，$\boldsymbol{X}$ を再設定する．

$$p(\boldsymbol{Y}|\boldsymbol{X},\boldsymbol{phi_Y}) = \frac{1}{(2\pi)^{DN/2}|K|^{D/2}}\exp(-\frac{1}{2}\mathrm{tr}(\boldsymbol{K}^{-1}\boldsymbol{Y}\boldsymbol{Y}^{\mathrm{T}})) \quad (1)$$

$$\begin{aligned} k(x_n, x_m) &= \alpha_{\boldsymbol{Y}}\exp(-\frac{\gamma_{\boldsymbol{Y}}}{2}(x_n - x_m)^{\mathrm{T}}(x_n - x_m)) \\ &+ \delta_{nm}\beta_{\boldsymbol{Y}}^{-1} \end{aligned} \quad (2)$$

結合荷重の更新とカーネルのパラメータの更新を最小二乗誤差が収束するまで繰り返すことで $\boldsymbol{X}$ が更新され，高次元の $\boldsymbol{Y}$ に対して時系列の関係は考慮されていない低次元の潜在空間 $\boldsymbol{X}$ を求めることが出来る．

2.2.2 Mean prediction

Wang[2] によって提案されたサンプリング手法を用いる．時刻 t における潜在状態 x_t が，その一つ前の状態 x_{t-1} を用いて式 (3) で表されるとし，R 個サンプリングを行う．

$$\boldsymbol{x}_t \sim N(\mu_X(\boldsymbol{x}_{t-1}); \sigma_X^2(\boldsymbol{x}_{t-1})\boldsymbol{I}) \quad (3)$$

$$\mu_X(\boldsymbol{x}) = \boldsymbol{X}_{out}^T\boldsymbol{K}_X^{-1}\boldsymbol{k}_X(\boldsymbol{x}) \quad (4)$$

$$\sigma_X^2(\boldsymbol{x}) = k_x(\boldsymbol{x},\boldsymbol{x}) - \boldsymbol{k}_x(\boldsymbol{x})^T\boldsymbol{K}_X^{-1}\boldsymbol{k}_X(\boldsymbol{x}) \quad (5)$$

2.2.3 パラメータ推定

最後に $\boldsymbol{X}$ のカーネルのパラメータの推定を行う．以下の式 (6) で表される $p(\boldsymbol{Y},\boldsymbol{X},\boldsymbol{\phi_Y},\boldsymbol{\phi_X})$ の対数尤度が最大になるよう式 (2) で表されるカーネル関数のパラメータ $\boldsymbol{\phi_Y}$, 式 (7) で表されるカーネル関数のパラメータ $\boldsymbol{\phi_X}$ を更新する．

$$\begin{aligned} &p(\boldsymbol{Y},\boldsymbol{X},\phi_X,\phi_Y) \\ &= p(\boldsymbol{Y}|\boldsymbol{X},\boldsymbol{\phi_Y})p(\boldsymbol{X}|\boldsymbol{\phi_X})p(\boldsymbol{\phi_X})p(\boldsymbol{\phi_Y}) \\ &= \frac{1}{(2\pi)^{D_YN/2}|\boldsymbol{K_Y}|^{D_Y/2}}\exp(-\frac{1}{2}\mathrm{tr}(\boldsymbol{K_Y}^{-1}\boldsymbol{Y}\boldsymbol{Y}^{\mathrm{T}})) \\ &\times p(x_1)\frac{1}{(2\pi)^{D_X(N-1)/2}|\boldsymbol{K_X}|^{D_X/2}}\exp(-\frac{1}{2}\mathrm{tr}(\boldsymbol{K_X}^{-1}\boldsymbol{X}_{out}\boldsymbol{X}_{out}{}^{\mathrm{T}})) \\ &\times p(\boldsymbol{\phi_X})p(\boldsymbol{\phi_Y}) \end{aligned} \quad (6)$$

$$\begin{aligned} k(x_n, x_m) &= \alpha_{\boldsymbol{X}}\exp(-\frac{\gamma_{\boldsymbol{X}}}{2}(x_n - x_m)^{\mathrm{T}}(x_n - x_m)) \\ &+ \delta_{nm}\beta_{\boldsymbol{X}}^{-1} + \eta_{\boldsymbol{X}}x_n \cdot x_m \end{aligned} \quad (7)$$

対数尤度の最大化を行う際微分して計算するが，式 (6) で表される $p(\boldsymbol{Y},\boldsymbol{X},\boldsymbol{\phi_Y},\boldsymbol{\phi_X})$ は微分が困難であるため，実際は Mean prediction で作成したサンプルを用いて近似を行う．

3 まとめと今後の課題

本研究では複数の高次元な時系列データの対応関係の学習について考察した．GPDM を用いることで時系列の関係を保持した状態で潜在空間に圧縮することが可能となる．また，その潜在空間をそれぞれのデータで共有する sharedGPDM を用いることで対応関係の学習をすることができる．GPDM を用いる際の初期設定の GPLVM の段階で MLP を導入することで精度の向上を図り，収束判定ができるようにする．今後の課題として，sharedGPDM の実装を行い，潜在空間を通して双方向にデータの変換が行えるようにするつもりである．

参考文献

[1] Neil D.Lawrence,“Gaussian Process Latent Variable Models for Visualisation of High Dimensional Data”, 2004.
[2] Jack M.Wang,“Gaussian Process Dynamical Models for Human Motion”, Master thesis,University of Tronto,2005.
[3] Carl Henrik Ek,“Shared Gaussian Process Latent Variable Models”, (PhD thesis),Oxford Brookes University,2009.
[4] Katsu Yamane,“Animating Non-Humanoid Characters with Human Motion Data”, Symposium on Computer Animation,2010.
[5] J.Chen,“Switching Gaussian Process Dynamic Models for Simultaneous Composite Motion Tracking and Recognition”,IEEE 2009.
[6] Jing Zhao,Shiliang Sun,“Revisiting Gaussian Process Dynamical Models”, IJCAI 2015.
[7] 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.

Copyright ©2017 Information Processing Society of Japan.
All Rights Reserved.