

# scikit-Learn

## 1.2.2. Regression

永田 純平

# Support Vector Regression(SVR)

- SVMの回帰問題に拡張したもの(SVR, NuSVR)
- 汎化誤差の上限を最小化するように学習を行うため、高い汎化能力をもつ。
- カーネルを適用することで非線形関数近似に拡張することができる。

# 回帰に対する損失関数

- 二乗誤差損失関数


$$\frac{1}{2} \sum_{n=1}^N \{f(x_n) - y_n\}^2 + \frac{1}{2} \|w\|^2$$

- $\varepsilon$ 許容誤差関数を用いた損失関数

$$C \sum_{n=1}^N E_{\varepsilon}(f(x_n) - y_n) + \frac{1}{2} \|w\|^2$$

## ※ $\epsilon$ 許容誤差関数

$$E_{\epsilon}(f(x_n) - y_n) = \begin{cases} 0 & |f(x) - y| < \epsilon \\ |f(x) - y| - \epsilon & (\textit{otherwise}) \end{cases}$$



# スラック変数の導入

$$f(x_n) - \varepsilon \leq y_n \leq f(x_n) + \varepsilon \text{より}$$

$$\begin{cases} \xi_n \geq 0, \hat{\xi}_n \geq 0 \\ y_n - f(x_n) - \varepsilon \leq \xi_n \\ f(x_n) - y_n - \varepsilon \leq \hat{\xi}_n \end{cases}$$

※実測値と予測値の誤差が $\varepsilon$ より大きいと損失として値をとる。

$$\xi_n = \begin{cases} 0 & y_n \leq f(x_n) + \varepsilon \\ \xi_n & y_n > f(x_n) + \varepsilon \end{cases}, \hat{\xi}_n = \begin{cases} 0 & y_n \leq f(x_n) - \varepsilon \\ \hat{\xi}_n & y_n > f(x_n) - \varepsilon \end{cases}$$

$$C \sum_{n=1}^N (\xi_n + \hat{\xi}_n) + \frac{1}{2} \|w\|^2$$

$$L = C \sum_{n=1}^N (\xi_n + \hat{\xi}_n) + \frac{1}{2} \|w\|^2 - \sum_{n=1}^N (\mu_n \xi_n + \hat{\mu}_n \hat{\xi}_n) - \sum_{n=1}^N a_n (\varepsilon + \xi_n + f(x_n) - y_n) - \sum_{n=1}^N \hat{a}_n (\varepsilon + \hat{\xi}_n + y_n - f(x_n))$$

※ $\mu_n, \hat{\mu}_n, a_n, \hat{a}_n$ はそれぞれの制約条件に対応するラグランジュ乗数

$f(x) = w \cdot x - b$ を代入し、 $w, b, \xi_n, \hat{\xi}_n$ をそれぞれ微分する

$$\frac{\partial L}{\partial w} = w - \sum_{n=1}^N (a_n - \hat{a}_n)x_n = 0 \rightarrow w = \sum_{n=1}^N (a_n - \hat{a}_n)x_n$$

$$\frac{\partial L}{\partial b} = \sum_{n=1}^N (a_n - \hat{a}_n) = 0,$$

$$\frac{\partial L}{\partial \xi_n} = C - a_n - \mu_n = 0 \rightarrow a_n + \mu_n = C$$

$$\frac{\partial L}{\partial \hat{\mu}_n} = C - \hat{a}_n - \hat{\mu}_n = 0 \rightarrow \hat{a}_n + \hat{\mu}_n = C$$

$$L(a_n, \hat{a}_n) = -\frac{1}{2} \sum_{n,m=1}^N (a_n - \hat{a}_n)(a_m - \hat{a}_m)(x_n \cdot x_m) \\ - \varepsilon \sum_{n=1}^N (a_n + \hat{a}_n) + \sum_{n=1}^N (a_n + \hat{a}_n)y_n$$

## 回帰モデル

$$f(x) = \sum_{n=1}^N (a_n - \hat{a}_n) (x \cdot x_n) - b$$

Support Vector Regression

