

# データサイエンス

問題 1. スカラーの値を持つデータ点  $x_i$  ( $i = 1, \dots, n$ ) が、確率密度関数  $p(x|C_1)$  と  $p(x|C_2)$  のいずれか一方に従って生成される場合の確率推論について、以下の問い合わせに答えよ。ただし、 $n$  は 1 以上の整数であり、 $C_1$  と  $C_2$  はそれぞれ異なるクラス 1, クラス 2 を表すものとする。

$$p(x|C_1) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x - \mu_1)^2}{2}\right), \quad p(x|C_2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu_2)^2}{2\sigma^2}\right)$$

ここで、クラス 1 の事前確率は  $3/7$  であり、クラス 2 の事前確率は  $4/7$  であるとする。 $\mu_1$  と  $\mu_2$  は定数であり、 $\sigma$  は正の定数であるとする。 $\exp(-0.5) \approx 0.61$  を用いてよい。

- (1) 3 つのデータ点  $x_1, x_2, x_3$  がクラス 1 に属しているものとする。このとき、 $\mu_1$  が従う尤度関数  $L_1(\mu_1)$  は  $L_1(\mu_1) = p(x_1|C_1)p(x_2|C_1)p(x_3|C_1)$  となる。最尤推定法により、 $\mu_1$  の推定値を導出せよ。また、3 つのデータ点が  $x_1 = 0.1, x_2 = 1.1, x_3 = -0.5$  である場合の  $\mu_1$  の推定値を求めよ。
- (2) 3 つのデータ点  $x_4, x_5, x_6$  がクラス 2 に属しているものとする。 $\mu_2$  と  $\sigma^2$  が従う尤度関数  $L_2(\mu_2, \sigma^2)$  を求めよ。最尤推定法により、 $\mu_2$  と  $\sigma^2$  の推定値を導出せよ。また、3 つのデータ点が  $x_4 = 1, x_5 = 2, x_6 = 3$  である場合の  $\mu_2$  と  $\sigma^2$  の推定値を求めよ。
- (3)  $\mu_1 = -0.1, \mu_2 = 2.9, \sigma = 2$  とし、1 つのデータ点  $x_7 = 0.9$  のみが与えられたとする。各クラスの事後確率を求めよ。また、事後確率最大化法により、データ点  $x_7$  が属するクラスを推定せよ。

問題 2. 2 次元上の 3 点のデータ点  $\mathbf{r}_i = (x_i, y_i)^T$  ( $i = 1, 2, 3$ ) からなるデータ集合が与えられた場合の主成分分析について、以下の問い合わせに答えよ。ここで、 $\mathbf{r}_1 = (-1, -1)^T, \mathbf{r}_2 = (0, 0)^T, \mathbf{r}_3 = (1, 1)^T$  とし、 $T$  は転置を示す。

- (1) データ集合における  $x_i$  の分散  $\sigma_x^2$ ,  $y_i$  の分散  $\sigma_y^2$ , ならびに、 $x_i$  と  $y_i$  の共分散  $\sigma_{xy}$  を求めることで、分散共分散行列  $\Sigma = \begin{pmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{pmatrix}$  を求めよ。得られた分散共分散行列  $\Sigma$  の固有値  $\lambda_1, \lambda_2$  と対応する固有ベクトル  $\mathbf{u}_1, \mathbf{u}_2$  を求めよ。なお、 $\lambda_1 \geq \lambda_2$  とする。
- (2) データ集合を主成分の空間に変換し、変換後のデータ点  $\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \tilde{\mathbf{r}}_3$  を求めよ。変換前の座標軸と変換後の座標軸（第 1 主成分、第 2 主成分の各軸）を用いて、変換後のデータ点  $\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \tilde{\mathbf{r}}_3$  を図示せよ。次元削減が可能であるかどうかを理由を付して述べよ。
- (3) 変換後のデータ点  $\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \tilde{\mathbf{r}}_3$  の第 1 主成分のみが与えられる場合を考える。第 1 主成分のみを持つ変換後のデータ点を元の空間に逆変換せよ。この逆変換により、変換前のデータ集合  $\mathbf{r}_1, \mathbf{r}_2, \mathbf{r}_3$  を再現可能であるかどうかを理由を付して述べよ。