

カーネル法とガウス過程

岡山大学 異分野基礎科学研究所

大槻純也



ベイズ線形回帰の課題


計算コスト $O(M^3)$

M : 基底関数 $\{\phi_j(\mathbf{x})\}$ の数 = 重み $\{w_j\}$ の数

$$S = (\beta \Phi^T \Phi + \alpha \mathbf{I})^{-1}$$

変数 $\mathbf{x} = \{x_1, x_2, \dots, x_D\}$ の次元が増えると
 M が **指数関数的に増大**

$$M \sim L^D \quad L: \text{各変数 } x_i \text{ の分割数}$$



対処法 1 :
モンテカルロ法を使う
(Markov Chain Monte Carlo法)


尤度関数

$$p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta) = \left(\frac{\beta}{2\pi}\right)^{N/2} \exp[-\beta E(\mathbf{w})]$$

$$E(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^N [y(x_n, \mathbf{w}) - t_n]^2$$

対処法 2 :
重みを消去 → カーネル法 (今日の内容)

参考文献 (ガウス過程)



←
初回に紹介した
PRMLの第6章
“Kernel Methods”

→
こちらの本もおすすめです。
表記がPRMLと同じにしてある
ので、PRMLと並行して読
んでも混乱しません。



カーネル

ベイズ線形回帰における予測分布 $p(t|x, \mathbf{x}, \mathbf{t})$ の平均

$$\begin{aligned} m(x) &= \beta \phi^T(x) S \Phi^T \mathbf{t} \\ &= \sum_{n=1}^N \beta \phi^T(x) S \phi(x_n) t_n \\ &\equiv \sum_{n=1}^N k(x, x_n) t_n \end{aligned}$$


$\{t_n\}$ を含まない部分

等価カーネル (equivalent **kernel**)

$$k(x, x') = \beta \phi^T(x) S \phi(x')$$

基底関数 $\{\phi_j(x)\}$ とデータ点 $\{x_n\}$ に依存

$k(x, x')$ の例：ガウス関数基底の場合



PRML Fig. 3.10

$x = x'$ にピークを持つ (局在している)
→ t の予測において、近くの点が強く影響する

カーネルトリック (kernel trick)

基底関数を用意して $k(x, x')$ を計算する代わりに、 $k(x, x')$ の関数形を仮定してしまう

ガウス過程

恒例の線形モデル

$$y(x, \mathbf{w}) = \mathbf{w}^T \phi(x)$$

今までは $\mathbf{w}$ の分布に注目していた

つまり、 $\mathbf{w}$ の事後確率分布 $\rightarrow y(x, \mathbf{w})$ の事後確率分布

今度は関数 $y(x, \mathbf{w})$ の分布を直接考える

パラメータ $\mathbf{w}$ の事前分布を仮定

$$p(\mathbf{w}) = \mathcal{N}(\mathbf{w} | \mathbf{0}, \alpha^{-1} \mathbf{I})$$

データ点がN個ある

$$\mathbf{x} = \{x_1, x_2, \dots, x_N\}$$

このとき $y_n \equiv y(x, \mathbf{w})$ の分布は？

$$y_n \equiv y(x_n, \mathbf{w}) \quad \mathbf{y} = \{y_1, y_2, \dots, y_N\}$$


結果： $\mathbf{y}$ の分布はガウス分布になる

$$p(\mathbf{y}) = \mathcal{N}(\mathbf{y} | \mathbf{0}, K)$$

導出

$$\mathbb{E}[\mathbf{y}] = \mathbf{0}$$

$$\mathbb{E}[\mathbf{y}\mathbf{y}^T] = \frac{1}{\alpha} \Phi \Phi^T$$



より共分散 K は

$$K = \frac{1}{\alpha} \Phi \Phi^T \quad \text{kernel matrix} \\ \text{カーネル行列}$$

$A^T A, A A^T$ の形を
一般にグラム行列
(Gram matrix)と呼ぶ

$$K_{nm} = \frac{1}{\alpha} \phi^T(x_n) \phi(x_m) \equiv k(x_n, x_m) \quad \text{kernel function} \\ \text{カーネル関数}$$


基底ベクトルの内積
 x_n と x_m がどれだけ似ているか

ガウス過程のイメージ

測定前

$\{y_1, \dots, y_N\}$ は決まっていない
ただし $\{x_1, \dots, x_N\}$ は与えられている

関数 $y(x)$ の事前確率
 $p(\mathbf{y}) = \mathcal{N}(\mathbf{y}|\mathbf{0}, K)$



分散

$$K_{nn} = k(x_n, x_n)$$

関数 $y(x)$ は揺らいでいる

相関している


$$K_{nm} = k(x_n, x_m)$$

独立に揺らいでいるわけではない

測定後

y_n の値が決まった

関数 $y(x)$ の条件付き確率
 $p(\mathbf{y}|\mathbf{y}_n)$



測定点の近くは
分散が小さくなる

測定点から遠い点は
分散が大きのまま

カーネル関数

カーネル関数の定義 $\mathbf{x} = \{x_1, \dots, x_D\}$

$$\begin{aligned} k(\mathbf{x}, \mathbf{x}') &= \phi^T(\mathbf{x})\phi(\mathbf{x}') \\ &= \sum_{j=1}^M \phi_j(\mathbf{x})\phi_j(\mathbf{x}') \end{aligned}$$


基底関数 $\{\phi_j(\mathbf{x})\}$ を仮定すれば計算できる

共通する性質

- $\mathbf{x} = \mathbf{x}'$ でピーク
- 速く減衰

このような性質を持つ $k(\mathbf{x}, \mathbf{x}')$ の関数形を直接与えてもよい

基底関数から作ったカーネルの例 ($D=1$)



PRML Fig. 6.1

カーネル関数

基底関数を仮定して計算する代わりに
 $k(\mathbf{x}, \mathbf{x}')$ の関数形を直接与える

$k(\mathbf{x}, \mathbf{x}')$ が満たすべき条件

1. $\mathbf{x}, \mathbf{x}'$ について対称
2. $\mathbf{x} = \mathbf{x}'$ でピーク。減衰。
3. 基底関数 $\phi_j(\mathbf{x})$ への分解が可能
(対応する基底が存在)

条件3の必要十分条件


任意の $\{\mathbf{x}_n\}$ から作ったカーネル行列 K が
positive semidefinite (半正定値性)

Gaussian kernel (ガウスカーネル)

$$k(\mathbf{x}, \mathbf{x}') = \theta_1 \exp \left(-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\theta_2} \right)$$

対応する基底関数は無限個のガウス関数基底

証明



ノイズ

観測データへのノイズの影響を考える

$$t_n = y_n + \epsilon_n \quad \text{ノイズ} = \text{確率変数}$$

観測値 予測値

$$p(\epsilon) = \mathcal{N}(\epsilon|0, \beta^{-1})$$

ノイズ ϵ_n が確率分布するので、
観測値 t_n も確率分布する

$$p(t_n|y_n) = \mathcal{N}(t_n|y_n, \beta^{-1})$$

N 個の観測データ $\mathbf{t} = (t_1, \dots, t_N)$ の確率分布

$$p(\mathbf{t}|\mathbf{y}) = \prod_{n=1}^N \mathcal{N}(t_n|y_n, \beta^{-1})$$
$$= \mathcal{N}(\mathbf{t}|\mathbf{y}, \beta^{-1}\mathbf{I}_N) \quad \text{多変量ガウス分布}$$

観測データ $\mathbf{t}$ の確率分布

= marginal distribution ($\mathbf{y}$ について周辺化)

sum rule

$$p(\mathbf{t}) = \int p(\mathbf{t}|\mathbf{y})p(\mathbf{y})d\mathbf{y} \quad \text{ガウス過程} \quad p(\mathbf{y}) = \mathcal{N}(\mathbf{y}|\mathbf{0}, K)$$
$$= \int \mathcal{N}(\mathbf{t}|\mathbf{y}, \beta^{-1}\mathbf{I}_N)\mathcal{N}(\mathbf{y}|\mathbf{0}, K)d\mathbf{y}$$

ガウス分布の畳み込み積分はガウス分布
公式PRML (2.115)

$$p(\mathbf{t}) = \mathcal{N}(\mathbf{t}|\mathbf{0}, K + \beta^{-1}\mathbf{I}_N)$$

観測ノイズがある場合、
ノイズの分散 β^{-1} をカーネル行列 K の対角項に足す

予測分布 (Predictive distribution)

N 個の測定値が与えられているとして
($N+1$)個めの測定値を予測したい

計算すべき量は conditional distribution

$$p(t_{N+1}|\mathbf{t}_N)$$

これを計算するために joint distribution

$$p(\mathbf{t}_{N+1}) = \mathcal{N}(\mathbf{t}_{N+1}|\mathbf{0}, C_{N+1})$$

$$C_N = K_N + \beta^{-1}\mathbf{I}_N$$

から出発し、次の式を使う

$$p(\mathbf{t}_N, t_{N+1}) = p(t_{N+1}|\mathbf{t}_N)p(\mathbf{t}_N)$$

↑
product rule

確率変数 t_{N+1} と共分散 C_{N+1} を分割

$$\mathbf{t}_{N+1} = \begin{pmatrix} \mathbf{t}_N \\ t_{N+1} \end{pmatrix} \quad C_{N+1} = \begin{pmatrix} C_N & \mathbf{k} \\ \mathbf{k}^T & c \end{pmatrix}$$

$\mathbf{x}_n$ と $\mathbf{x}_{N+1}$ の相関

ガウス分布の条件付き確率はガウス分布
公式PRML (2.81), (2.82)

$$p(t_{N+1}|\mathbf{t}_N) = \mathcal{N}(t_{N+1}|m(\mathbf{x}_{N+1}), \sigma^2(\mathbf{x}_{N+1}))$$

$$m(\mathbf{x}_{N+1}) = \mathbf{k}^T C_N^{-1} \mathbf{t}_N$$

$$\sigma^2(\mathbf{x}_{N+1}) = c - \mathbf{k}^T C_N^{-1} \mathbf{k}$$

次回の予告

【実習】 ガウス過程を使って実際に予測分布を計算してみる

