

## 第4章 ベイズ判別問題とパターン認識

4.4 ミニマックス決定

4.5 パターン認識と分類

4.6 ベイズ決定による判別（分類）

4.7 判別分析

05T4078Y 茂木哲矢

2008.10.03

# Outline

- ① 4.4 ミニマックス決定
- ② 4.5 パターン認識と分類
- ③ 4.6 ベイズ決定による判別（分類）
- ④ 4.7 判別分析
- ⑤ まとめ

## トレード・オフ

### 伝送の確率

- 「イエス」 → 「ノー」の誤りが起こりやすい
- $e(1|0)$  は減少すると、 $e(0|1)$  は増加する
- $e(0|1)$  は減少すると、 $e(1|0)$  は増加する
- $e(1|0)$  と  $e(0|1)$  はトレード・オフの関係

表 4.5: 伝送の確率

送信 → 受信	確率 (%)
「イエス」 → 「イエス」	93.970
「イエス」 → 「ノー」	6.030
「ノー」 → 「ノー」	97.220
「ノー」 → 「イエス」	2.780

## ミニマックス決定

- 誤りの確率の大きいほう  $Max\{e(0|1), e(1|0)\}$  を最小化する
- $e(0|1) = e(1|0)$  となるようにする
- 2つのくさび形が等しくなる決定境界で，判断の方式  $x \begin{matrix} \geq \\ \leq \end{matrix} 0.500$  のとき
- 計算の際に，事前確率，損失の情報がいらぬ

# パターン認識と例

## パターン認識

- パターンを概念に分類要約して，それに対応付けること
- 数理的問題としてはかなり難しい
- 普通の意味で感覚による認識は，すべてパターン認識

## パターン認識の例

- 光学的文字読取装置
- マークシートや郵便番号の読取装置
- スキャナー付属の文字読み取り機能

## パターン認識の難しさ

- 2次元, 3次元のパターンでは, どこから計算するか決めることが難しい
- コンピュータによる計算は, デジタル的なものには適しているが, アナログ的なものには適さない

→ 解を見つける方法の1つとして, 統計的決定論がある

### 特徴抽出

- パターンとは図形そのものではない
- パターンは様々な特徴を持つ（花の形では，花弁の大きさ，がく片の大きさ，etc.）
- そのものとわかるための主要な特徴を選出する

$$\Psi(\text{無限次元}) \rightarrow z(p \text{次元})$$

$\Psi$  はパターン， $z$  は特徴ベクトル

- 特徴抽出 = 次元を低下させる

### 判別・分類

特徴ベクトルから，カテゴリーのどれかに分類する数理的手続きのこと

$z$  が分からないとき  $\Pi$  に分類する問題

損失 0-1 型単純損失

事前分布  $w_k$  ( $k = 1, 2, \dots, K$ )

$\Pi_k$  に分類する事前期待損失

$$w_1 \cdot 1 + \dots + w_{k-1} \cdot 1 + w_k \cdot 0 + w_{k+1} \cdot 1 + \dots + w_K \cdot 1 \quad (4.6.3)$$

$\Pi_k$  に分類する条件

$$1 - w_k \leq 1 - w_l \quad (l = 1, 2, \dots, K) \quad (4.6.4)$$

$z$  が分かったとき  $\Pi$  に分類する問題

事後確率最大の  $\Pi$  へ分類する

$\Pi_k$  の事後確率

$$w'_k = \frac{w_k f_k(z)}{w_1 f_1(z) + \cdots + w_K f_K(z)} \quad (4.6.5)$$

$\Pi_k$  に分類する条件

$$w_k f_k(z) = \max\{w_1 f_1(z), \cdots, w_K f_K(z)\} \quad (4.6.6)$$

$\Pi_k$  に分類する条件 (尤度比の形)

$$\frac{f_1(z)}{f_k(z)} \leq \frac{w_k}{w_1}, \frac{f_2(z)}{f_k(z)} \leq \frac{w_k}{w_2}, \cdots, \frac{f_K(z)}{f_k(z)} \leq \frac{w_k}{w_K} \quad (4.6.7)$$

## 多次元正規分布 I

$\mathbf{z} = (x_1, x_2, \dots, x_p)'$  の分布  $f(\mathbf{z})$

平均

$$\mu_i = E(x_i) \quad (i = 1, 2, \dots, p) \quad (4.6.9)$$

共分散

$$\sigma_{ij} = E((x_i - \mu_i)(x_j - \mu_j)) \quad (i, j = 1, 2, \dots, p) \quad (4.6.10)$$

$p$  次元正規分布  $N_p(\boldsymbol{\theta}, \boldsymbol{\Sigma})$

$$f(\mathbf{z}|\boldsymbol{\theta}, \boldsymbol{\Sigma}) = (2\pi)^{-p/2} |\boldsymbol{\Sigma}|^{-1/2} \exp\left\{-\frac{1}{2}(\mathbf{z} - \boldsymbol{\theta})' \boldsymbol{\Sigma}^{-1}(\mathbf{z} - \boldsymbol{\theta})\right\},$$
$$\boldsymbol{\theta} = (\mu_1, \mu_2, \dots, \mu_p), \quad \boldsymbol{\Sigma} = \{\sigma_{ij}\}$$

(4.6.11)

## 多次元正規分布 II

$z = p$  次元ベクトルの場合の尤度比

$$\log \frac{f_z(z)}{f_k(z)} = (\boldsymbol{\theta}_l - \boldsymbol{\theta}_k)' \boldsymbol{\Sigma}^{-1} z - \frac{1}{2} (\boldsymbol{\theta}_l + \boldsymbol{\theta}_k)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\theta}_l - \boldsymbol{\theta}_k) \equiv F_{lk}(z)$$

$$F_{lk}(z) \leq \log \left( \frac{w_k}{w_l} \right) \quad (l = 1, 2, \dots, K) \quad (4.6.13)$$

- $z$  に対する  $F_{lk}$  の値で分類される
- $F_{lk}$  は  $z$  に対して線型なので線型判別関数とよばれる

$$F_{kl}(z) = -F_{lk}(z) \quad (4.6.14)$$

ベイズ判別領域

$$R_k = \left\{ z \mid F_{kl} \geq \log \left( \frac{w_l}{w_k} \right) \quad (l = 1, 2, \dots, K) \right\} \quad (4.6.15)$$

## 判別分析

- 多変量解析の方法の1つ
- 固有値問題に帰着する
- 次元を落とすことによって情報の圧縮ができる  
(= 特徴抽出に用いることができる)

## 判別分析の問題

群 (母集団, カテゴリー)  $K$  個      ケース (個体, サンプル) の数

群に対する変数  $x_i (i = 1, 2, \dots, p)$        $n_k (k = 1, 2, \dots, K)$

線型関数

$$L = l_1x_1 + l_2x_2 + \dots + l_px_p \quad (4.7.1)$$

$L$  の “差が付く” ように,  $l_1, l_2, \dots, l_p$  を選ぶ

## 分散・共分散行列

$x_j$  の平均

$$\bar{x}_j^{(s)} = \frac{\sum_i^{(s)} x_{ij}}{n_s}, \quad \bar{x}_j = \frac{\sum_i x_{ij}}{n} \quad (4.7.2)$$

変数間の情報をとらえるために，分散・共分散行列を用いる．

$$\begin{aligned} \text{群間} : b_{jl} &= \frac{\sum_{s=1}^K n_s (\bar{x}_j^{(s)} - \bar{x}_j)(\bar{x}_l^{(s)} - \bar{x}_l)}{n - 1} \\ \text{群内} : w_{jl} &= \frac{\sum_{s=1}^K \sum_i^{(s)} (x_{ij}^{(s)} - \bar{x}_j^{(s)})(x_{il}^{(s)} - \bar{x}_l^{(s)})}{n - 1} \end{aligned} \quad (4.7.4)$$

$$\text{全体} : t_{jl} = \frac{\sum_i (x_{ij} - \bar{x}_j)(x_{il} - \bar{x}_l)}{n - 1}$$

$$\mathbf{B} = \{b_{ij}\}, \quad \mathbf{W} = \{w_{ij}\}, \quad \mathbf{T} = \{t_{ij}\} \quad (4.7.5)$$

$$t_{jl} = b_{jl} + w_{jl}, \quad \mathbf{T} = \mathbf{B} + \mathbf{W} \quad (4.7.6)$$

# 判別スコア I

## 判別スコア

判別スコア  $L = l_1x_1 + l_2x_2 + \cdots + l_px_p$

判別スコアは，群間分散  $\gg$  群内分散のような値であることが望ましい

$l = \{l_1, l_2, \dots, l_p\}'$  とする

### 群間分散

$$l'Bl = \sum_i \sum_j b_{ij}l_i l_j \quad (4.7.8)$$

### 群内分散

$$l'Wl = \sum_i \sum_j w_{ij}l_i l_j \quad (4.7.9)$$

### レイリー商

$$Q \equiv \frac{l'Bl}{l'Wl} \Rightarrow \text{最大} \quad (4.7.10)$$

## 判別スコア II

固有値問題

群の間で“差が付く” $l$   
の選び方

$$= Bl = \lambda Wl \quad (4.7.11)$$

に帰着する

最大固有値

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \quad (4.7.12)$$

固有ベクトル $l^{(1)}$ の成分  $l_1^{(1)}, l_2^{(1)}, \dots, l_p^{(1)}$

判別スコア (判別関数)

$$L^{(1)} = l_1^{(1)}x_1 + l_2^{(1)}x_2 + \dots + l_p^{(1)}x_p \quad (4.7.13)$$

## まとめ

- 誤りがトレード・オフの関係にあるとき決定境界はミニマックス決定で決める
  - パターン認識の解を見つける方法には
    - ▶ ベイズ決定
    - ▶ 判別分析
- がある