

# 知能機械と自然言語処理


## 知能機械部 第8回

ソフトウェア情報学部

Goutam Chakraborty

1

# 簡単な分類の仕方



2

# 多次元の確率密度関数

Class  $C_1$  のデータの平均  $\bar{\mu}_1$ , 相関行列  $\Sigma_1$  の場合、条件付き確率密度関数は

$$f_1(\vec{x}) = \frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{|\Sigma_1|}} \exp\left(-\frac{1}{2}(\vec{x} - \bar{\mu}_1)^T \Sigma_1^{-1} (\vec{x} - \bar{\mu}_1)\right) \dots\dots ①$$

Class  $C_2$  のデータの平均  $\bar{\mu}_2$ , 相関行列  $\Sigma_2$  の場合、条件付き確率密度関数は

$$f_2(\vec{x}) = \frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{|\Sigma_2|}} \exp\left(-\frac{1}{2}(\vec{x} - \bar{\mu}_2)^T \Sigma_2^{-1} (\vec{x} - \bar{\mu}_2)\right) \dots\dots ②$$

3

# logarithm (対数) の復習

$$\log_{10} x = \log x$$

$$\log_e x = \ln x$$

$$\log_2 x = \lg x$$

$$e = 1 + \frac{1}{1} + \frac{1}{2!} + \dots \infty$$

$$= 1 + \sum_{i=1}^{\infty} \frac{1}{i!} = 2.71828\dots$$

$$\log_a b \times \log_b c \times \log_c a = 1$$

$$\log_a a = 1$$

$$\log_2 8a = \log_2 2^3 + \log_2 a = 3 + \log_2 a$$

$$\ln 3.3 = ? \quad \log_e 3.3 \times \log_{10} e \times \frac{1}{\log_{10} 3.3} = 1$$

対数表から求める

4

# 境界線の求め方(1)

①, ②より,  $f_1(\vec{x}) = f_2(\vec{x})$ ,  $P(C_1) = P(C_2)$  ならば、「 $\vec{x}$  の軌跡は、2つのクラス境界線」となる。これに  $\log_e$  を両辺にとると

$$-\ln \sqrt{|\Sigma_1|} + \left[-\frac{1}{2}(\vec{x} - \bar{\mu}_1)^T \Sigma_1^{-1} (\vec{x} - \bar{\mu}_1)\right] = -\ln \sqrt{|\Sigma_2|} + \left[-\frac{1}{2}(\vec{x} - \bar{\mu}_2)^T \Sigma_2^{-1} (\vec{x} - \bar{\mu}_2)\right]$$

$$-\frac{1}{2} \ln |\Sigma_1| - \frac{1}{2} (\vec{x}^T \Sigma_1^{-1} \vec{x} - \vec{x}^T \Sigma_1^{-1} \bar{\mu}_1 - \bar{\mu}_1^T \Sigma_1^{-1} \vec{x} + \bar{\mu}_1^T \Sigma_1^{-1} \bar{\mu}_1)$$

$$= -\frac{1}{2} \ln |\Sigma_2| - \frac{1}{2} (\vec{x}^T \Sigma_2^{-1} \vec{x} - \vec{x}^T \Sigma_2^{-1} \bar{\mu}_2 - \bar{\mu}_2^T \Sigma_2^{-1} \vec{x} + \bar{\mu}_2^T \Sigma_2^{-1} \bar{\mu}_2)$$

$$\ln |\Sigma_1| + (\vec{x}^T \Sigma_1^{-1} \vec{x} - \vec{x}^T \Sigma_1^{-1} \bar{\mu}_1 - \bar{\mu}_1^T \Sigma_1^{-1} \vec{x} + \bar{\mu}_1^T \Sigma_1^{-1} \bar{\mu}_1)$$

$$= \ln |\Sigma_2| + (\vec{x}^T \Sigma_2^{-1} \vec{x} - \vec{x}^T \Sigma_2^{-1} \bar{\mu}_2 - \bar{\mu}_2^T \Sigma_2^{-1} \vec{x} + \bar{\mu}_2^T \Sigma_2^{-1} \bar{\mu}_2)$$

$\Sigma_1 = \Sigma_2$  のとき,  $\vec{x}^T \cdot \vec{x}$  の項がなくなり、境界線は直線になる。

5

# 境界線の求め方(2)

これから、2つのクラスの問題について考える。  
 $C_1$  の平均と相関行列は  $\bar{\mu}_1, \Sigma_1$ 、 $C_2$  は  $\bar{\mu}_2, \Sigma_2$ 。  
 データは  $d$  次元のデータで、特色の数は  $d$ 。  
 ベイズの定理から境界線の式は以下の式で求められる。

$$\frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{|\Sigma_1|}} e^{-\frac{1}{2}[(\vec{x} - \bar{\mu}_1)^T \Sigma_1^{-1} (\vec{x} - \bar{\mu}_1)]} \times P(C_1)$$

$$= \frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{|\Sigma_2|}} e^{-\frac{1}{2}[(\vec{x} - \bar{\mu}_2)^T \Sigma_2^{-1} (\vec{x} - \bar{\mu}_2)]} \times P(C_2)$$

6

## 境界線の求め方(3)

$\log_e$  を両辺にとると

$$-\frac{1}{2} \ln |\Sigma_1| - \frac{1}{2} [(\vec{x} - \vec{\mu}_1)^T \Sigma_1^{-1} (\vec{x} - \vec{\mu}_1)] + \ln P(C_1)$$

$$= -\frac{1}{2} \ln |\Sigma_2| - \frac{1}{2} [(\vec{x} - \vec{\mu}_2)^T \Sigma_2^{-1} (\vec{x} - \vec{\mu}_2)] + \ln P(C_2)$$

$$[(\vec{x} - \vec{\mu}_2)^T \Sigma_2^{-1} (\vec{x} - \vec{\mu}_2)] - [(\vec{x} - \vec{\mu}_1)^T \Sigma_1^{-1} (\vec{x} - \vec{\mu}_1)] = \ln |\Sigma_1| - \ln |\Sigma_2| + 2 \ln P(C_2) - 2 \ln P(C_1)$$

7

## 境界線の求め方(4)

ここで、実際の数値を入れて計算してみる。ただし、 $P(C_1) = P(C_2)$  であるとする。

$$\vec{\mu}_1 = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad \Sigma_1 = \begin{bmatrix} 0.30 & 0 \\ 0 & 0.35 \end{bmatrix}$$

$$|\Sigma_1| = 0.105$$

$$\Sigma_1^{-1} = \begin{bmatrix} 3.3 & 0 \\ 0 & 2.8 \end{bmatrix}$$

$$\vec{\mu}_2 = \begin{bmatrix} 4 \\ 0 \end{bmatrix} \quad \Sigma_2 = \begin{bmatrix} 1.20 & 0 \\ 0 & 1.85 \end{bmatrix}$$

$$|\Sigma_2| = 2.22$$

$$\Sigma_2^{-1} = \begin{bmatrix} 0.8 & 0 \\ 0 & 0.5 \end{bmatrix}$$

8

## 境界線の求め方(5)

$$\begin{bmatrix} x_1 - 4 & x_2 \end{bmatrix} \begin{bmatrix} 0.8 & 0 \\ 0 & 0.5 \end{bmatrix} \begin{bmatrix} x_1 - 4 \\ x_2 \end{bmatrix} - \begin{bmatrix} x_1 & x_2 \end{bmatrix} \begin{bmatrix} 3.3 & 0 \\ 0 & 2.8 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \ln |\Sigma_1| - \ln |\Sigma_2|$$

$$\begin{bmatrix} 0.8(x_1 - 4) & 0.5x_2 \end{bmatrix} \begin{bmatrix} x_1 - 4 \\ x_2 \end{bmatrix} - \begin{bmatrix} 3.3x_1 & 2.8x_2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = -2.2 - 0.8$$

$$\begin{bmatrix} 0.8(x_1 - 4)^2 + 0.5x_2^2 \end{bmatrix} - \begin{bmatrix} 3.3x_1^2 + 2.8x_2^2 \end{bmatrix} = -3.0$$

$$\begin{bmatrix} 0.8x_1^2 - 6.4x_1 + 12.8 + 0.5x_2^2 \end{bmatrix} - \begin{bmatrix} 3.3x_1^2 + 2.8x_2^2 \end{bmatrix} = -3.0$$

$$-2.5x_1^2 - 6.4x_1 - 2.3x_2^2 = -15.8$$


$$\frac{(x_1 + 1.3)^2}{2.3} + \frac{x_2^2}{2.5} = 3.5$$

この境界線は楕円になる

9

## 境界線の求め方(6)

$$\frac{(x_1 + 1.3)^2}{8.05} + \frac{x_2^2}{8.75} = 1$$



10

## 境界線の種類

- $\Sigma_1 = \Sigma_2$  のとき、境界線は直線になる
- $\Sigma_1 \neq \Sigma_2$  のとき、境界線は曲線 (Conics) になる
  - 楕円 (Circle)
  - 楕円 (Ellipse)
  - 放物線 (Parabola)
  - 双曲線 (Hyperbola)

11

## 行列の積の復習

$$\Sigma = \begin{bmatrix} 0.3 & 0 \\ 0 & 0.3 \end{bmatrix} \text{ のとき、 } \vec{x}^T \Sigma^{-1} \vec{x} \text{ を求めてみよう！}$$

$$\Sigma^{-1} = \frac{1}{0.3 \times 0.3} \begin{bmatrix} 0.3 & 0 \\ 0 & 0.3 \end{bmatrix}$$

$$\vec{x}^T \Sigma^{-1} \vec{x} = \begin{bmatrix} x_1 & x_2 \end{bmatrix} \times \frac{1}{0.3 \times 0.3} \begin{bmatrix} 0.3 & 0 \\ 0 & 0.3 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$= \frac{100}{9} \begin{bmatrix} x_1 & x_2 \end{bmatrix} \begin{bmatrix} 0.3 & 0 \\ 0 & 0.3 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$= 11 \times \begin{bmatrix} 0.3x_1 & 0.3x_2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = 3.3x_1^2 + 3.3x_2^2$$

12

## 曲線の基礎

- $ax_1^2 + bx_2^2 + cx_1x_2 + dx_1 + ex_2 + f = 0$ 
  - $a \neq 0, b \neq 0 \rightarrow$  円 ( $a=b$ ), 楕円
  - $a=0, b \neq 0$  または  $a \neq 0, b=0 \rightarrow$  放物線
  - $a=b=c=0 \rightarrow$  直線
  - $a=b=c=0$  のとき、成立する  $dx_1 + ex_2 + f = 0$
  - $\Sigma_1 = \Sigma_2$

13

## 課題

- Nishin2D-300.txt, Sanma2D-500.txtのデータの最初の200のデータを使って、境界線の式を求めよ。(データを正規化する必要あり)
  - つまり、 $P(C_1) = P(C_2)$  となる。
  - $\bar{\mu}_1, \bar{\mu}_2, \Sigma_1, \Sigma_2$  を求める必要がある

14

## 境界線の問題(例題)[1]

$C_1$	$\Sigma_1 = \begin{bmatrix} 1 & 1 \\ 1 & 2 \end{bmatrix}$	$\bar{\mu}_1 = \begin{bmatrix} 2 \\ 4 \end{bmatrix}$
$C_2$	$\Sigma_2 = \begin{bmatrix} 1 & 1 \\ 1 & 2 \end{bmatrix}$	$\bar{\mu}_2 = \begin{bmatrix} 4 \\ 5 \end{bmatrix}$

$$P(C_1) = P(C_2)$$

このときの境界線の式を求めてみよう!

$$\left[ (\bar{x} - \bar{\mu}_2)^T \Sigma_2^{-1} (\bar{x} - \bar{\mu}_2) \right] - \left[ (\bar{x} - \bar{\mu}_1)^T \Sigma_1^{-1} (\bar{x} - \bar{\mu}_1) \right] = \ln|\Sigma_1| - \ln|\Sigma_2| + 2\ln P(C_2) - 2\ln P(C_1)$$

$$\therefore \left[ (\bar{x} - \bar{\mu}_1)^T \Sigma^{-1} (\bar{x} - \bar{\mu}_1) \right] = \left[ (\bar{x} - \bar{\mu}_2)^T \Sigma^{-1} (\bar{x} - \bar{\mu}_2) \right]$$

15

## 境界線の問題(例題)[2]

$$|\Sigma| = 1 \cdot 2 - 1 \cdot 1 = 1$$

$$\Sigma^{-1} = \begin{bmatrix} 1 & 1 \\ 1 & 2 \end{bmatrix}^{-1} = \begin{bmatrix} 2 & -1 \\ -1 & 1 \end{bmatrix}$$

$$\left[ (\bar{x} - \bar{\mu}_1)^T \Sigma^{-1} (\bar{x} - \bar{\mu}_1) \right] = [x_1 - 2 \quad x_2 - 4] \begin{bmatrix} 2 & -1 \\ -1 & 1 \end{bmatrix} \begin{bmatrix} x_1 - 2 \\ x_2 - 4 \end{bmatrix}$$

=

16