

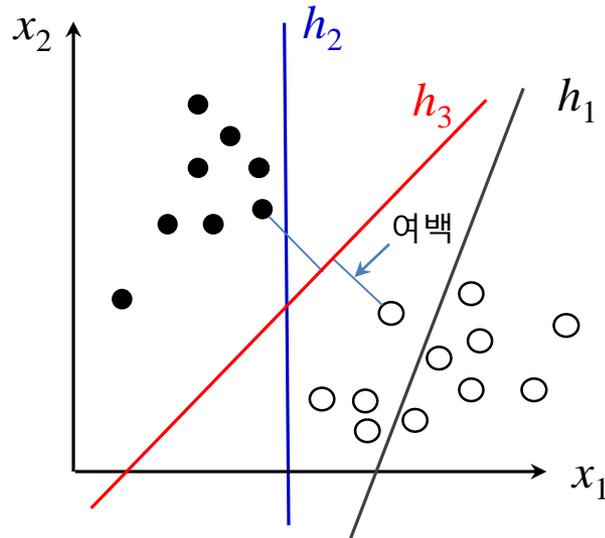
기계 학습

Part IV. 서포트 벡터 머신(SVM)

10.1 SVM

❖ Support Vector Machine (SVM)

- Vladimir Vapnik이 제안
- 분류 오차를 줄이면서 동시에 **여백을 최대**로 하는 **결정 경계(decision boundary)**를 찾는 **이진 분류기(binary classifier)**



h₃가 h₂보다 우수

- **여백(margin)**
 - 결정 경계와 가장 가까이에 있는 학습 데이터까지의 거리
- **서포트 벡터(support vector)**
 - 결정 경계로부터 가장 가까이에 있는 학습 데이터들

SVM

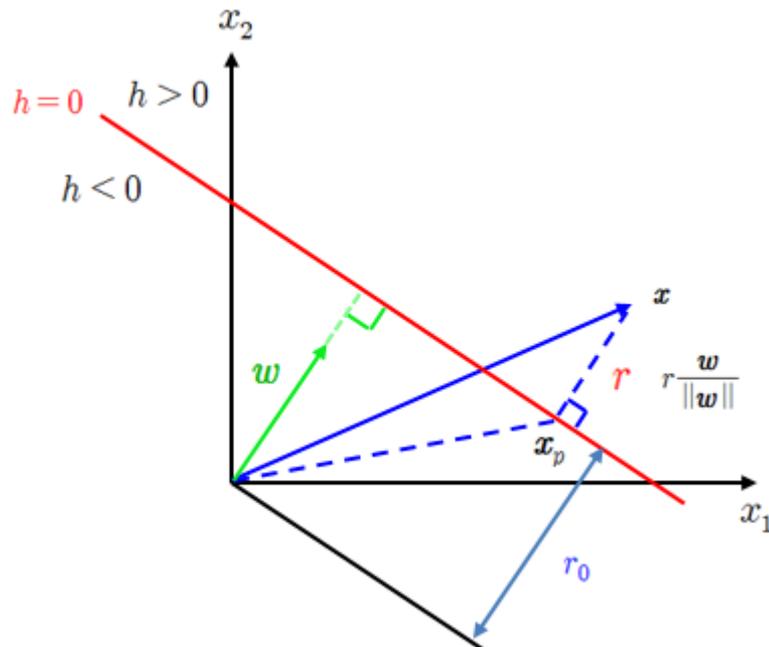
❖ 초평면 기하학

▪ 초평면(hyperplane)

- 4차원이상의 공간에서 선형 방정식으로 표현되는 결정 경계

입력 데이터 $\mathbf{x} = [x_1 \ x_2 \ \cdots \ x_d]^\top$

$$h(\mathbf{x}) = w_1x_1 + w_2x_2 + \cdots + w_dx_d + b = \mathbf{w}^\top \mathbf{x} + b = 0$$



$$\mathbf{x} = \mathbf{x}_p + r \frac{\mathbf{w}}{\|\mathbf{w}\|}$$

$$\mathbf{w}^\top \mathbf{x} = \mathbf{w}^\top \mathbf{x}_p + r \frac{\mathbf{w}^\top \mathbf{w}}{\|\mathbf{w}\|}$$

$$\mathbf{w}^\top \mathbf{x} = \mathbf{w}^\top \mathbf{x}_p + r \|\mathbf{w}\|$$

$$\mathbf{w}^\top \mathbf{x} + b = \mathbf{w}^\top \mathbf{x}_p + b + r \|\mathbf{w}\|$$

$$h(\mathbf{x}) = r \|\mathbf{w}\| \quad r = \frac{h(\mathbf{x})}{\|\mathbf{w}\|}$$

$$r_0 = \frac{h(\mathbf{0})}{\|\mathbf{w}\|} = \frac{b}{\|\mathbf{w}\|}$$

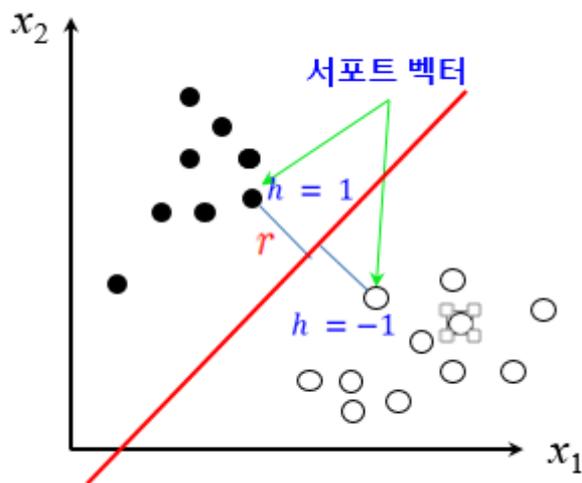
10.2 SVM의 학습

❖ SVM의 학습 목표

- 학습데이터 $X = \{(x_1, t_1), (x_2, t_2), \dots, (x_N, t_N)\}$ $t_i \in \{1, -1\}$, $i = 1, \dots, N$
- 분류를 위한 **초평면의 만족조건**

❶ $t_i h(x_i) \geq 1$, $i = 1, \dots, N$

❷ 서포트 벡터와의 거리, 즉 여백을 최대로 한다.



조건 ❶ 서포트 벡터 x' 에서의 $|h(x')| = 1$

$h(x) > 0$ 인 공간에 $t_i = 1$

$h(x) < 0$ 인 공간에 $t_i = -1$

조건 ❷ $r = \frac{h(x)}{\|w\|}$ 서포트 벡터에 대해서는 $h(x) = 1$

$$r = \frac{1}{\|w\|}$$

Find w, b which minimizes $J(w) = \frac{1}{2} \|w\|^2$

subject to $t_i h(x_i) \geq 1$, $i = 1, \dots, N$

$$h(x) = w^T x + b = 0$$

10.3 SVM의 최적화 문제

❖ 제약조건 최적화

Find \mathbf{x} which minimizes $f(\mathbf{x})$
subject to $g(\mathbf{x}) = 0$
 $h(\mathbf{x}) \leq 0$

▪ 라그랑주 함수

$$L(\mathbf{x}, \alpha, \lambda) = f(\mathbf{x}) + \lambda g(\mathbf{x}) + \alpha h(\mathbf{x})$$

$$(\alpha \geq 0)$$

Find \mathbf{w}, b which minimizes $J(\mathbf{w}) = \frac{1}{2}\|\mathbf{w}\|^2$
subject to $t_i h(\mathbf{x}_i) \geq 1, \quad i = 1, \dots, N$



Find \mathbf{w}, b which minimizes $J(\mathbf{w}) = \frac{1}{2}\|\mathbf{w}\|^2$
subject to $1 - t_i h(\mathbf{x}_i) \leq 0, \quad i = 1, \dots, N$

▪ 라그랑주 함수

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2}\|\mathbf{w}\|^2 + \sum_{i=1}^N \alpha_i (1 - t_i (\mathbf{w}^\top \mathbf{x}_i + b))$$

$$\alpha_i \geq 0$$

SVM의 최적화 문제

❖ SVM의 최적화 문제

$$\text{Find } \mathbf{w}, b \text{ which minimizes } J(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2$$
$$\text{subject to } 1 - t_i h(\mathbf{x}_i) \leq 0, \quad i = 1, \dots, N$$

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 + \sum_{i=1}^N \alpha_i (1 - t_i (\mathbf{w}^\top \mathbf{x}_i + b)) \quad \alpha_i \geq 0$$

▪ 해에 대한 KKT(Karush-Kuhn-Tucker) 조건

① $\alpha_i \geq 0, \quad i = 1, \dots, N$

② $1 - t_i h(\mathbf{x}_i) = 1 - t_i (\mathbf{w}^\top \mathbf{x}_i + b) \leq 0, \quad i = 1, \dots, N$

③ $\alpha_i (1 - t_i h(\mathbf{x}_i)) = 0, \quad i = 1, \dots, N$ 상보적 여유성(complementary slackness)

④ $\frac{\partial L}{\partial \mathbf{w}} = 0, \quad \frac{\partial L}{\partial b} = 0$

▪ 쌍대 함수(dual function)

$$\tilde{L}(\boldsymbol{\alpha}) = \min_{\mathbf{w}, b} L(\mathbf{w}, b, \boldsymbol{\alpha})$$

$$\frac{\partial \tilde{L}}{\partial \boldsymbol{\alpha}} = 0, \quad \frac{\partial \tilde{L}}{\partial \boldsymbol{\alpha}} = 0$$

SVM의 최적화 문제

❖ SVM의 최적화 문제

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 + \sum_{i=1}^N \alpha_i (1 - t_i (\mathbf{w}^\top \mathbf{x}_i + b)) \quad \alpha_i \geq 0$$

▪ 쌍대함수(dual function)

$$\tilde{L}(\boldsymbol{\alpha}) = \min_{\mathbf{w}, b} L(\mathbf{w}, b, \boldsymbol{\alpha})$$

$$\frac{\partial L}{\partial \mathbf{w}} = 0, \quad \frac{\partial L}{\partial b} = 0$$

▪ $L(\mathbf{w}, b, \boldsymbol{\alpha})$ 의 미분을 0으로 하면

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^N \alpha_i t_i \mathbf{x}_i = 0$$

$$\mathbf{w} = \sum_{i=1}^N \alpha_i t_i \mathbf{x}_i$$

$$\frac{\partial L}{\partial b} = - \sum_{i=1}^N \alpha_i t_i = 0$$

$$\sum_{i=1}^N \alpha_i t_i = 0$$

SVM의 최적화 문제

❖ SVM의 최적화 문제

$$\mathbf{w} = \sum_{i=1}^N \alpha_i t_i \mathbf{x}_i \quad \sum_{i=1}^N \alpha_i t_i = 0$$

▪ 초평면 함수식

$$h(\mathbf{x}) = \mathbf{w}^\top \mathbf{x} + b = \mathbf{w} \cdot \mathbf{x} + b = \sum_{i=1}^N \alpha_i t_i \mathbf{x}_i \cdot \mathbf{x} + b$$

▪ $L(\mathbf{w}, b, \boldsymbol{\alpha})$ 에 넣어 전개하면

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 + \sum_{i=1}^N \alpha_i (-t_i (\mathbf{w}^\top \mathbf{x}_i + b) + 1)$$

$$\begin{aligned} \tilde{L}(\boldsymbol{\alpha}) &= \frac{1}{2} \left(\sum_{i=1}^N \alpha_i t_i \mathbf{x}_i \right) \left(\sum_{j=1}^N \alpha_j t_j \mathbf{x}_j \right)^\top - \sum_{i=1}^N \alpha_i t_i \sum_{j=1}^N \alpha_j t_j \mathbf{x}_j \mathbf{x}_i^\top - b \sum_{i=1}^N \alpha_i t_i + \sum_{i=1}^N \alpha_i \\ &= -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \mathbf{x}_j^\top + \sum_{i=1}^N \alpha_i \\ &= -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \cdot \mathbf{x}_j + \sum_{i=1}^N \alpha_i \end{aligned}$$

SVM의 최적화 문제

❖ SVM의 최적화 문제

$$\text{Find } \mathbf{w}, b \text{ which minimizes } J(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2$$
$$\text{subject to } 1 - t_i h(\mathbf{x}_i) \leq 0, \quad i = 1, \dots, N$$

- 라그랑주 함수로 표현한 **본 문제**(primal problem)

$$\text{Find } \mathbf{w}, b \text{ which minimizes } L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 + \sum_{i=1}^N \alpha_i (1 - t_i (\mathbf{w}^\top \mathbf{x}_i + b))$$
$$\text{subject to } \alpha_i \geq 0, \quad i = 1, \dots, N$$



- w 와 b 가 없는 **쌍대 문제**(dual problem)

$$\text{Find } \boldsymbol{\alpha} \text{ which maximizes } \tilde{L}(\boldsymbol{\alpha}) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \cdot \mathbf{x}_j + \sum_{i=1}^N \alpha_i$$
$$\text{subject to } \sum_{i=1}^N \alpha_i t_i = 0, \quad i = 1, \dots, N$$
$$\alpha_i \geq 0, \quad i = 1, \dots, N$$

- **문제 복잡도**

- 데이터 개수 N 에 관계
- 데이터 차원과 무관

SVM의 최적화 문제

❖ SVM의 최적화 문제 해결

- 쌍대 문제(dual problem)의 **최소화 문제** 변환

Find α which **maximizes** $\tilde{L}(\alpha) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \cdot \mathbf{x}_j + \sum_{i=1}^N \alpha_i$

subject to $\sum_{i=1}^N \alpha_i t_i = 0, \quad i = 1, \dots, N$

$\alpha_i \geq 0, \quad i = 1, \dots, N$



Find α which **minimizes** $\tilde{L}(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \cdot \mathbf{x}_j - \sum_{i=1}^N \alpha_i$

subject to $\sum_{i=1}^N \alpha_i t_i = 0, \quad i = 1, \dots, N$

$\alpha_i \geq 0, \quad i = 1, \dots, N$

이차식 계획법(quadratic programming) 문제

SVM의 최적화 문제

❖ 이차식 계획법(quadratic programming)

Find α which **minimizes** $\tilde{L}(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \cdot \mathbf{x}_j - \sum_{i=1}^N \alpha_i$

subject to $\sum_{i=1}^N \alpha_i t_i = 0, \quad i = 1, \dots, N$

$\alpha_i \geq 0, \quad i = 1, \dots, N$

$$\tilde{L}(\alpha) = \frac{1}{2} [\alpha_1 \quad \alpha_2 \quad \dots \quad \alpha_N] \begin{bmatrix} t_1 t_1 \mathbf{x}_1 \cdot \mathbf{x}_1 & t_1 t_2 \mathbf{x}_1 \cdot \mathbf{x}_2 & \dots & t_1 t_N \mathbf{x}_1 \cdot \mathbf{x}_N \\ t_2 t_1 \mathbf{x}_2 \cdot \mathbf{x}_1 & t_2 t_2 \mathbf{x}_2 \cdot \mathbf{x}_2 & \dots & t_2 t_N \mathbf{x}_2 \cdot \mathbf{x}_N \\ \vdots & \vdots & \ddots & \vdots \\ t_N t_1 \mathbf{x}_N \cdot \mathbf{x}_1 & t_N t_2 \mathbf{x}_N \cdot \mathbf{x}_2 & \dots & t_N t_N \mathbf{x}_N \cdot \mathbf{x}_N \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_N \end{bmatrix} - \sum_{i=1}^N \alpha_i$$

$$= \frac{1}{2} \mathbf{x}^\top H \mathbf{x} - \sum_{i=1}^N \alpha_i$$

- 선형대수학의 **quadratic problem solver** 라이브러리 이용
 - MatLab/Octave의 **quadprog()**
 - Python의 **solvers.qp()**

SVM의 최적화 문제

❖ 이차식 계획법(quadratic programming) – cont.

- MatLab/Octave의 `quadprog()`
 - 이차식 계획법의 표준식(canonical form)

$$\text{Find } \boldsymbol{\alpha} \text{ which minimizes } L_D(\boldsymbol{\alpha}) = \frac{1}{2} \boldsymbol{\alpha}^\top H \boldsymbol{\alpha} + \mathbf{f}^\top \boldsymbol{\alpha}$$

$$\text{subject to } A\boldsymbol{\alpha} \leq \mathbf{a} \text{ and } B\boldsymbol{\alpha} = \mathbf{b}$$

- $\boldsymbol{\alpha} = \text{quadprog}(H, \mathbf{f}, \mathbf{A}, \mathbf{a}, \mathbf{B}, \mathbf{b})$

• SVM의 쌍대문제

$$\tilde{L}(\boldsymbol{\alpha}) = \frac{1}{2} [\alpha_1 \ \alpha_2 \ \cdots \ \alpha_N] \begin{bmatrix} t_1 t_1 \mathbf{x}_1 \cdot \mathbf{x}_1 & t_1 t_2 \mathbf{x}_1 \cdot \mathbf{x}_2 & \cdots & t_1 t_N \mathbf{x}_1 \cdot \mathbf{x}_N \\ t_2 t_1 \mathbf{x}_2 \cdot \mathbf{x}_1 & t_2 t_2 \mathbf{x}_2 \cdot \mathbf{x}_2 & \cdots & t_2 t_N \mathbf{x}_2 \cdot \mathbf{x}_N \\ \vdots & \vdots & \ddots & \vdots \\ t_N t_1 \mathbf{x}_N \cdot \mathbf{x}_1 & t_N t_2 \mathbf{x}_N \cdot \mathbf{x}_2 & \cdots & t_N t_N \mathbf{x}_N \cdot \mathbf{x}_N \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_N \end{bmatrix} - \sum_{i=1}^N \alpha_i$$

$$= \frac{1}{2} \boldsymbol{\alpha}^\top H \boldsymbol{\alpha} - \sum_{i=1}^N \alpha_i$$

$$\text{subject to } \sum_{i=1}^N \alpha_i t_i = 0, \quad i = 1, \dots, N$$

$$\alpha_i \geq 0, \quad i = 1, \dots, N \quad \Rightarrow \quad -\alpha_i \leq 0, \quad i = 1, \dots, N$$

SVM의 최적화 문제

❖ 이차식 계획법(quadratic programming) – cont.

- MatLab/Octave의 `quadprog()`

$$\text{Find } \boldsymbol{\alpha} \text{ which minimizes } L_D(\boldsymbol{\alpha}) = \frac{1}{2} \boldsymbol{\alpha}^\top H \boldsymbol{\alpha} - \sum_{i=1}^N \alpha_i$$

$$\text{subject to } -\alpha_i \leq 0 \text{ and } \sum_{i=1}^N \alpha_i t_i = 0, \quad i = 1, \dots, N$$

$$\text{Find } \boldsymbol{\alpha} \text{ which minimizes } L_D(\boldsymbol{\alpha}) = \frac{1}{2} \boldsymbol{\alpha}^\top H \boldsymbol{\alpha} + \mathbf{f}^\top \boldsymbol{\alpha}$$

$$\text{subject to } A\boldsymbol{\alpha} \leq \mathbf{a} \text{ and } B\boldsymbol{\alpha} = \mathbf{b}$$

- $\boldsymbol{\alpha} = \text{quadprog}(H, \mathbf{f}, \mathbf{A}, \mathbf{a}, \mathbf{B}, \mathbf{b})$

• SVM의 쌍대문제

$$H = \begin{bmatrix} t_1 t_1 \mathbf{x}_1 \cdot \mathbf{x}_1 & t_1 t_2 \mathbf{x}_1 \cdot \mathbf{x}_2 & \cdots & t_1 t_N \mathbf{x}_1 \cdot \mathbf{x}_N \\ t_2 t_1 \mathbf{x}_2 \cdot \mathbf{x}_1 & t_2 t_2 \mathbf{x}_2 \cdot \mathbf{x}_2 & \cdots & t_2 t_N \mathbf{x}_2 \cdot \mathbf{x}_N \\ \vdots & \vdots & \ddots & \vdots \\ t_N t_1 \mathbf{x}_N \cdot \mathbf{x}_1 & t_N t_2 \mathbf{x}_N \cdot \mathbf{x}_2 & \cdots & t_N t_N \mathbf{x}_N \cdot \mathbf{x}_N \end{bmatrix} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_N \end{bmatrix} \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_N \end{bmatrix}^\top \cdot * \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_N \end{bmatrix} \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \\ \vdots \\ \mathbf{x}_N \end{bmatrix}^\top$$

$$\mathbf{f} = \begin{bmatrix} -1 \\ -1 \\ \vdots \\ -1 \end{bmatrix} \quad A = \begin{bmatrix} -1 & 0 & \cdots & 0 \\ 0 & -1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & -1 \end{bmatrix} \quad \mathbf{a} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad B = [t_1 \ t_2 \ \cdots \ t_N] \quad \mathbf{b} = [0]$$

SVM의 학습 예

❖ MatLab/Octave의 사용한 예

- 부류 1 (+1) : (1,6), (1,8), (4,11)
- 부류 2 (-1) : (5,2), (7,6), (9,3)

▪ 입력데이터 X

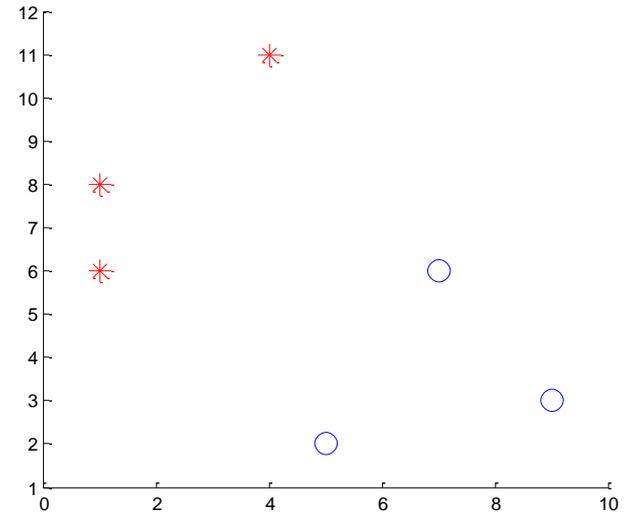
- $X = [1 \ 6; 1 \ 8; 4 \ 11; 5 \ 2; 7 \ 6; 9 \ 3]$

$$X = \begin{bmatrix} 1 & 6 \\ 1 & 8 \\ 4 & 11 \\ 5 & 2 \\ 7 & 6 \\ 9 & 3 \end{bmatrix}$$

▪ 출력 데이터 t

- $t = [1; 1; 1; -1; -1; -1]$

$$t = \begin{bmatrix} 1 \\ 1 \\ 1 \\ -1 \\ -1 \\ -1 \end{bmatrix}$$



▪ 행렬 H

$$H = (X \cdot X') . * (t \cdot t')$$

$$H = \begin{bmatrix} 37 & 49 & 70 & -17 & -43 & -27 \\ 49 & 65 & 92 & -21 & -55 & -33 \\ 70 & 92 & 137 & -42 & -94 & -69 \\ -17 & -21 & -42 & 29 & 47 & 51 \\ -43 & -55 & -94 & 47 & 85 & 81 \\ -27 & -33 & -69 & 51 & 81 & 90 \end{bmatrix}$$

SVM의 학습 예

❖ MatLab/Octave의 사용한 예 - cont.

- $f = \text{-ones}(6,1)$
- $A = \text{-eye}(6)$
- $a = \text{zeros}(6,1)$
- $B = t'$
- $b = [0]$

$$f = \begin{bmatrix} -1 \\ -1 \\ -1 \\ -1 \\ -1 \\ -1 \end{bmatrix}$$

$$A = \begin{bmatrix} -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 \end{bmatrix}$$

$$a = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

$$B = [1 \ 1 \ 1 \ -1 \ -1 \ -1]$$

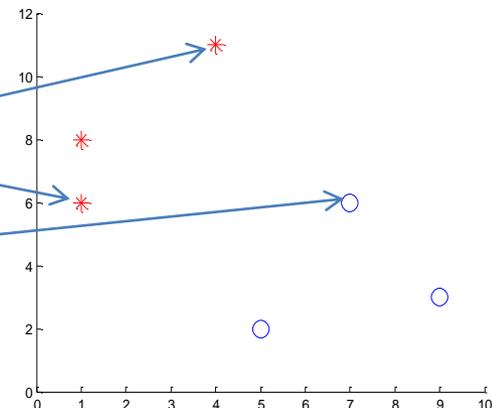
▪ 이차식 계획법 사용

- $\alpha = \text{quadprog}(H + \text{eye}(6) * 0.001, f, A, a, B, b)$

$$X = \begin{bmatrix} 1 & 6 \\ 1 & 8 \\ 4 & 11 \\ 5 & 2 \\ 7 & 6 \\ 9 & 3 \end{bmatrix}$$

$$\alpha = \begin{bmatrix} 0.0356 \\ 0.0000 \\ 0.0400 \\ 0.0000 \\ 0.0756 \\ 0.0000 \end{bmatrix}$$

서포트 벡터



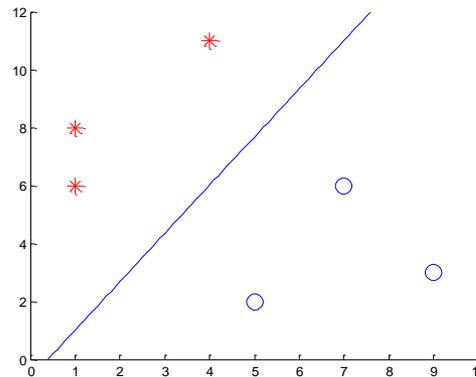
SVM의 학습 예

❖ SVM의 최적화 문제 해결

- 선형대수학의 **quadratic problem solver** 라이브러리를 이용
 - 최적화 문제의 해인 $\alpha_1, \alpha_2, \dots, \alpha_N$ 계산
- KKT 조건의 $\alpha_i(1 - h(\mathbf{x}_i)) = 0$ 때문에, $\alpha_i \neq 0$ 이라면 $h(\mathbf{x}_i) = 1$
- $\alpha_i \neq 0$ 인 \mathbf{x}_i 가 서포트 벡터
- \mathbf{w} 의 계산

$$\mathbf{w} = \sum_{i=1}^N \alpha_i t_i \mathbf{x}_i = \begin{bmatrix} -0.333 \\ 0.200 \end{bmatrix}$$

$$X = \begin{bmatrix} 1 & 6 \\ 1 & 8 \\ 4 & 11 \\ 5 & 2 \\ 7 & 6 \\ 9 & 3 \end{bmatrix} \quad \alpha = \begin{bmatrix} 0.0356 \\ 0.0000 \\ 0.0400 \\ 0.0000 \\ 0.0756 \\ 0.0000 \end{bmatrix}$$



$$h(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b$$

$$= \sum_{i=1}^N \alpha_i t_i \mathbf{x}_i \cdot \mathbf{x} + b$$

$$h(x_1, x_2) = -0.333x_1 + 0.2x_2 + 0.13$$

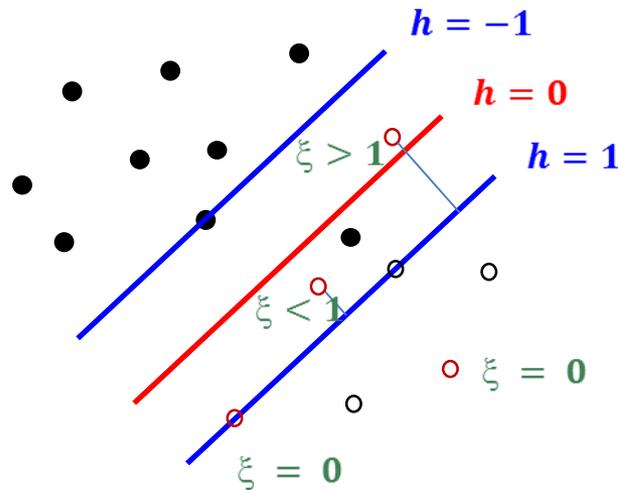
▪ b 의 계산

- 서포트 벡터 하나를 $t_i(\mathbf{w}^\top \mathbf{x}_i - b) = 1$ 에 넣어 계산

$$\begin{bmatrix} -0.333 \\ 0.200 \end{bmatrix}^\top \begin{bmatrix} 1 \\ 6 \end{bmatrix} - b = 1 \quad b = 0.13$$

10.4 선형 분리불가 문제의 SVM

❖ 선형 분리불가 문제의 SVM



- 슬랙변수(slack variable) ξ_i
 - 학습 데이터별로 하나씩 생성
 - SVM의 분할 초평면에서 서포트벡터보다 멀리 위치하면, $\xi_i = 0$
 - 이외의 경우, $\xi_i = |t_i - h(\mathbf{x}_i)|$

$$t_i h(\mathbf{x}_i) \geq 1 - \xi_i, \quad i = 1, \dots, N$$

선형 분리불가 문제의 SVM

❖ 선형분리가 되지 않는 데이터에 대한 SVM

▪ 최적화 문제

- 슬랙 변수를 허용하는 제약조건

$$t_i h(\mathbf{x}_i) \geq 1 - \xi_i, \quad i = 1, \dots, N$$

- 슬랙 변수 값의 합을 최소화

$$\text{Find } \mathbf{w}, b \text{ which minimizes } J(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i$$

$$\text{subject to } t_i h(\mathbf{x}_i) \geq 1 - \xi_i, \quad i = 1, \dots, N$$

$$\xi_i \geq 0, \quad i = 1, \dots, N$$

$$C > 0$$

- 라그랑주 함수

$$L(\mathbf{w}, b, \xi, \alpha, \beta) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i + \sum_{i=1}^N \alpha_i (1 - t_i h(\mathbf{x}_i) - \xi_i) - \sum_{i=1}^N \beta_i \xi_i$$

선형 분리불가 문제의 SVM

❖ 선형분리가 되지 않는 데이터에 대한 SVM

▪ 최적화 문제 - cont.

• 라그랑주 함수

$$L(\mathbf{w}, b, \xi, \alpha, \beta) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i + \sum_{i=1}^N \alpha_i (1 - t_i h(\mathbf{x}_i) - \xi_i) - \sum_{i=1}^N \beta_i \xi_i$$

• 쌍대 문제(dual problem)

$$\tilde{L}(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \cdot \mathbf{x}_j$$

$$\sum_{i=1}^N \alpha_i t_i = 0$$

$$0 \leq \alpha_i \leq C \longleftarrow \text{상한(upper bound)에 대한 제약조건 추가}$$

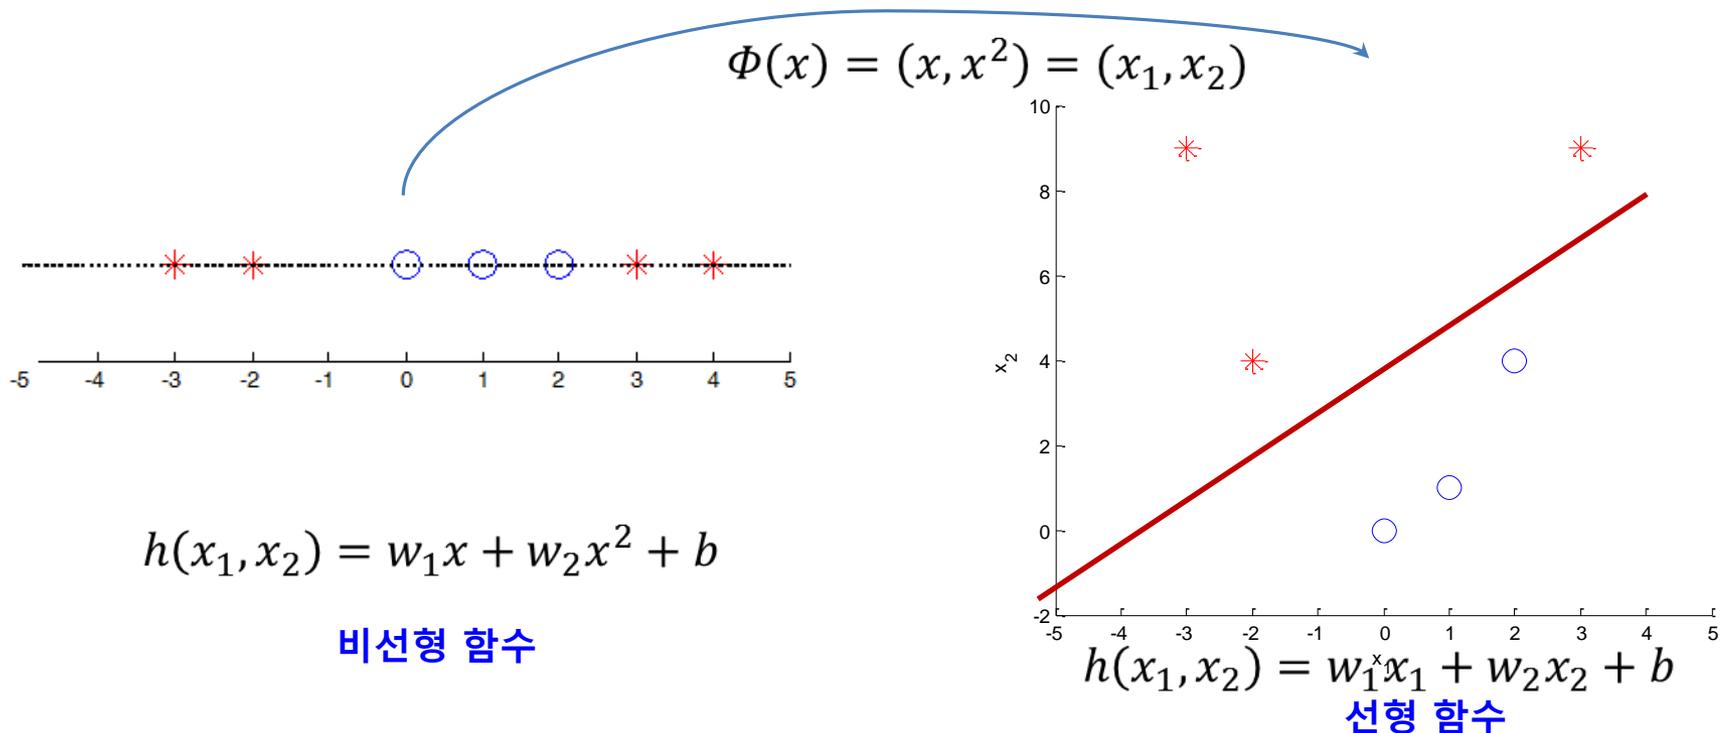
10.5 비선형 SVM

❖ 선형 SVM (linear SVM)

- 선형인 초평면으로 공간 분할
- 슬랙변수를 도입하더라도 한계

❖ 데이터의 고차원 사상(high-dimensional mapping)

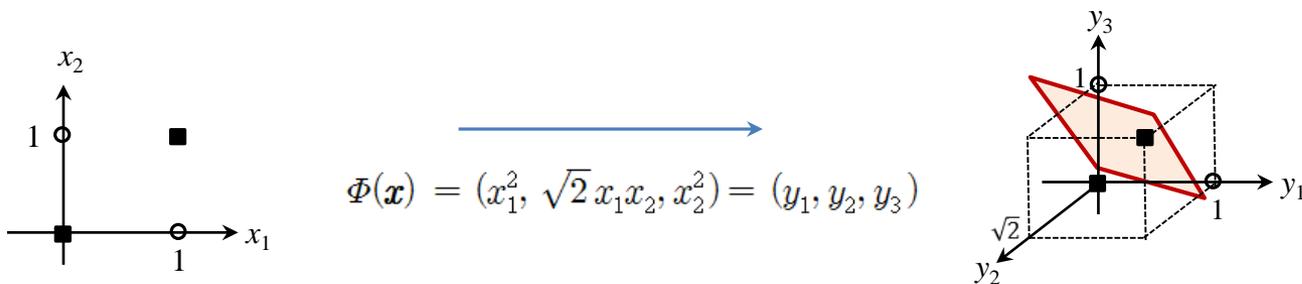
- 데이터를 고차원의 사상하면 선형 분리 가능



비선형 SVM

❖ 데이터의 고차원 사상 - cont.

- XOR 문제



❖ 고차원 변환의 문제점

- 차원의 저주(curse of dimensionality) 문제 발생
- 테스트 데이터에 대한 **일반화**(generalization) 능력 저하 가능
 - **여백(margin) 최대화**를 통해 일반화 능력 유지
- 계산 비용 증가
 - **커널 트릭(kernel trick)** 사용으로 해결

비선형 SVM

❖ SVM의 최적화 문제

▪ 선형 SVM

Find α which **minimizes** $\tilde{L}(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \mathbf{x}_i \cdot \mathbf{x}_j - \sum_{i=1}^N \alpha_i$

subject to $\sum_{i=1}^N \alpha_i t_i = 0, \quad i = 1, \dots, N$

$\alpha_i \geq 0, \quad i = 1, \dots, N$

$$h(\mathbf{x}) = \sum_{i=0}^N \alpha_i t_i \mathbf{x}_i \cdot \mathbf{x} + b$$

▪ 데이터의 고차원 변환

$$\mathbf{x}_i \rightarrow \Phi(\mathbf{x}_i)$$

▪ 비선형 SVM

$$\tilde{L}(\alpha) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j) + \sum_{i=1}^N \alpha_i$$

$$h(\mathbf{x}) = \sum_{i=1}^N \alpha_i t_i \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) + b$$

비선형 SVM

❖ 커널 트릭(kernel trick)

- $\Phi(x_i) \cdot \Phi(x_j)$ 를 고차원으로 변환하여 계산하지 않고, 원래 데이터에서 계산
- 고차원 변환없이 계산할 수 있는 커널 함수(kernel function) K 사용
 - $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$

❖ 커널 함수의 예

- $K(x, y) = (x^T y)^2$
 - $x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad y = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}$
 - $(x^T y)^2 = (x_1 y_1 + x_2 y_2)^2 = (x_1 y_1)^2 + 2(x_1 y_1)(x_2 y_2) + (x_2 y_2)^2$
 $= \begin{bmatrix} (x_1)^2 & \sqrt{2}x_1 x_2 & (x_2)^2 \end{bmatrix} \begin{bmatrix} (y_1)^2 & \sqrt{2}y_1 y_2 & (y_2)^2 \end{bmatrix}^T$
 $= \Phi(x) \cdot \Phi(y)$
 - $\Phi(x) = \begin{bmatrix} (x_1)^2 \\ \sqrt{2}x_1 x_2 \\ (x_2)^2 \end{bmatrix} \quad \Phi(y) = \begin{bmatrix} (y_1)^2 \\ \sqrt{2}y_1 y_2 \\ (y_2)^2 \end{bmatrix}$

비선형 SVM

❖ 대표적인 커널 함수(kernel function)

- 다항식 커널(polynomial kernel)

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^p, \quad p \text{는 양의정수}$$

- RBF(radial basis function) 커널

$$K(\mathbf{x}_i, \mathbf{x}_j) = e^{-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / (2\sigma^2)}$$

- 쌍곡 탄젠트(hyperbolic tangent) 커널

$$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\alpha \mathbf{x}_i \cdot \mathbf{x}_j + \beta)$$

비선형 SVM

❖ 커널 트릭을 사용할 때의 최적화 문제

$$\tilde{L}(\alpha) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j \Phi(x_i) \cdot \Phi(x_j) + \sum_{i=1}^N \alpha_i$$

$$h(x) = \sum_{i=1}^N a_i t_i \Phi(x_i) \cdot \Phi(x) + b$$

▪ 커널 함수 적용

$$\tilde{L}(\alpha) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j K(x_i, x_j) + \sum_{i=1}^N \alpha_i$$

$$h(x) = \sum_{i=1}^N a_i t_i K(x_i, x) + b$$

비선형 SVM

❖ 초평면 결정

▪ 선형 SVM

$$\tilde{L}(\alpha) = \frac{1}{2} [\alpha_1 \ \alpha_2 \ \dots \ \alpha_N] \begin{bmatrix} t_1 t_1 \mathbf{x}_1 \cdot \mathbf{x}_1 & t_1 t_2 \mathbf{x}_1 \cdot \mathbf{x}_2 & \dots & t_1 t_N \mathbf{x}_1 \cdot \mathbf{x}_N \\ t_2 t_1 \mathbf{x}_2 \cdot \mathbf{x}_1 & t_2 t_2 \mathbf{x}_2 \cdot \mathbf{x}_2 & \dots & t_2 t_N \mathbf{x}_2 \cdot \mathbf{x}_N \\ \vdots & \vdots & \ddots & \vdots \\ t_N t_1 \mathbf{x}_N \cdot \mathbf{x}_1 & t_N t_2 \mathbf{x}_N \cdot \mathbf{x}_2 & \dots & t_N t_N \mathbf{x}_N \cdot \mathbf{x}_N \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_N \end{bmatrix} - \sum_{i=1}^N \alpha_i$$

▪ 비선형 SVM

$$\tilde{L}(\alpha) = \frac{1}{2} [\alpha_1 \ \alpha_2 \ \dots \ \alpha_N] \begin{bmatrix} t_1 t_1 K(\mathbf{x}_1, \mathbf{x}_1) & t_1 t_2 K(\mathbf{x}_1, \mathbf{x}_2) & \dots & t_1 t_N K(\mathbf{x}_1, \mathbf{x}_N) \\ t_2 t_1 K(\mathbf{x}_2, \mathbf{x}_1) & t_2 t_2 K(\mathbf{x}_2, \mathbf{x}_2) & \dots & t_2 t_N K(\mathbf{x}_2, \mathbf{x}_N) \\ \vdots & \vdots & \ddots & \vdots \\ t_N t_1 K(\mathbf{x}_N, \mathbf{x}_1) & t_N t_2 K(\mathbf{x}_N, \mathbf{x}_2) & \dots & t_N t_N K(\mathbf{x}_N, \mathbf{x}_N) \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_N \end{bmatrix} - \sum_{i=1}^N \alpha_i$$

▪ 이차식 계획법 라이브러리 사용

- quadprog(), solver.qp()
- $\alpha_1, \alpha_2, \dots, \alpha_N$ 계산
- 고차원의 초평면 함수 결정

$$h(\mathbf{x}) = \sum_{i=1}^N a_i t_i \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) + b$$

$$h(\mathbf{x}) = \sum_{i=1}^N a_i t_i K(\mathbf{x}_i, \mathbf{x}) + b$$

SVM

❖ 비선형 SVM에 의한 결정 경계 및 서포트 벡터

