

第4章

最尤推定法

- 4.1 最尤推定法の定義
- 4.2 ガウスモデル

07T4072F 岡崎駿

パラメトリック法（前回）

- ・パラメトリック法

パラメトリックと呼ばれる有限個のパラメータで記述された確率密度関数の集合の中から、真の確率密度関数を最もよく近似するものを選ぶ。



『最尤推定法』

パラメトリックモデル

有限個のパラメータで記述された確率密度関数の集合

- ・パラメトリックモデル

$$q(\mathbf{x}; \boldsymbol{\theta})$$

- ・確率変数: \mathbf{x}
- ・パラメータ: $\boldsymbol{\theta} = (\theta^{(1)}, \dots, \theta^{(t)})^T$
- ・パラメータの定義域: Θ

尤度と最尤推定法(1)

目的: 確率密度関数を近似したい



手元の訓練標本が最も生起しやすいように
パラメータを決定する

尤度と最尤推定法(2)

・尤度

訓練標本 $\{\mathbf{x}\}_{i=1}^n$ が最も生起しやすい確率を、
パラメータ $\boldsymbol{\theta}$ の関数と見たもの

$$L(\boldsymbol{\theta}) := \prod_{i=1}^n q(\mathbf{x}_i; \boldsymbol{\theta})$$

・最尤推定法

尤度が最大になるようにパラメータ値を決定する方法

$$\hat{\boldsymbol{\theta}}_{ML} := \arg \max_{\boldsymbol{\theta} \in \Theta} L(\boldsymbol{\theta})$$

$\hat{\boldsymbol{\theta}}_{ML}$: 最尤推定法によって得られるパラメータ値

確率密度関数と尤度方程式

パラメータ $\hat{\theta}_{ML}$ を用いた確率密度関数

$$\hat{p}(\mathbf{x}) = q(\mathbf{x}; \hat{\theta}_{ML})$$

パラメトリックモデル $q(\mathbf{x}; \theta)$ が θ に関して
微分可能なとき

$$\left. \frac{\partial}{\partial \theta} L(\theta) \right|_{\theta = \hat{\theta}_{ML}} = \mathbf{0}_t$$




『尤度方程式』

尤度方程式と最尤推定解

『尤度方程式』  『最尤推定解』

○ 必要条件
× 十分条件



対数尤度

「尤度を最大にするパラメータ」

||

「対数をとった尤度を最大にするパラメータ」

※具体的な計算方法は用いるパラメトリックモデルによって異なる！

$$\begin{aligned}\hat{\boldsymbol{\theta}}_{ML} &= \arg \max_{\boldsymbol{\theta} \in \Theta} \log L(\boldsymbol{\theta}) \\ &= \arg \max_{\boldsymbol{\theta} \in \Theta} \left[\sum_{i=1}^n \log q(\mathbf{x}_i; \boldsymbol{\theta}) \right]\end{aligned}$$

対数尤度

$$\left. \frac{\partial}{\partial \boldsymbol{\theta}} \log L(\boldsymbol{\theta}) \right|_{\boldsymbol{\theta} = \hat{\boldsymbol{\theta}}_{ML}} = \mathbf{0}_t$$

尤度方程式

ガウスモデル

ガウス分布をパラメトリックモデルとして用いたもの

d 次元ベクトルのパターン \mathbf{x} に対する一般形

$$q(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{\frac{d}{2}} \det(\boldsymbol{\Sigma})^{\frac{1}{2}}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})\right)$$

▪ d 次元期待値ベクトル: $\boldsymbol{\mu}$

▪ $d \times d$ 行列のガウスモデルのパラメータ(分散共分散行列): $\boldsymbol{\Sigma}$

※ $\boldsymbol{\Sigma}$ は正定値行列かつ対称行列の必要がある。

そのため任意の非ゼロベクトル $\boldsymbol{\varphi}$ に対して $\boldsymbol{\varphi}^T \boldsymbol{\Sigma} \boldsymbol{\varphi} > 0$ を満たす。

ガウスモデル-尤度方程式-

ガウスモデルの特徴

→パラメータ $\boldsymbol{\mu}$ と $\boldsymbol{\Sigma}$ がそれぞれ分布の期待値と分散共分散行列に対応している。(2.1節24p)

$$\left\{ \begin{array}{l} \boldsymbol{\mu} = E_{\mathbf{x}}[\mathbf{x}] = \int \mathbf{x}q(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma})d\mathbf{x} \\ \boldsymbol{\Sigma} = V_{\mathbf{x}}[\mathbf{x}] = \int (\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T q(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma})d\mathbf{x} \end{array} \right.$$

ガウスモデルの尤度方程式は

$$\left\{ \begin{array}{l} \left. \frac{\partial}{\partial \boldsymbol{\mu}} \log L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \right|_{\boldsymbol{\mu} = \hat{\boldsymbol{\mu}}_{ML}} = \mathbf{0}_d \\ \left. \frac{\partial}{\partial \boldsymbol{\Sigma}} \log L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \right|_{\boldsymbol{\Sigma} = \hat{\boldsymbol{\Sigma}}_{ML}, \boldsymbol{\mu} = \hat{\boldsymbol{\mu}}_{ML}} = \mathbf{0}_{d \times d} \end{array} \right.$$

ガウスモデル-最尤推定法-

前ページの尤度方程式を解けば μ 、 Σ の最尤推定量 $\hat{\mu}_{ML}$ 、 $\hat{\Sigma}_{ML}$ が得られる。

$$\left\{ \begin{array}{l} \hat{\mu}_{ML} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \\ \hat{\Sigma}_{ML} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \hat{\mu}_{ML})(\mathbf{x}_i - \hat{\mu}_{ML})^T \end{array} \right.$$

真の期待値を標本平均、
真の分散共分散行列を標本分散共分散行列
で表している。

共分散のないガウスモデル(1)

- 一般の分散共分散行列 Σ の i 番目の対角成分を $(\sigma^{(i)})^2$ で表す。

$$q(\mathbf{x}; \boldsymbol{\mu}, \sigma^{(1)}, \dots, \sigma^{(d)}) = \prod_{j=1}^d \frac{1}{\sqrt{2\pi(\sigma^{(j)})^2}} \exp\left(-\frac{(x^{(j)} - \mu^{(j)})^2}{2(\sigma^{(j)})^2}\right)$$

- $\sigma^{(j)}$ の最尤推定量

$$\hat{\sigma}^{(j)}_{ML} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^{(j)} - \mu_i^{(j)})^2}$$

共分散のないガウスモデル(2)

- 全ての分散 $(\sigma^{(j)})^2$ が全て等しいガウスモデル
※ 共通の分散を σ で表す。

$$q(\mathbf{x}; \boldsymbol{\mu}, \sigma) = \frac{1}{(2\pi\sigma^2)^{\frac{d}{2}}} \exp\left(-\frac{(\mathbf{x} - \boldsymbol{\mu})^T (\mathbf{x} - \boldsymbol{\mu})}{2\sigma^2}\right)$$

- σ の最尤推定量

$$\hat{\sigma}_{ML} = \sqrt{\frac{1}{nd} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})^T (\mathbf{x}_i - \boldsymbol{\mu})} = \sqrt{\frac{1}{d} \sum_{j=1}^d (\hat{\sigma}_{ML}^{(j)})^2}$$