


SVM: Mathematics Behind Large Margin Classification

$$\min_{\theta} \frac{1}{2} \sum_{j=1}^n \theta_j^2$$

s.t. $\|\theta\| \cdot p^{(i)} \geq 1$ if $y^{(i)} = 1$
 such that $\|\theta\| \cdot p^{(i)} \leq -1$ if $y^{(i)} = 0$

$p^{(i)}$ は (符号を正の) $x^{(i)}$ から θ への射影 (projection)



$$\theta = (\theta_1, 0)$$

$$2 \cdot \theta_1 + 1 \cdot 0 \geq 1 \quad \therefore \theta_1 \geq \frac{1}{2}$$

$$-2 \cdot \theta_1 + 1 \cdot 0 \leq -1 \quad \therefore \theta_1 \geq \frac{1}{2}$$

$\|\theta\|$ を最小化したいから

$$\theta = \left(\frac{1}{2}, 0\right)$$

$$\|\theta\| = \frac{1}{2}$$

この方向の vector の長さを最小に求めたい。
(条件を満たすこと)

SVM : Kernels

Non-linear Decision Boundary

$$\text{predict } z=1 \text{ if } \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1 x_2 + \theta_4 x_1^2 + \theta_5 x_2^2 + \dots \geq 0$$

kernel ... Given x , landmark $l^{(1)}, l^{(2)}, l^{(3)}$ 2次元以上の新しく feature を計算せよ.

$$f_1 = \underbrace{\text{similarity}(x, l^{(1)})}_{\uparrow \text{kernel}} = \exp\left(-\frac{\|x - l^{(1)}\|^2}{2\sigma^2}\right)$$

$\sum_{j=1}^n (x_j - l_j^{(1)})^2$

$$f_2 = \quad \quad \quad (2) \quad \quad \quad (2) \quad \quad \quad \uparrow \text{Gaussian kernel}$$
$$f_3 = \quad \quad \quad (3) \quad \quad \quad (3)$$

$$\text{if } x \approx l^{(1)} \quad f_1 \approx \exp\left(-\frac{0^2}{2\sigma^2}\right) \approx 1$$

if x が $l^{(1)}$ から遠ければ

$$f_1 = \exp\left(-\frac{\text{大定数}^2}{2\sigma^2}\right) \approx 0$$

SVM: Kernels I の Quiz

x_1 は1次元の feature

$$l^{(1)} = 5$$


$$f_1 = \exp\left(-\frac{\|x_1 - l^{(1)}\|^2}{2\sigma^2}\right)$$

$\sigma^2 = 1$ の時のグラフ



$$f = e^{-\frac{x}{2}}$$

$\sigma^2 = 4$ のときのグラフ



$$f = e^{-\frac{x}{8}}$$

SVM: kernels II

Given x , $f_i = \text{similarity}(x, l^{(i)}) = \exp\left(-\frac{\|x - l^{(i)}\|^2}{2\sigma^2}\right)$

Predict $y=1$, if $\theta_0 + \theta_1 f_1 + \theta_2 f_2 + \theta_3 f_3 \geq 0$

$l^{(1)}, l^{(2)}, l^{(3)}, \dots$ をどうやって見つければよいか?

SVM with kernels

$(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})$ が与えられた時

$l^{(1)} = x^{(1)}, l^{(2)} = x^{(2)}, \dots, l^{(m)} = x^{(m)}$ とする。

example x が与えられたと

$$\begin{matrix} f_1 = \text{similarity}(x, l^{(1)}) \\ f_2 = \text{similarity}(x, l^{(2)}) \\ \vdots \end{matrix} \rightarrow \text{まとめ? } f = \begin{pmatrix} f_0 \\ f_1 \\ f_2 \\ \vdots \end{pmatrix}, \text{ ただし } f_0 = 1$$

training example $(x^{(i)}, y^{(i)})$ に対して

$$\begin{matrix} f_1^{(i)} = \text{sim}(x^{(i)}, l^{(1)}) \\ f_2^{(i)} = \text{sim}(x^{(i)}, l^{(2)}) \\ \vdots \\ f_i^{(i)} = \text{sim}(x^{(i)}, l^{(i)}) = 1 \quad \text{同じなので} \\ \vdots \\ f_m^{(i)} = \text{sim}(x^{(i)}, l^{(m)}) \end{matrix}$$

\rightarrow まとめ? $f^{(i)} = \begin{pmatrix} f_0^{(i)} \\ f_1^{(i)} \\ f_2^{(i)} \\ \vdots \\ f_m^{(i)} \end{pmatrix}$ ← 1 を除いて記述する場合がある。

与えられた x に対して、この f を計算する。 if $\theta^T f \geq 0$, predict $y=1$

Training (学習)

$$\min_{\theta} C \sum_{i=1}^m y^{(i)} \text{cost}_1(\theta^T f^{(i)}) + (1-y^{(i)}) \text{cost}_0(\theta^T f^{(i)}) + \frac{1}{2} \sum_{j=1}^n \theta_j^2$$

\nwarrow $x^{(i)}$ の代わりに $f^{(i)}$ を使うのがポイント
 \nearrow θ_0 は入っていない
 $n=m$ だぞうた

SVM のパラメータ

$C (= \frac{1}{\lambda})$ $C \rightarrow$ 大 ($\lambda \rightarrow$ 小) $\text{bias} \rightarrow$ 小 $\text{variance} \rightarrow$ 大
 ($\because \theta_0$ 以外の $\theta_1 \sim \theta_n$ を小さくしようという影響が減るから)

$C \rightarrow$ 小 ($\lambda \rightarrow$ 大) $\text{bias} \rightarrow$ 大 $\text{variance} \rightarrow$ 小
 ($\because \theta_0$ 以外の $\theta_1 \sim \theta_n$ を小さくしようとする影響が大きくなるから)

α^2 $\alpha^2 \rightarrow$ 大 features f_i から離れていても正の値 ($0 \cdot \theta$) をとる。
 overfitting ぎみにはなるぞい。 \nearrow 中々りと影響が減っていく。
 $\text{bias} \rightarrow$ 大 $\text{variance} \rightarrow$ 小

$\alpha^2 \rightarrow$ 小 上の逆で $\text{bias} \rightarrow$ 小 $\text{variance} \rightarrow$ 大

[講義中の Quiz]

SVM で学習させたが overfit になった。どうすればよい

- ① C を増やす ($\lambda \rightarrow$ 小) $\text{variance} \rightarrow$ 大 \rightarrow overfit になる \times
- ② C を減らす ($\lambda \rightarrow$ 大) θ_0 が相対的に大 $\therefore \text{bias}$ 大 underfit \circ
- ③ α^2 を増やす。 f_i から離れる影響が中々りと underfit \circ
- ④ α^2 を減らす。 f_i から離れる影響が急激に \rightarrow overfit \times

SVMs in Practice

パラメータ C を選ぶ

kernel (similarity function) を選ぶ

(例) カーネルなし (linear kernel)

$$z = 1, \text{ if } \theta^T x \geq 0$$

$$\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n \geq 0$$

n 大 m 小 のとき $x \in \mathbb{R}^{n+1}$

(例2) Gaussian kernel

$$f_i = \exp\left(-\frac{\|x - l^{(i)}\|^2}{2\alpha^2}\right), \text{ where } l^{(i)} = x^{(i)}$$

α^2 を選ぶ必要あり n 小 m 大 の時

Gaussian kernel を用いる前には feature scaling を行うこと

全ての similarity function が valid な kernel とは限りません。
[SVM パッケージの最適化が正しく動作して、発散しない]

↓
Mercer's Theorem
を満たす必要はある

たくさんのおff-the-shelf kernel が利用可能である

$$\text{polinomial kernel} \quad (x^T l + \text{定数})^{\text{次数}}$$

[講義中の Quiz]

C, α^2 のような kernel のパラメータを選ぶ時、どうやって選ぶか？

① training data による結果を出すもの

② cross validation data

← ① α^2 は cross validation data
で決定する。

③ test data

④ SVM margin が最大のもの

SVMs in Practice

Multi-class classification

Multi-class classification 機能を持っている SVM パッケージも多い。

一方, one-vs-all 手法を用いることもある。

Logistic regression vs. SVMs

featureの数 n と サンプルの数 m を比較して

$n \rightarrow$ 大, logistic regression
 $n=10,000$ kernel なしの (linear kernel の) SVM } を使うべき
 $m=10 \sim 1000$

$n \rightarrow$ 小, $m \rightarrow$ 中, Gaussian kernel の SVM を使うべき
 $n=1 \sim 1000, m=10 \sim 10,000$

$n \rightarrow$ 小, $m \rightarrow$ 大 ほとんどの feature を追加して
 $n=1 \sim 1000$ $m=50,000$ 以上 logistic regression
kernel なしの (linear kernel の) SVM } を使うべき

上記の全ての場合で neural network はうまく動作するか、学習に時間がかかるとはもしかたない。