

# カーネル多変量解析

## 第4.4章 外れ値新規性検出

茨城大学工学部情報工学科  
倉持辰洋

# 外れ値・新規性検出

- 非常に多いデータから意味のある重要な情報を抽出したい

例)・監視システムで通常と性質の異なるデータ

・数多くのニュースから新規性の高い情報を抽出

- この章では二つの方法を紹介する

1クラスv-サポートベクトルマシン

⇒超平面で正常値と外れ値を分離

サポートベクトル領域記述法

⇒球面で正常値と外れ値を分離

# 1クラス $v$ -サポートベクトルマシン(1)

- $v$ トリックを使った外れ値検出
- 特徴ベクトル  $\omega$  とパラメータ  $\Phi$  の内積からなる関数

$$f(\mathbf{x}) = \mathbf{w}^T \Phi(\mathbf{x})$$

を考える

- サンプルは  $f(\mathbf{x}^{(1)}), \dots, f(\mathbf{x}^{(n)})$  のように1次元のデータとなる

# 1クラス $\nu$ -サポートベクトルマシン(2)


- しきい値  $\rho (> 0)$  でデータを二つに分ける

$\rho \leq f(x^{(i)})$  となるデータ

⇒ 正常値

$\rho > f(x^{(i)})$  となるデータ

⇒ 外れ値



# しきい値 $\rho(1)$

- $\rho$ の値を決めたい

正常値のクラスは多くのデータを含むはず

⇒  $\rho$ の値は小さいほうがいい

クラスタはできるだけまとまってほしい

⇒  $\rho$ の値は大きいほうがいい

- 4. 3章の関数(4. 42)を使い損失関数

$$r_{\rho}(f(\mathbf{x})) = \max\{0, \rho - f(\mathbf{x})\}$$

を作り、外れ値で正の値をとるようにする。

# しきい値 $\rho(2)$

- 二次の正則化を行う

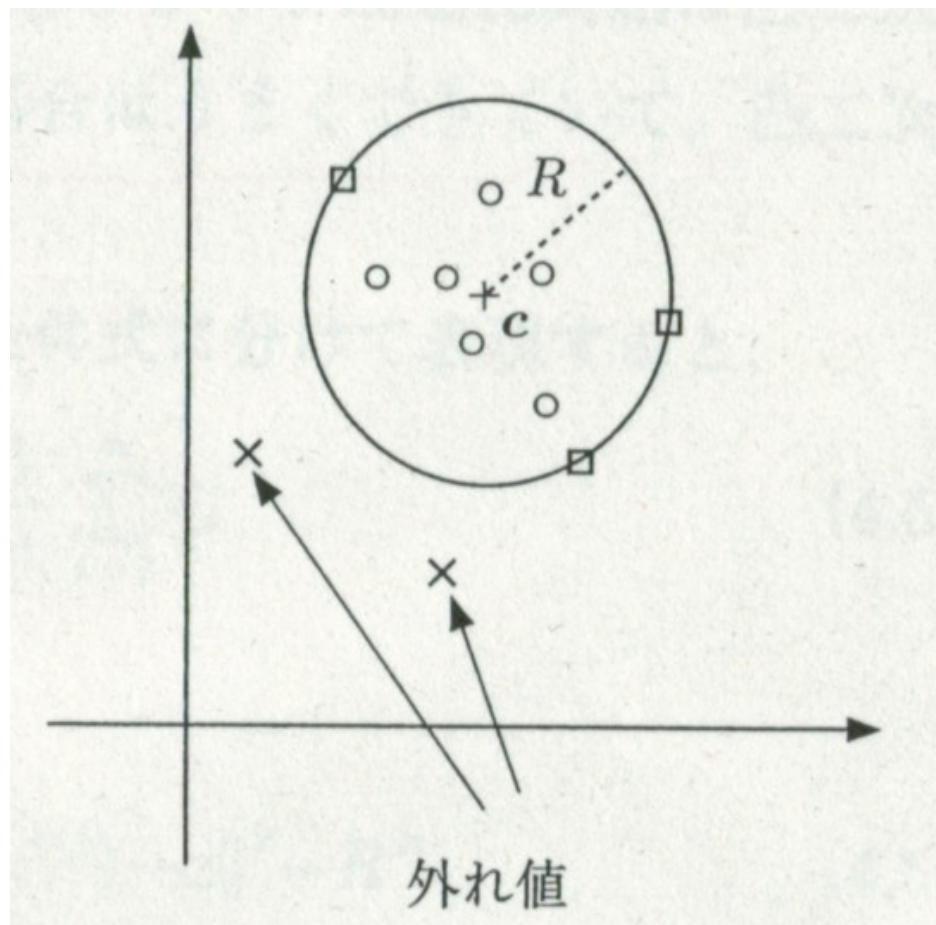
$$\min_{\rho > 0} \frac{1}{n} \sum_{i=1}^n r_{\rho}(f(\mathbf{x}^{(i)})) + \frac{1}{2} \boldsymbol{\alpha}^T K \boldsymbol{\alpha} - \nu \rho$$

- この式はが入っていない-サポートベクトルマシンと同じものとなっている。

⇒ 正常値であるサンプルを一つのクラスとして扱う1クラス問題として解ける

# サポートベクトル領域記述法(1)

- 特徴空間において  
中心： $c$   
半径： $R$   
というパラメータをとる
- 中心からの二乗距離が  
球からはみ出す場合  
損失とする。



# サポートベクトル領域記述法(2)

- 球からはみだす、つまり  $R^2$  以上のときを損失として加えてやるので

$$\min_{R^2, \mathbf{c}} \frac{1}{n} \sum_{i=1}^n r_{R^2}(\|\Phi(\mathbf{x}^{(i)}) - \mathbf{c}\|^2) + \nu R^2$$

となり、損失関数は

$$r_{R^2}(z) = \max\{0, z - R^2\}$$

となる

# サポートベクトル領域記述法(3)

- 正則化項  $\nu R^2 \Rightarrow$  半径が大きくなるのを抑止
- $r_{R^2} \Rightarrow$  区分的な二つの制約式に分けれる

↓けれど

- 制約式にパラメータ $c$ の2次式が入っている
  - $\Rightarrow$  一般に、制約が2次関数である最適問題は凸二次計画問題になるとは限らない
- 今回の場合は凸二次計画問題となる

# 凸二次計画問題へ(1)

- 損失関数を二つの条件式に分けて表現

最小化問題:

$$\min_{R^2, \xi, c} \nu R^2 + \frac{1}{n} \sum_{i=1}^n \xi_i$$

制約条件:  $\xi_i \geq 0$ ,  $\xi_i \geq \|\Phi(\mathbf{x}^{(i)}) - \mathbf{c}\|^2 - R^2$

これらと等価になる

# 凸二次計画問題へ(2)

- 先の最小化問題より

ラグランジュ関数:

$$L(R^2, \xi, c, \beta, \gamma) = vR^2 + \frac{1}{n} \sum_{i=1}^n \xi_i - \sum_{i=1}^n \beta_i \xi_i - \sum_{i=1}^n \gamma_i (\xi_i - \|\Phi(\mathbf{x}^{(i)}) - \mathbf{c}\|^2 + R^2)$$

- 1次式のみ  $R^2, \xi_i$  について係数を0とおくと

$$v = \sum_{i=1}^n \gamma_i, \quad \frac{1}{n} - \beta_i = \gamma_i$$

- $\mathbf{c}$  について微分し0とおくと

$$\mathbf{c} = \frac{1}{\sum_{i=1}^n \gamma_i} \sum_{i=1}^n \gamma_i \Phi(\mathbf{x}^{(i)}) = \frac{1}{v} \sum_{i=1}^n \gamma_i \Phi(\mathbf{x}^{(i)})$$

# 凸二次計画問題へ(3)

- $v = \sum_{i=1}^n \gamma_i$  をLに代入することで双対問題の目的関数が得られる

$$\begin{aligned} L_{dual}(\boldsymbol{\gamma}) &= \sum_{i=1}^n \gamma_i \left\| \boldsymbol{\Phi}(\mathbf{x}^{(i)}) - \frac{1}{v} \sum_{j=1}^n \gamma_j \boldsymbol{\Phi}(\mathbf{x}^{(j)}) \right\|^2 \\ &= \sum_{i=1}^n \gamma_i \left\{ K_{ii} - \frac{2}{v} \sum_{j=1}^n \gamma_j K_{ij} + \frac{1}{v^2} \sum_{j,j'} \gamma_j \gamma_{j'} K_{jj'} \right\} \\ &= \sum_{i=1}^n \gamma_i K_{ii} - \frac{1}{v} \sum_{i=1}^n \sum_{j=1}^n \gamma_i \gamma_j K_{ij} \end{aligned}$$

- 凸二次計画問題となった

# 凸二次計画問題へ(4)

- 制約式:  $0 \leq \gamma_i \leq \frac{1}{n}, \quad \sum_{i=1}^n \gamma_i = v$

# パラメータRを求める

- 相補性条件より

$\gamma_i, \beta_i$  が0でない場合

$$\xi_i = 0, \xi_i - \|\Phi(\mathbf{x}^{(i)}) - \mathbf{c}\|^2 + r^2 = 0$$

- これより以下の式で求めることができる

$$R^2 = \|\Phi(\mathbf{x}^{(i)}) - \mathbf{c}\|^2$$