

ガウス過程回帰

Gaussian Process Regression

大阪府立大学 工学研究科
清水 悠生

本記事の内容と対象

- ✓ ガウス過程による回帰を
なんとなく理解するための記事

- ✓ この順番で説明
 - ① ガウス分布とは
 - ② ガウス過程回帰をざっくり理解する
 - ③ ガウス過程の導出と意味
 - ④ ガウス過程を用いた回帰分析

① ガウス分布とは

- ✓ まずガウス過程回帰の名前の由来でもある
ガウス分布と呼ばれる確率分布の話からスタート


ガウス分布（正規分布）とは

- ✓ 確率密度が次式で与えられる分布を
ガウス分布（正規分布） と呼び、 $N(\mu, \sigma^2)$ で表す

$$N(\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$


μ : 平均
 σ^2 : 分散
 σ : 標準偏差

確率密度



標準偏差と確率

- ✓ 平均を中心とした標準偏差の整数倍以内のデータが出力される確率は下図のとおり




95.4%の確率で $\mu \pm 2\sigma$ の間の値が出力される！ という意味

分散のイメージ

- ✓ 分散はばらつき具合を表す指標であり
分散が小さいほど平均値に近い値が得られやすくなる


分散：小

確率密度



分散：大

確率密度



2次元のガウス分布

✓ ガウス分布を2次元に拡張すると次式のようなになる


$$N(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{2\pi\sqrt{|\boldsymbol{\Sigma}|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$

$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$: 確率変数ベクトル,

$\boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}$: 平均ベクトル,

$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \sigma_2^2 \end{bmatrix}$: 分散共分散行列

σ_1^2 : x_1 の分散
 σ_2^2 : x_2 の分散
 $\sigma_{12} = \sigma_{21}$: x_1 と x_2 の共分散



共分散のイメージ




✓ 変数間に相関があるとき、共分散の絶対値は大きくなる

$$\Sigma = \begin{bmatrix} 1 & -0.9 \\ -0.9 & 1 \end{bmatrix}$$

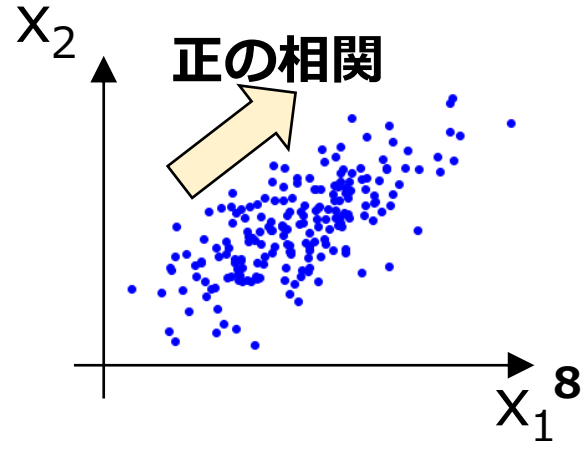


$$\Sigma = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} 1 & 0.7 \\ 0.7 & 1 \end{bmatrix}$$

確率密度分布



ガウス分布からのサンプル



N次元のガウス分布（多変量正規分布）

- ✓ ガウス分布をN次元に拡張すると次式のようなになる

$$N(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{N/2} \sqrt{|\boldsymbol{\Sigma}|}} \exp\left(-\frac{1}{2}(\boldsymbol{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{x} - \boldsymbol{\mu})\right)$$

$$\boldsymbol{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} : \text{確率変数ベクトル}, \quad \boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_N \end{bmatrix} : \text{平均ベクトル},$$

共分散

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_2^2 & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \cdots & \sigma_N^2 \end{bmatrix} : \text{分散共分散行列}$$

分散


- ✓ 多変量正規分布とよぶ

② ガウス過程回帰をざっくり理解する

- ✓ ガウス過程回帰は回帰分析手法の一つ
- ✓ カーネル関数を適切に選択することで
非線形な回帰分析が可能
- ✓ **どれだけその予測が信頼できるか**, という情報も算出可能

回帰分析の前提


- ✓ 下図のデータが与えられている状況を考える



最小二乗法の場合

- ✓ 最小二乗法により求めた3次の多項式近似曲線は下図の通り
- ✓ 未知データ x^* の予測 $f(x^*)$ は定数として与えられる


目的変数 y



- ✓ 最小二乗法の詳細はこちら
- ✓ <https://yuyumoyuyu.com/2020/12/13/simpleregressionwithols/>

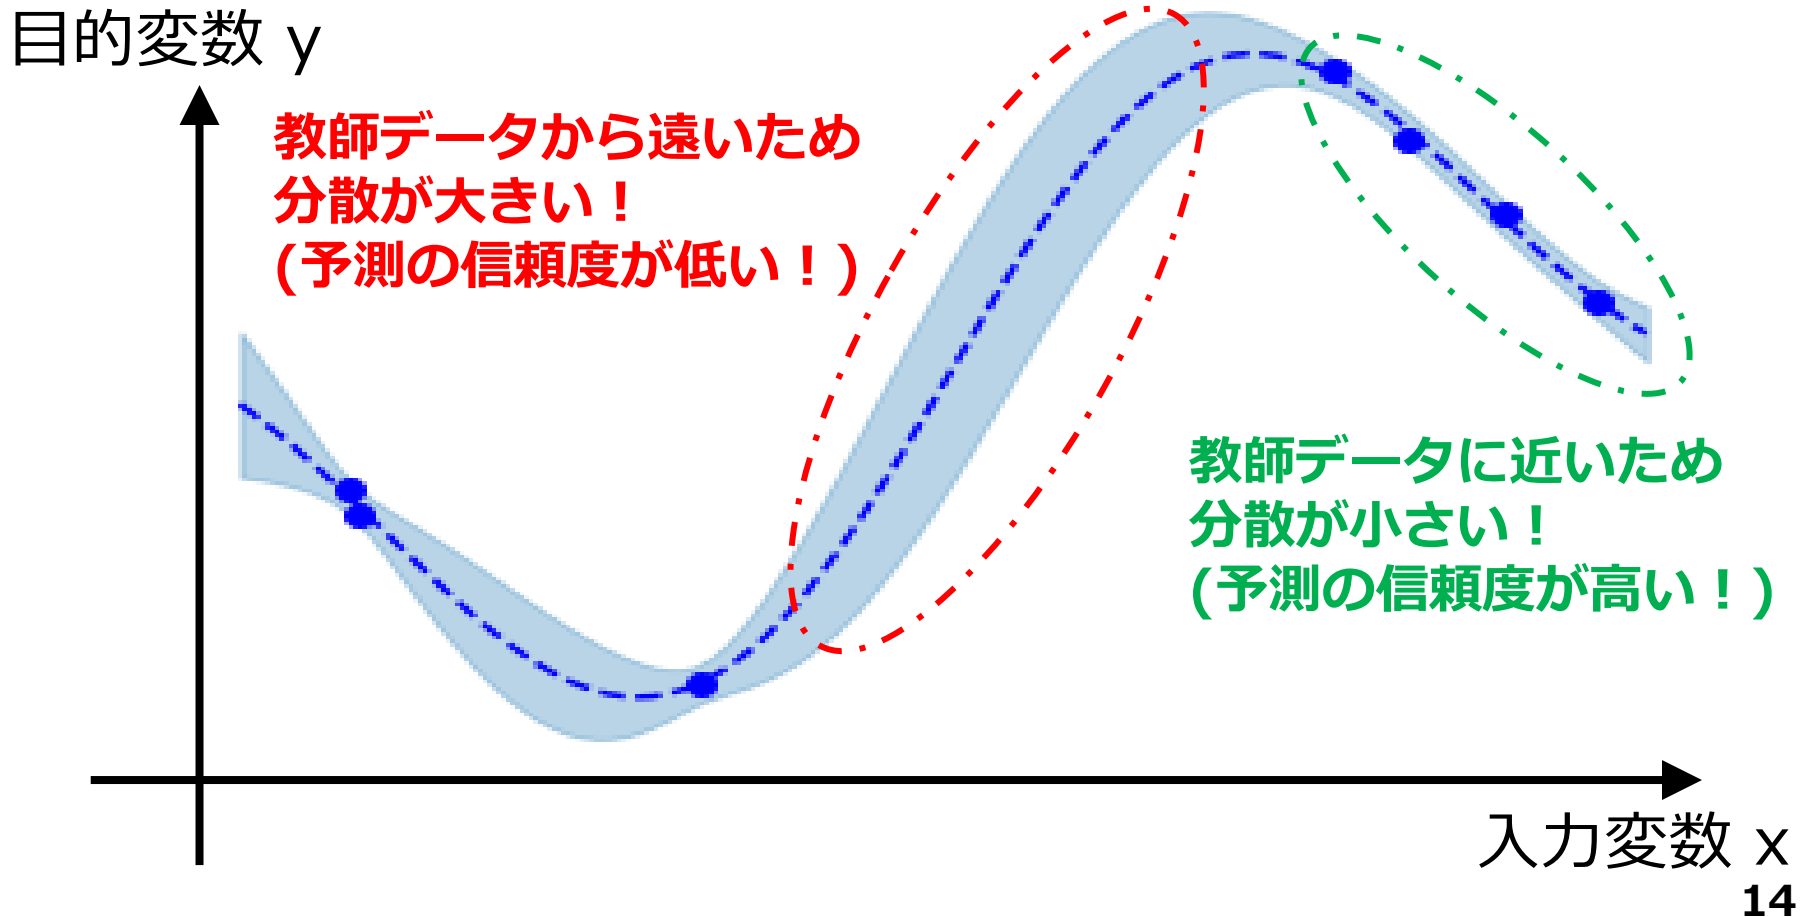
ガウス過程回帰の場合

- ✓ ガウス過程回帰の場合は**予測が確率として与えられる**！
- ✓ 未知データ x^* の予測 $f(x^*)$ は**ガウス分布に従う**



ガウス過程回帰の特徴

- ✓ ガウス過程回帰の予測結果は、入力(教師)データから遠ければ遠いほど分散が大きくなる (予測の信頼度が低下)



ガウス過程回帰のざっくりまとめ

- ✓ ガウス過程回帰の特徴は下記の通り
 - モデルの予測値が確定した値ではなく**確率で与えられる**
 - その予測値は**ガウス分布**に従い、分散の値により予測の信頼度が求められる
 - **教師データに近い入力変数**が与えられた場合は、**予測値の分散が小さくなる**（予測の信頼度が高くなる）
- ✓ なんとなく理解出来たら、先にプログラムを動かしてみるのも手↓
- ✓ <https://github.com/yshimizu12/GaussianProcessRegression>

③ ガウス過程とは

- ✓ まず、ガウス過程とは何か説明

ガウス過程の定義

- ✓ ガウス過程の定義は以下の通り
- ✓ 入力 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$ が与えられたとき
対応する**出力ベクトル \mathbf{f} が多変量ガウス分布に従うとき**
 \mathbf{f} はガウス過程に従う, という

$$\mathbf{f} = \begin{pmatrix} f(x^{(1)}) \\ f(x^{(2)}) \\ \vdots \\ f(x^{(N)}) \end{pmatrix} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$$

- ✓ 次ページから, この導出と意味について説明

線形回帰モデルの引用

- ✓ n組のデータが与えられた場合の線形回帰モデルは以下の通り

$$\begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \vdots \\ y^{(n)} \end{bmatrix} = w_0 + w_1 \begin{bmatrix} x_1^{(1)} \\ x_1^{(2)} \\ \vdots \\ x_1^{(n)} \end{bmatrix} + \dots + w_m \begin{bmatrix} x_m^{(1)} \\ x_m^{(2)} \\ \vdots \\ x_m^{(n)} \end{bmatrix} = \begin{bmatrix} 1 & x_1^{(1)} & \dots & x_m^{(1)} \\ 1 & x_1^{(2)} & \dots & x_m^{(2)} \\ \vdots & \vdots & \dots & \vdots \\ 1 & x_1^{(n)} & \dots & x_m^{(n)} \end{bmatrix} \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_m \end{bmatrix}$$

$$\Leftrightarrow \mathbf{y} = \mathbf{X}\mathbf{w}$$

$y^{(i)}$: i番目の出力データ ($i = 1, \dots, n$)

$x_1^{(i)}, \dots, x_m^{(i)}$: i番目のm種類の
入力データ ($i = 1, \dots, n$)

w_0, \dots, w_m : 重み係数

- ✓ こちら↓で定義したモデル

- ✓ <https://yuyumoyuyu.com/2020/12/20/multipleregression/>

非線形写像

- ✓ 関数の表現力をあげるため、
入力ベクトルを関数化して表現する

$$\begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \vdots \\ y^{(n)} \end{bmatrix} = \begin{bmatrix} \phi_0(\mathbf{x}^{(1)}) & \phi_1(\mathbf{x}^{(1)}) & \cdots & \phi_m(\mathbf{x}^{(1)}) \\ \phi_0(\mathbf{x}^{(2)}) & \phi_1(\mathbf{x}^{(2)}) & \cdots & \phi_m(\mathbf{x}^{(2)}) \\ \vdots & \vdots & \ddots & \vdots \\ \phi_0(\mathbf{x}^{(n)}) & \phi_1(\mathbf{x}^{(n)}) & \cdots & \phi_m(\mathbf{x}^{(n)}) \end{bmatrix} \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_m \end{bmatrix}$$

$$\Leftrightarrow \mathbf{y} = \Phi \mathbf{w}$$

$y^{(i)}$: i 番目の出力データ ($i = 1, \dots, n$)

$\mathbf{x}^{(i)}$: i 番目の入力ベクトル ($i = 1, \dots, n$)

ϕ_j : j 番目の関数 ($j = 0, \dots, m$)

w_0, \dots, w_m : 重み係数

関数の例

$$\phi(x) = x^2, x^3, \sin x, \log x, \dots$$

様々な非線形表現を用いることでモデルの表現力を向上！

重みをガウス分布に従って生成

- ✓ 重み \mathbf{w} が以下のガウス分布から生成されるものとする

$$\mathbf{w} = \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_m \end{bmatrix} \sim N(\mathbf{0}, \lambda^2 \mathbf{I}) = N\left(\begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}, \begin{bmatrix} \lambda^2 & & 0 \\ & \ddots & \\ 0 & & \lambda^2 \end{bmatrix}\right)$$

平均0 分散は全て λ^2 共分散は全て0 \Rightarrow 独立!

- ✓ 行列 Φ は定数行列であるため、
出力ベクトル $\mathbf{y} = \Phi \mathbf{w}$ も同様にガウス分布に従う

出力ベクトルの平均と共分散行列

- ✓ 出力ベクトルの期待値は以下のとおり

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

Φ は定数

\mathbf{w} の期待値は $\mathbf{0}$

$\mathbb{E}[X]$: X の期待値

- ✓ 出力ベクトルの共分散行列は以下のとおり

$$\Sigma = \mathbb{E}[(\mathbf{y} - \mathbb{E}[\mathbf{y}])(\mathbf{y} - \mathbb{E}[\mathbf{y}])^T]$$

$$= \mathbb{E}[\mathbf{y}\mathbf{y}^T]$$

$$= \mathbb{E}[(\Phi \mathbf{w})(\Phi \mathbf{w})^T]$$

$$= \mathbb{E}[\Phi \mathbf{w} \mathbf{w}^T \Phi^T]$$

$$= \Phi \mathbb{E}[\mathbf{w} \mathbf{w}^T] \Phi^T$$

$$= \Phi \lambda^2 \mathbf{I} \Phi^T = \lambda^2 \Phi \Phi^T$$

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

$\mathbf{y} = \Phi \mathbf{w}$ を代入

転置行列の積の公式

Φ は定数

$$\begin{aligned} \mathbf{w} \text{の分散を } V[\mathbf{w}] \text{ とすると} \\ V[\mathbf{w}] &= \mathbb{E}[\mathbf{w} \mathbf{w}^T] - \mathbb{E}[\mathbf{w}] \mathbb{E}[\mathbf{w}]^T \\ &= \mathbb{E}[\mathbf{w} \mathbf{w}^T] \end{aligned}$$

まとめると…

- ✓ これまでの計算をまとめると次のようになり
これは最初のガウス過程の定義に一致


$$\mathbf{y} \sim N(\mathbf{0}, \lambda^2 \Phi \Phi^T)$$

- ✓ この計算には**重みベクトル w が出てこない!**
- ✓ つまり、他の機械学習手法のように重みを学習する必要がなく、共分散行列を計算するだけでよい!



出力データの平均は0でよいのか？

- ✓ 平均ベクトルが $\mathbf{0}$ になっているが
観測データ y はあらかじめ平均を引いておけば
平均が $\mathbf{0}$ になるため、以下では平均 $\mathbf{0}$ のガウス過程を扱う

$$y \sim N(\mathbf{0}, \lambda^2 \Phi \Phi^T)$$



平均で引く



ガウス過程の共分散行列の解釈


- ✓ 共分散は特徴ベクトル ϕ の内積で計算できるため
類似した入力ベクトル x に対応する出力 y も似た値をとる

$$\begin{aligned}\Sigma &= \lambda^2 \Phi \Phi^T = \lambda^2 \begin{bmatrix} \vdots & & \\ \phi_0(x^{(i)}) & \cdots & \phi_m(x^{(i)}) \\ \vdots & & \end{bmatrix} \begin{bmatrix} \cdots & \begin{bmatrix} \phi_0(x^{(j)}) \\ \vdots \\ \phi_m(x^{(j)}) \end{bmatrix} & \cdots \end{bmatrix} \\ &= \lambda^2 \begin{bmatrix} \vdots & & \\ \phi(x^{(i)})^T \\ \vdots & & \end{bmatrix} \begin{bmatrix} \cdots & \begin{bmatrix} \phi(x^{(j)}) \end{bmatrix} & \cdots \end{bmatrix}\end{aligned}$$


$$\Rightarrow \Sigma_{ij} = \lambda^2 \phi(x^{(i)})^T \phi(x^{(j)})$$

共分散行列の(i,j)要素


$x^{(i)}$ と $x^{(j)}$ が
似たベクトル



$\phi(x^{(i)})$ と
 $\phi(x^{(j)})$ の
内積が大きい



Σ_{ij} が大きい



$y^{(i)}$ と $y^{(j)}$ が
似た値と
なりやすい
(p.8参照)

カーネル関数の導入

- ✓ 共分散行列の各要素は特徴ベクトル $\boldsymbol{\phi}$ の内積によって決まるため、特徴ベクトルを明示的に求める必要はない
- ✓ 適当な**カーネル関数**を用いることで、共分散行列を表現
- ✓ **カーネル行列**や**グラム行列**と呼ばれる

カーネル関数： $\mathbf{x}^{(i)}$ と $\mathbf{x}^{(j)}$ の類似度を表現する関数

$$k(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \lambda^2 \boldsymbol{\phi}(\mathbf{x}^{(i)})^T \boldsymbol{\phi}(\mathbf{x}^{(j)})$$

共分散行列をカーネル行列（グラム行列） \mathbf{K} を用いて表現

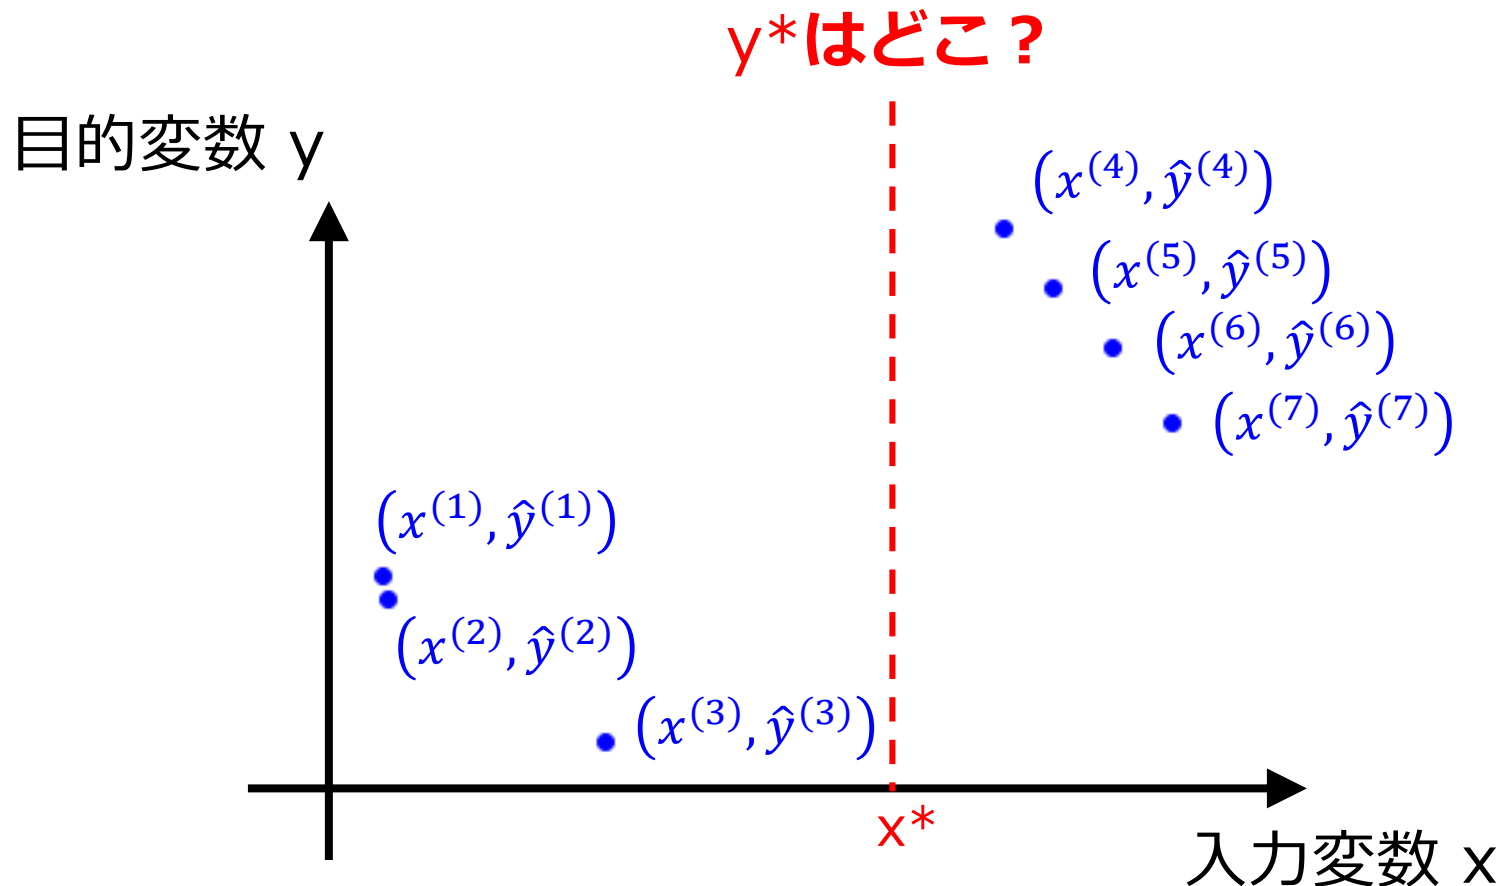
$$\boldsymbol{\Sigma} = \mathbf{K} = \begin{bmatrix} k(\mathbf{x}^{(1)}, \mathbf{x}^{(1)}) & k(\mathbf{x}^{(1)}, \mathbf{x}^{(2)}) & \dots & k(\mathbf{x}^{(1)}, \mathbf{x}^{(N)}) \\ k(\mathbf{x}^{(2)}, \mathbf{x}^{(1)}) & k(\mathbf{x}^{(2)}, \mathbf{x}^{(2)}) & \dots & k(\mathbf{x}^{(2)}, \mathbf{x}^{(N)}) \\ \vdots & \vdots & \ddots & \vdots \\ k(\mathbf{x}^{(N)}, \mathbf{x}^{(1)}) & k(\mathbf{x}^{(N)}, \mathbf{x}^{(2)}) & \dots & k(\mathbf{x}^{(N)}, \mathbf{x}^{(N)}) \end{bmatrix}$$

④ ガウス過程を用いた回帰分析

- ✓ つづいて、ガウス過程を用いた回帰分析の方法について説明

未知のデータをどう予測するか？


- ✓ 図のように既知のデータセットが与えられた前提で未知の入力変数 x^* に対応する y^* を予測する



最小二乗法なら簡単

- ✓ 以下のように、最小二乗法により3次多項式を求めた場合
重み係数 w_0, w_1, w_2, w_3 が全て計算済みなので
未知の入力データ x^* を代入するだけでよい

目的変数 y




ガウス過程では一筋縄ではいかない

- ✓ ガウス過程の場合，既知データの確率分布だけが与えられ
重み係数は明示的に計算されておらず，予測ができない！

$$\mathbf{y} = [y^{(1)} \quad y^{(2)} \quad y^{(3)} \quad y^{(4)} \quad y^{(5)} \quad y^{(6)} \quad y^{(7)}]^T \sim N(\mathbf{0}, \mathbf{K})$$

y^* はどこ？



未知の入力データを含んだ分布を考える

- ✓ ガウス過程回帰では，未知の入力データを含んだ分布を再定義して考える！

$$\mathbf{y}' = \begin{bmatrix} y^{(1)} \\ \vdots \\ y^{(7)} \\ y^* \end{bmatrix} \sim N \left(\begin{bmatrix} 0 \\ \vdots \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} \mathbf{K} & \mathbf{k}_* \\ \mathbf{k}_*^T & k(x^*, x^*) \end{bmatrix} \right)$$

未知データと既知データのカーネル関数

- ✓ この多変量ガウス分布から，予測分布は次式で与えられる（証明は参考文献参照）

$$p(y^* | x^*, \mathbf{x}, \mathbf{y}) = N \left(\mathbf{k}_*^T \mathbf{K}^{-1} \mathbf{y}, k(x^*, x^*) - \mathbf{k}_*^T \mathbf{K}^{-1} \mathbf{k}_* \right)$$

$x^*, \mathbf{x}, \mathbf{y}$ が与えられた時の y^* の確率

期待値
分散

予測分布の期待値と分散の解釈

✓ 予測分布の解釈は次の通り

期待値 $k_*^T K^{-1} \mathbf{y}$

K^{-1} によって線形変換された \mathbf{y} と k_*^T の内積と解釈可能

k_*^T は未知データと既知データの類似度を表しているため

x^* に類似した $x^{(i)}$ の出力 $y^{(i)}$ に期待値が類似すると解釈できる

分散 $k(x^*, x^*) - k_*^T K^{-1} k_*$

K^{-1} によって線形変換された k_* と k_*^T の内積が $k(x^*, x^*)$ から

差し引かれる

k_*^T は未知データと既知データの類似度を表しているため

x^* に類似した $x^{(i)}$ が多ければ多いほど $k_*^T K^{-1} k_*$ が大きくなり

分散が小さくなり、予測の信頼度が向上すると解釈できる