

ガウス過程による潜在変数モデル

Gaussian Process Latent
Variable Model (GPLVM)

明治大学 理工学部 応用化学科
データ化学工学研究室 金子 弘昌

ガウス過程による潜在変数モデル [1,2] とは？¹

- ✓各特徴量 x が、潜在変数 z からのガウス過程回帰により生成されると仮定し、潜在変数を計算する
- ✓カーネル関数により非線形の潜在変数を計算可能
- ✓ z のカーネル関数であり、 x のカーネル関数を計算する
カーネル主成分分析とは異なる
- ✓主成分分析 + カーネル関数 + ガウス分布
- ✓次元削減手法の一つ
- ✓事前に潜在変数の数を決める
- ✓潜在変数の事前分布により、様々な潜在変数を計算可能

- ガウス過程回帰 (Gaussian Process Regression, GPR)
<https://datachemeng.com/gaussianprocessregression/> を理解している
ことが前提の説明になります

[1] N. Lawrence, Gaussian Process Latent Variable Models for Visualisation of High Dimensional Data, NIPS Proceedings, 2003

[2] 持橋 大地, 大羽 成征, ガウス過程と機械学習, 講談社, 2019

GPR と GPLVM

✓ GPR で念頭にあったこと :

説明変数 x の値が似ている (近い) サンプル同士は、
目的変数 y の値も似ている (近い)

→ サンプル間における y の値の関係は、 x の値の関係から計算できる

✓ GPLVM で念頭にあること :

潜在変数 z の値が似ている (近い) サンプル同士は、
特徴量 x の値も似ている (近い)

→ サンプル間における x の値の関係は、 z の値の関係から計算できる

GPR で導いたこと

- ✓ i 番目のサンプルの y の平均値は 0
- ✓ i 番目のサンプルと j 番目のサンプルとの間の y の共分散 ($j = i$ のときは分散) は、 i 番目のサンプルの \mathbf{x} の値と j 番目のサンプルの \mathbf{x} の値から計算される

- 具体的には、 $K(\mathbf{x}^{(i)}, \mathbf{x}^{(j)})$ (K はカーネル関数)

カーネル関数の例 (他には、GPR のスライドの p.28-30 参照):

$$K(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \theta_0 \exp\left\{-\frac{\theta_1}{2} \|\mathbf{x}^{(i)} - \mathbf{x}^{(j)}\|^2\right\} + \theta_2 + \theta_3 \sum_{k=1}^m x_k^{(i)} x_k^{(j)}$$

GPLVM でもそのまま使います！

- ✓ i 番目のサンプルの \mathbf{x} の平均値は 0
 - ✓ i 番目のサンプルと j 番目のサンプルとの間の \mathbf{x} の共分散 ($j = i$ のときは分散) は、 i 番目のサンプルの \mathbf{z} の値と j 番目のサンプルの \mathbf{z} の値から計算される
 - 具体的には、 $K(\mathbf{z}^{(i)}, \mathbf{z}^{(j)})$ (K はカーネル関数)
- \mathbf{z} でカーネル関数を計算 (カーネル主成分分析では \mathbf{x} で計算)

全サンプルの確率

- ✓ 潜在変数が z のとき、サンプル $1, 2, \dots, i, \dots, n$ の \mathbf{x} の値が生じる確率
- n : サンプル数

$$p(\mathbf{x} | z) = \prod_{i=1}^n p(\mathbf{x}^{(i)} | z)$$

$$= \prod_{i=1}^n N\left(\mathbf{x}^{(i)} \mid 0, K\left(\mathbf{z}^{(i)}, \mathbf{z}^{(j)}\right)\right)$$



平均 0、分散共分散行列が $K\left(\mathbf{z}^{(i)}, \mathbf{z}^{(j)}\right)$ の
正規分布

この確率が大きくなる z の値を求めたいが、 z の事前分布 $p(z)$ は？

z の事前分布 $p(z)$

✓ GPLVM における基本の事前分布 (いわゆる GPLVM)

- 各潜在変数の平均値 0, 分散 1,
潜在変数間の共分散 0 の多次元正規分布

✓ infinite Warped Mixture Model (iWMM) [1]

- 混合ガウス分布 (Gaussian Mixture Models, GMM)
<https://datachemeng.com/gaussianmixturemodel/>

✓ Gaussian Process Dynamical Model (GPDM) [2]

- 潜在変数 z が時系列データであること (時間発展すること) を仮定
- 非線形なマルコフ過程 (ある時刻の z の値は 1 時刻前の z の値のみに依存)

$$p(z) = \prod_{i=2}^n p(\mathbf{z}^{(i)} | \mathbf{z}^{(i-1)}) \quad \Rightarrow \quad \text{カーネル関数で表現}$$

[1] T. Iwata, et al., <https://arxiv.org/abs/1206.1846>

[2] J. M. Wang, et al., IEEE Transactions on Pattern Recognition and Machine Intelligence, 30, 283-298, 2008

GPLVMでは X, Z の同時確率を最大化

同時確率 $p(x, z) = p(x | z) \times p(z)$ を最大化する z を求める

意味合い (式変形後)

x の分散共分散行列と、 z のグラム行列 (カーネル関数の値の行列) の逆行列が等しくなるように、 z を求める



潜在変数の高次元空間において直交化 (主成分分析) を行っているイメージ

GPLVM などを実行するためのコード

✓GPLVM

- GPy (Python): <https://sheffieldml.github.io/GPy/>
 - 変分ベイズ法を用いてハイパーパラメータも学習する Bayesian GPLVM が実装されており便利
- varGPLVM (MATLAB): <https://github.com/SheffieldML/varGPLVM>

✓iWMM

- warped-mixtures(MATLAB):
<https://github.com/duvenaud/warped-mixtures>

✓GPDM

- <http://www.dgp.toronto.edu/~jmwang/gpdm/> (MATLAB)