

ガウス過程回帰入門

瀬戸 道生 (防衛大学校・数学教育室)

Real, Complex and Functional Analysis Seminar

2020 年 12 月 13 日

学習と過学習

学習とは

データ（入力） $\xrightarrow{\text{学習}}$ 予測（出力）

- 繰り返し学習することで、予測精度の向上が期待される。

過学習とは

- 予測がデータに依存し過ぎている状態

ガウス過程回帰とは

- 機械学習 (Machine Learning) で非常に有力かつ有名な手法

ガウス過程回帰の使い方

工学上の問題

ある装置 $x \rightarrow y$ があり、
データ x を入力したとき、 \hat{z} を観測したとする。
このとき、新たなデータ x_* に対する出力 $z(x_*)$ を、
誤差を考慮して

$$z = y + \varepsilon$$

の形の関数で推定したい。

ガウス過程回帰の使い方

工学上の問題

ある装置 $x \rightarrow y$ があり、
データ x を入力したとき、 \hat{z} を観測したとする。
このとき、新たなデータ x_* に対する出力 $z(x_*)$ を、
誤差を考慮して

$$z = y + \varepsilon$$

の形の関数で推定したい。

ガウス過程回帰の導入

- y, ε が独立に多次元ガウス分布に従うと仮定する。
- このとき、すべての計算がガウス分布の範囲で納まる。

多次元ガウス分布

μ を \mathbb{R}^n のベクトル, Σ を $n \times n$ の正定値行列とする.

$$N(\mathbf{x}; \mu, \Sigma) := \frac{1}{(2\pi)^{n/2}(\det \Sigma)^{1/2}} \exp\left(-\frac{1}{2}\langle \Sigma^{-1}(\mathbf{x} - \mu), \mathbf{x} - \mu \rangle\right)$$

(多次元ガウス分布 (の確率密度関数))

- μ は平均ベクトル, Σ は共分散行列とよばれる.

多次元ガウス分布

μ を \mathbb{R}^n のベクトル, Σ を $n \times n$ の正定値行列とする.

$$N(\mathbf{x}; \mu, \Sigma) := \frac{1}{(2\pi)^{n/2}(\det \Sigma)^{1/2}} \exp\left(-\frac{1}{2}\langle \Sigma^{-1}(\mathbf{x} - \mu), \mathbf{x} - \mu \rangle\right)$$

(多次元ガウス分布 (の確率密度関数))

- μ は平均ベクトル, Σ は共分散行列とよばれる.

同時分布

$\mathbf{y} \sim N(\mathbf{0}, \Sigma)$ かつ $\varepsilon \sim N(\mathbf{0}, \beta^{-1}I)$ のとき (独立性も仮定する),

$$\mathbf{z} = \mathbf{y} + \varepsilon \sim N(\mathbf{0}, \Sigma + \beta^{-1}I).$$

- データを Σ の中に織り込む方法がある (カーネル法).

カーネル法

カーネル関数

X : 集合, $k : X \times X$ 上の関数

k はカーネル関数 $\stackrel{\text{def}}{\Leftrightarrow}$ (i) and (ii)

(i) $\forall x, y \in X \ k(x, y) = k(y, x)$ (対称性)

(ii) $\forall n \in \mathbb{N}, \forall c_1, \dots, c_n \in \mathbb{R}, \forall x_1, \dots, x_n \in X$

$$\sum_{i,j=1}^n c_i c_j k(x_i, x_j) \geq 0 \quad (\text{半正定値性})$$

カーネル法

カーネル関数

X : 集合, $k: X \times X$ 上の関数

k はカーネル関数 $\stackrel{\text{def}}{\Leftrightarrow}$ (i) and (ii)

(i) $\forall x, y \in X \ k(x, y) = k(y, x)$ (対称性)

(ii) $\forall n \in \mathbb{N}, \forall c_1, \dots, c_n \in \mathbb{R}, \forall x_1, \dots, x_n \in X$

$$\sum_{i,j=1}^n c_i c_j k(x_i, x_j) \geq 0 \quad (\text{半正定値性})$$

再生核ヒルベルト空間

$k_x := k(\cdot, x)$ から内積 $\langle k_y, k_x \rangle_{\mathcal{H}_k} = k(x, y)$ が構成できる.

カーネルトリック

データ $x_1, \dots, x_n \in X$ を $x_j \mapsto k_{x_j}$ と変換する.

ガウス過程回帰 1

仮定

$\forall n \in \mathbb{N}, \forall \mathbf{x} = (x_1, \dots, x_n) (x_i \neq x_j)$ に対し,

$$K_n = K_n(\mathbf{x}) = \begin{pmatrix} k(x_1, x_1) & \cdots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \cdots & k(x_n, x_n) \end{pmatrix} > 0 \text{ (固有値がすべて 0 より大)}$$

を仮定する．例えば， K がガウスカーネルなら OK

$$k(x, y) = \exp(-\gamma \|x - y\|^2) \quad (\gamma > 0) \quad (\text{ガウスカーネル})$$

記号

新しいデータ $\mathbf{x}_* = (x_{n+1}, \dots, x_{n+m})$ に対し,

$$K_{n+m} = K_{n+m}(\mathbf{x}, \mathbf{x}_*) = \begin{pmatrix} K_n & \mathbf{k} \\ \mathbf{k}^\top & K_m \end{pmatrix} \quad \text{と定める.}$$

ガウス過程回帰 2

\mathbb{R}^n の中を多次元ガウス分布に従って動くベクトルを構成する .

1. $\forall \{k_{x_j}\}_{j=1}^n$ の正規直交基底を $\{\varphi_j\}_{j=1}^n$ とする .
2. $\Phi = (\varphi_i(x_j))$ とおくと ,

$$k(x_i, x_j) = \langle k_{x_i}, k_{x_j} \rangle_{\mathcal{H}_k} = \sum_{\ell=1}^n \varphi_{\ell}(x_i) \varphi_{\ell}(x_j) = (\Phi \Phi^{\top} \text{ の } i, j \text{ 成分})$$

3. $\mathbf{w} \sim N(\mathbf{0}, \alpha^{-1} I_n)$ に対し , $y(\mathbf{w}, x_i) = \sum_{j=1}^n \varphi_j(x_i) w_j$ と定めると

$$\mathbf{y}(\mathbf{w}, \mathbf{x}) = \begin{pmatrix} y(\mathbf{w}, x_1) \\ \vdots \\ y(\mathbf{w}, x_n) \end{pmatrix} \sim N(\mathbf{0}, \alpha^{-1} \Phi \Phi^{\top}) = N(\mathbf{0}, \alpha^{-1} K_n)$$

が成り立つ .

ガウス過程回帰 3

ここまでのまとめ

$\mathbf{y} \sim N(\mathbf{0}, K_n)$ かつ $\varepsilon \sim N(\mathbf{0}, \beta^{-1}I_n)$ のとき,

$$\mathbf{z} = \mathbf{y} + \varepsilon \sim N(\mathbf{0}, K_n + \beta^{-1}I_n)$$

が成り立つ.

ガウス過程回帰 3

ここまでのまとめ

$\mathbf{y} \sim N(\mathbf{0}, K_n)$ かつ $\varepsilon \sim N(\mathbf{0}, \beta^{-1}I_n)$ のとき,

$$\mathbf{z} = \mathbf{y} + \varepsilon \sim N(\mathbf{0}, K_n + \beta^{-1}I_n)$$

が成り立つ.

条件付き分布

$\hat{\mathbf{z}}$ を観測した後に \mathbf{t} が従う分布を

$$p(\mathbf{t} | \hat{\mathbf{z}}) = C \exp \left(-\frac{1}{2} \langle (K_{n+m} + \beta^{-1}I_{n+m})^{-1} \begin{pmatrix} \hat{\mathbf{z}} \\ \mathbf{t} \end{pmatrix}, \begin{pmatrix} \hat{\mathbf{z}} \\ \mathbf{t} \end{pmatrix} \rangle \right)$$

と定める. ここで, C は \mathbf{t} で積分して 1 になるような定数 (付録を参照).

ガウス過程回帰 4

$$\begin{aligned} p(\mathbf{t} | \hat{\mathbf{z}}) &= C \exp \left(-\frac{1}{2} \langle (K_{n+m} + \beta^{-1} I_{n+m})^{-1} \begin{pmatrix} \hat{\mathbf{z}} \\ \mathbf{t} \end{pmatrix}, \begin{pmatrix} \hat{\mathbf{z}} \\ \mathbf{t} \end{pmatrix} \rangle \right) \\ &= C \exp \left(-\frac{1}{2} \langle \begin{pmatrix} L_{11} & L_{12} \\ L_{21} & L_{22} \end{pmatrix} \begin{pmatrix} \hat{\mathbf{z}} \\ \mathbf{t} \end{pmatrix}, \begin{pmatrix} \hat{\mathbf{z}} \\ \mathbf{t} \end{pmatrix} \rangle \right) \\ &= \tilde{C} \exp \left(-\frac{1}{2} \langle L_{22}(\mathbf{t} - \mathbf{a}), \mathbf{t} - \mathbf{a} \rangle \right) \quad (\text{平方完成}) \end{aligned}$$

ここで, \mathbf{a} (平均) は

$$\mathbf{a} = \begin{pmatrix} \sum_{j=1}^n c_j k_{x_j}(x_{n+1}) \\ \vdots \\ \sum_{j=1}^n c_j k_{x_j}(x_{n+m}) \end{pmatrix}, \quad \begin{pmatrix} c_1 \\ \vdots \\ c_n \end{pmatrix} = (K_n + \beta^{-1} I_n)^{-1} \hat{\mathbf{z}}.$$

により与えられる. この \mathbf{a} を $z(x_*)$ の予測として採用する.

付録 (条件付き分布)

$x \in [x_0, x_0 + h]$ のときに $y \in A$ となる条件付き確率

$$P(y \in A \mid x \in [x_0, x_0 + h]) = \frac{P((x, y) \in [x_0, x_0 + h] \times A)}{P((x, y) \in [x_0, x_0 + h] \times \mathbb{R})}$$

を分布関数の言葉で書き直せば,

$$\begin{aligned} P(y \in A \mid x \in [x_0, x_0 + h]) &= \frac{\int_A \left(\int_{x_0}^{x_0+h} p(x, y) dx \right) dy}{\int_{\mathbb{R}} \left(\int_{x_0}^{x_0+h} p(x, y) dx \right) dy} \\ &= \frac{\int_A \left(\frac{1}{h} \int_{x_0}^{x_0+h} p(x, y) dx \right) dy}{\int_{\mathbb{R}} \left(\frac{1}{h} \int_{x_0}^{x_0+h} p(x, y) dx \right) dy} \\ &\rightarrow \frac{\int_A p(x_0, y) dy}{\int_{\mathbb{R}} p(x_0, y) dy} \quad (h \rightarrow 0). \end{aligned}$$

このようにして, $x = x_0$ のときの条件付き分布 (確率密度関数) $Cp(x_0, y)$ ($1/C = \int_{\mathbb{R}} p(x_0, y) dy$) を得る.

CM

瀬戸・畑中・伊吹「機械学習のための関数解析入門」

内容

第1章 内積の数学1 (線形代数)

第2章 内積の数学2 (フーリエ解析)

第3章 内積の数学3 (ヒルベルト空間論)

第4章 カーネル法 (入門編)

第5章 カーネル法 (発展編)

- 理工系学部3年生以上を対象とした教科書.
- 数学専攻4年生の就職対策に最適.

内田老鶴圃から 2021年3月発売予定