

Bayesian Machine Learning: Project 1

Seung-Hoon Na

December 2, 2019

1 GP regression

Regression문제는 $y = f(x)$ 의 unknown f 를 추론하는 것으로, parametric model에서는 f 를 θ 로 표현한 후, θ 를 estimation하는 문제를 다룬다.

Non-parametric model에서는 f 를 parameter를 거치지 않고 직접 추론한다. GP(Gaussian process)는 non-parametric model중 하나로, $p(f(\mathbf{x}_1), \dots, f(\mathbf{x}_n))$ 를 평균 $\boldsymbol{\mu}$, kernel $\mathbf{K}$ 를 공분산 (covariance)으로 취하는 joint Gaussian으로 가정한다.

보다 구체적으로, 함수 f 가 GP를 따른다고 할때 (함수 f 에 대한 prior가 GP 일때), 다음과 같이 표기하자.

$$f(\mathbf{x}) \sim GP(m(\mathbf{x}), \kappa(\mathbf{x}, \mathbf{x}')) \quad (1)$$

여기서 $m(\mathbf{x})$ 은 평균 함수, $\kappa(\mathbf{x}, \mathbf{x}')$ 는 kernel 또는 공분산 함수로 다음과 같이 정의 된다.

$$\begin{aligned} m(\mathbf{x}) &= E[f(\mathbf{x})] \\ \kappa(\mathbf{x}, \mathbf{x}') &= E[f(\mathbf{x} - m(\mathbf{x}))] E[f(\mathbf{x}' - m(\mathbf{x}'))] \end{aligned}$$

이때 $\kappa()$ 은 공분산이 되어야 하므로, positive definite kernel이 되어야 한다.

GP가정에 따라, $\mathbf{X} = [\mathbf{x}_1^T; \dots; \mathbf{x}_N^T]$ 에 대한 함수벡터 $\mathbf{f} = (f(\mathbf{x}_1), \dots, f(\mathbf{x}_N))$ 는 joint Gaussian을 따른다.

$$p(\mathbf{f}|\mathbf{X}) = \mathcal{N}(\mathbf{f}|\boldsymbol{\mu}, \mathbf{K}) \quad (2)$$

여기서, $\mathbf{K}_{ij} = \kappa(\mathbf{x}_i, \mathbf{x}_j)$, $\boldsymbol{\mu} = (m(\mathbf{x}_1), \dots, m(\mathbf{x}_N))$ 이다.

1.1 Noisy observations상에서 GP posterior density

우리가 각 $\mathbf{x}$ 마다 관측한 데이터 (observations)값들이 다음과 같이 f 에 대한 noisy version이라고 가정하자.

$$y = f(\mathbf{x}) + \epsilon \quad (3)$$

여기서 $\epsilon \sim \mathcal{N}(0, \sigma_y^2)$ 이다.

이때, 관측데이터와 (noise-free) test데이터의 joint density는 다음과 같다.

$$\begin{pmatrix} \mathbf{y} \\ \mathbf{f} \end{pmatrix} \sim \mathcal{N}\left(\mathbf{0}, \begin{pmatrix} \mathbf{K}_y & \mathbf{K}_* \\ \mathbf{K}_*^T & \mathbf{K}_{**} \end{pmatrix}\right) \quad (4)$$

여기서 $\mathbf{K}_y = \mathbf{K} + \sigma_y^2 \mathbf{I}_N$ 이다.

또한, zero mean을 가정할 경우에, posterior density는 다음과 같다.

$$\begin{aligned}
p(\mathbf{f}_*|\mathbf{X}_*, \mathbf{X}, \mathbf{y}) &= \mathcal{N}(\mathbf{f}_*|\boldsymbol{\mu}_*, \boldsymbol{\Sigma}_*) \\
\boldsymbol{\mu}_* &= \mathbf{K}_*^T \mathbf{K}_y^{-1} \mathbf{y} \\
\boldsymbol{\Sigma}_* &= \mathbf{K}_{**} - \mathbf{K}_*^T \mathbf{K}_y^{-1} \mathbf{K}_*
\end{aligned} \tag{5}$$

Multivariate Gaussian 분포의 conditional probability, linear system의 정리를 이용하여 Eq. (4)와 Eq. (5)를 유도하시오.

1.2 Marginal likelihood를 이용한 kernel parameter 학습

GP상에서 marginal likelihood를 유도하기 위해, 다음 식에서 출발하자.

$$p(\mathbf{y}|\mathbf{X}) = \int p(\mathbf{y}|\mathbf{f}, \mathbf{X}) p(\mathbf{f}|\mathbf{X}) d\mathbf{f} \tag{6}$$

여기서, $p(\mathbf{f}|\mathbf{X}) = \mathcal{N}(\mathbf{f}|\mathbf{0}, \mathbf{K})$, $p(\mathbf{y}|\mathbf{f}) = \prod_i \mathcal{N}(y_i|f_i, \sigma_y^2)$ 이다.
정리하면, GP상에서 marginal likelihood는 다음과 같다.

$$\begin{aligned}
\log p(\mathbf{y}|\mathbf{X}) &= \log \mathcal{N}(\mathbf{y}|\mathbf{K}_y) \\
&= -\frac{1}{2} \mathbf{y} \mathbf{K}_y^{-1} \mathbf{y} - \frac{1}{2} \log |\mathbf{K}_y| - \frac{N}{2} \log 2\pi
\end{aligned} \tag{7}$$

kernel parameters를 $\boldsymbol{\theta}$ 라고 하자. kernel parameter 학습을 위한, gradient를 위한 식은 다음과 같다 (교과서 Eq. 15.24참조).

$$\frac{\partial}{\partial} \log p(\mathbf{y}|\mathbf{X}) = \frac{1}{2} \text{tr} \left((\boldsymbol{\alpha} \boldsymbol{\alpha}^T - \mathbf{K}_y^{-1}) \frac{\partial \mathbf{K}_y}{\partial \theta_j} \right) \tag{8}$$

여기서, $\boldsymbol{\alpha} = \mathbf{K}_y^{-1} \mathbf{y}$ 이다.
Eq. (8)을 유도하시오.

1.3 GP regression 구현: numpy기반

아래 Algorithm 15.1은 GP regression의 pseudo code를 보여준다.

Algorithm 15.1: GP regression

```

1  $\mathbf{L} = \text{cholesky}(\mathbf{K} + \sigma_y^2 \mathbf{I});$ 
2  $\boldsymbol{\alpha} = \mathbf{L}^T \setminus (\mathbf{L} \setminus \mathbf{y});$ 
3  $\mathbb{E}[f_*] = \mathbf{k}_*^T \boldsymbol{\alpha};$ 
4  $\mathbf{v} = \mathbf{L} \setminus \mathbf{k}_*;$ 
5  $\text{var}[f_*] = \kappa(\mathbf{x}_*, \mathbf{x}_*) - \mathbf{v}^T \mathbf{v};$ 
6  $\log p(\mathbf{y}|\mathbf{X}) = -\frac{1}{2} \mathbf{y}^T \boldsymbol{\alpha} - \sum_i \log L_{ii} - \frac{N}{2} \log(2\pi)$ 

```

Figure 1: GP regression

Numpy를 이용하여 GP regression을 위한 python 코드를 작성하시오.
작성된 코드를 다음 데이터상에서 테스트하시오.

1. **Synthetic data:** $f(x) = x \sin(x)$ 가 true function이라고 가정하고, noisy observation 데이터를 5-20개 내외로 만든 후에 이로부터 GP regression 함수를 plot 하시오. Murphy's book 그림 15.2-15.3과 같이 true function 및 training example도 plot 해야 한다. 50개 정도 random하게 선택된 test points로 test set을 만들고 GP regression과 true 값간의 *Mean squared error*도 산출 하시오.

또한 Murphy's book의 Figure 15.2-15.3에서 처럼 test 지점의 $f(x)$ 의 variance를 이용하여 $\mathbb{E}[f(\mathbf{x})] \pm 2std(f(\mathbf{x}))$ 해당되는 구간은 shaded area로 표현 하시오.

또한, kernel은 다음 squared-exponential kernel 을 사용하라.

$$\kappa_y(x_p, x_q) = \sigma_f^2 \exp\left(-\frac{1}{2l^2} (x_p - x_q)^2\right) + \sigma_y^2 \delta_{pq} \quad (9)$$

1.4 GP regression을 위한 kernel parameter 학습: numpy 기반

Multi-dimensional SE kernel의 식은 다음과 같다.

$$\kappa_y(\mathbf{x}_p, \mathbf{x}_q) = \sigma_f^2 \exp\left(-\frac{1}{2}(\mathbf{x}_p - \mathbf{x}_q)^T \mathbf{M}(\mathbf{x}_p - \mathbf{x}_q)\right) + \sigma_y^2 \delta_{pq} \quad (10)$$

다음 문항순서대로 numpy에 기반하여 kernel parameters 학습하는 python 코드를 작성 하시오.

1. **Gradient 유도:** 앞서 Eq. (8)에서 kernel로 위의 Multi-dimensional SE kernel를 사용한 식을 유도 하시오.
2. **kernel 학습 구현:** 유도된 식을 이용하여, Numpy에 기반하여 kernel parameters를 gradient ascent 방법으로 학습하는 python 코드를 작성 하시오.
3. **synthetic 데이터상 실험:** ($f(x) = x \sin(x)$ 상)에서 kernel parameters를 학습하고, 학습하는 과정에서 marginal likelihood 및 test set상의 Mean squared error를 출력 하시오. Default parameter와 학습된 parameter를 이용한 regression function (error bar 포함)을 true function과 비교하여 plot 하시오.

1.5 GP regression 적용: Airfoil dataset

작성된 code를 이용하여, 다음 Airfoil 데이터상에서 GP regression 및 kernel parameter 학습을 수행하고, 실험결과를 정리 하시오. Airfoil의 1-5개의 field로부터 마지막 6번째 field의 값을 regression하는 함수를 얻으면 된다.

<https://archive.ics.uci.edu/ml/datasets/Airfoil+Self-Noise>

다음은 실험에 대한 지침이다.

- Airfoil dataset은 40:60 정도의 비율로 training, test 데이터로 구성하여 사용할 것
- Test set 상에서 default parameter와 학습된 kernel parameter를 각각 이용한 GP regression의 성능 비교를 포함할 것 (mean squared error)
- kernel parameter를 학습이 진행됨에 따라 성능 변화 추이를 파악할 수 있도록 epoch에 대한 성능 곡선을 plot할 것

2 GP regression: Gpytorch

다음 gpytorch를 설치한 후, simple GP regression과 simple GP classification의 tutorial의 내용을 이해하고 실행해보시오.

- <https://github.com/cornellius-gp/gpytorch>
- https://github.com/cornellius-gp/gpytorch/blob/master/examples/01_Simple_GP_Regression/Simple_GP_Regression.ipynb
- https://github.com/cornellius-gp/gpytorch/blob/master/examples/02_Simple_GP_Classification/Simple_GP_Classification.ipynb

다음 논문을 참조하여 gpytorch에서 GP classification에서 variational approximation에 기반한 posterior근사 방법의 핵심과정을 이해하고 정리해보시오.

- <http://proceedings.mlr.press/v5/titsias09a/titsias09a.pdf>
- <http://www.auai.org/uai2013/prints/papers/244.pdf>
- <https://arxiv.org/pdf/1411.2005.pdf>