

LINEAR CLASSIFIERS


در این فصل: طراحی طبقه‌بندهای خطی صرفنظر از توزیع‌های توصیف‌کننده داده‌های آموزشی برتری: سادگی، دقت، سرعت

❖ The Problem: Consider a two class task with ω_1, ω_2

معادله خطی

➤ $g(\underline{x}) = \underline{w}^T \underline{x} + w_0 = 0 =$
 $w_1 x_1 + w_2 x_2 + \dots + w_l x_l + w_0 = 0$

فضای لایه‌ی



➤ Assume $\underline{x}_1, \underline{x}_2$ on the decision hyperplane :


$$0 = \underline{w}^T \underline{x}_1 + w_0 = \underline{w}^T \underline{x}_2 + w_0 \Rightarrow$$

$$\underline{w}^T (\underline{x}_1 - \underline{x}_2) = 0 \quad \forall \underline{x}_1, \underline{x}_2$$
 بردار وزن‌ها \underline{w} بر ابرصفحه تقسیم عمود است.

➤ Hence:

\underline{w} \perp on the hyperplane

$$g(\underline{x}) = \underline{w}^T \underline{x} + w_0 = 0$$



$$w_1 x_1 + w_2 x_2 + w_0 = 0$$

فاصله از خط

$$d = \frac{|w_0|}{\sqrt{w_1^2 + w_2^2}}, \quad z = \frac{|g(\underline{x})|}{\sqrt{w_1^2 + w_2^2}}$$

(۱۶)

❖ The Perceptron Algorithm

الگوریتم Perceptron:


جدایی پذیر خطی

فرض: کلاسها جدایی پذیر خطی باشند.

- Assume linearly separable classes, i.e.,


$$\exists \underline{w}^* : w^{*T} \underline{x} > 0 \quad \forall \underline{x} \in \omega_1 \quad \text{نیم‌صفه‌ای منفی}$$

$$w^{*T} \underline{x} < 0 \quad \forall \underline{x} \in \omega_2 \quad \text{نیم‌صفه‌ای مثبت}$$



- The case $\underline{w}^{*T} \underline{x} + w_0^*$ falls under the above formulation, since

- $\underline{w}' \equiv \begin{bmatrix} \underline{w}^* \\ w_0^* \end{bmatrix}, \underline{x}' \equiv \begin{bmatrix} \underline{x} \\ 1 \end{bmatrix} \Rightarrow \underline{w}'^T \underline{x}' = 0$



- $\underline{w}^{*T} \underline{x} + w_0^* = \underline{w}'^T \underline{x}' = 0$

هدف: راه‌حلی برای به دست آوردن ابرصفحه \underline{w} که دو دسته را از هم جدا کند.

- Our goal: Compute a solution, i.e., a hyperplane \underline{w} , so that

$$\underline{w}^T \underline{x} (> <) 0 \quad \underline{x} \in \begin{cases} \omega_1 \\ \omega_2 \end{cases}$$

- The steps
 - Define a cost function to be minimized
 - Choose an algorithm to minimize the cost function
 - The minimum corresponds to a solution

➤ The Cost Function

$$\Rightarrow J(\underline{w}) = \sum_{\underline{x} \in Y} (\delta_x \underline{w}^T \underline{x})$$

تابع هزینه *perception*:

- Where Y is the subset of the vectors **wrongly** classified by \underline{w} . When $Y = (\text{empty set})$ a solution is achieved and

Y : زیر مجموعه ای از بردارها که به اشتباه طبقه بندی شده اند.
وقتی $Y = \emptyset$ نشود به جواب رسیده ایم.

$$Y = \emptyset \rightarrow$$

- $J(\underline{w}) = 0$

- $$\begin{cases} \delta_x = -1 & \text{if } \underline{x} \in Y \text{ and } \underline{x} \in \omega_1 \\ \delta_x = +1 & \text{if } \underline{x} \in Y \text{ and } \underline{x} \in \omega_2 \end{cases}$$

$$\underline{w}^T \underline{x} < 0$$


$$\underline{w}^T \underline{x} > 0 \rightarrow \underline{x} \in \omega_1$$

$$\underline{w}^T \underline{x} < 0 \rightarrow \underline{x} \in \omega_2$$

$$\underline{w}^T \underline{x} > 0$$

- $J(\underline{w}) \geq 0$

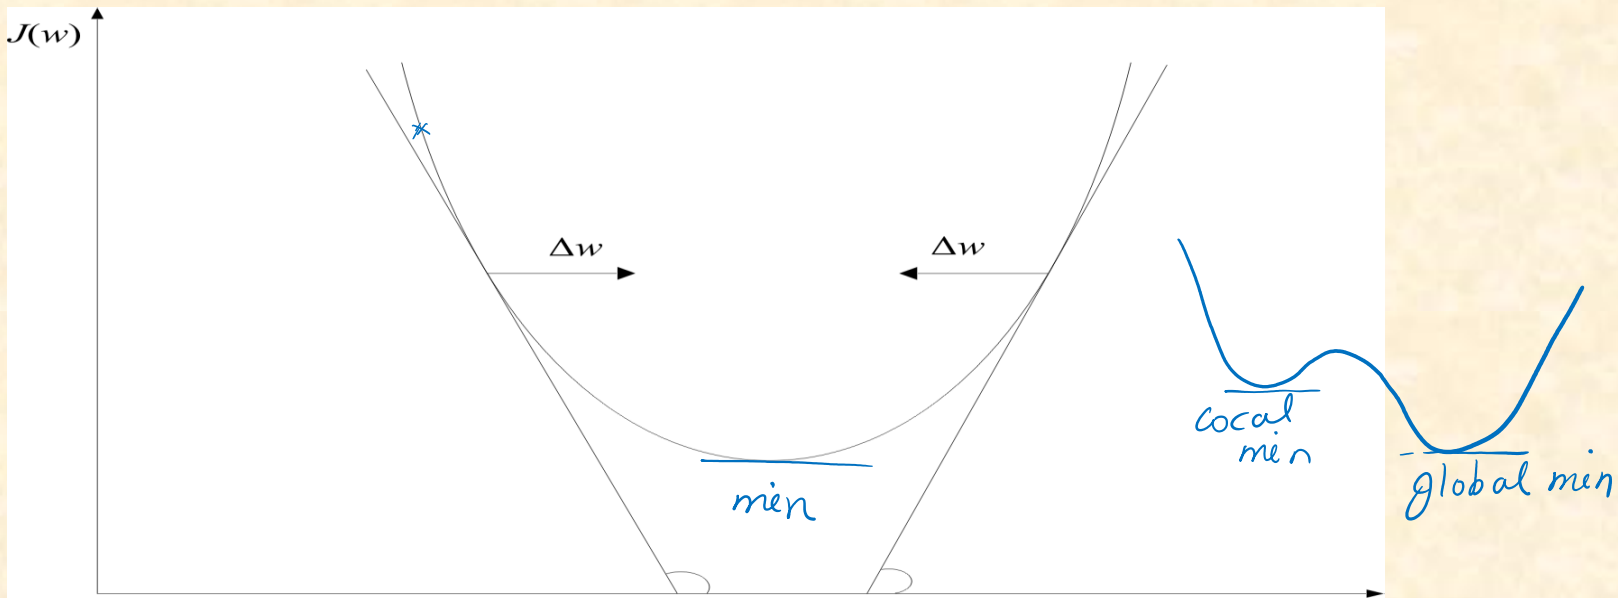
- $J(\underline{w})$ is piecewise linear (WHY?)



➤ The Algorithm

- The philosophy of the gradient descent is adopted.

گرادیان نزولی



$$\underline{w}(\text{new}) = \underline{w}(\text{old}) + \Delta \underline{w}$$

$$\Delta \underline{w} = -\mu \frac{\partial J(\underline{w})}{\partial \underline{w}} \Big|_{\underline{w} = \underline{w}(\text{old})}$$

$$\Delta \underline{w} = -\mu \frac{\partial J(\underline{w})}{\partial \underline{w}} \Big|_{\underline{w} = \underline{w}_{\text{old}}}$$
 ← با پارامتر تنظیم سرعت هم برای

- Wherever valid

$$\frac{\partial J(\underline{w})}{\partial \underline{w}} = \frac{\partial}{\partial \underline{w}} \left(\sum_{\underline{x} \in Y} \delta_x \underline{w}^T \underline{x} \right) = \sum_{\underline{x} \in Y} \delta_x \underline{x}$$

$\Rightarrow \underline{w}_{\text{new}} = \underline{w}_{\text{old}} + \Delta \underline{w}$

- $$\underline{w}(t+1) = \underline{w}(t) - \rho_t \sum_{\underline{x} \in Y} \delta_x \underline{x}$$

کار با پارامتر تنظیم
 دقت‌های کم‌تر اعداد دقیق
 بیشتر

This is the celebrated **Perceptron Algorithm**

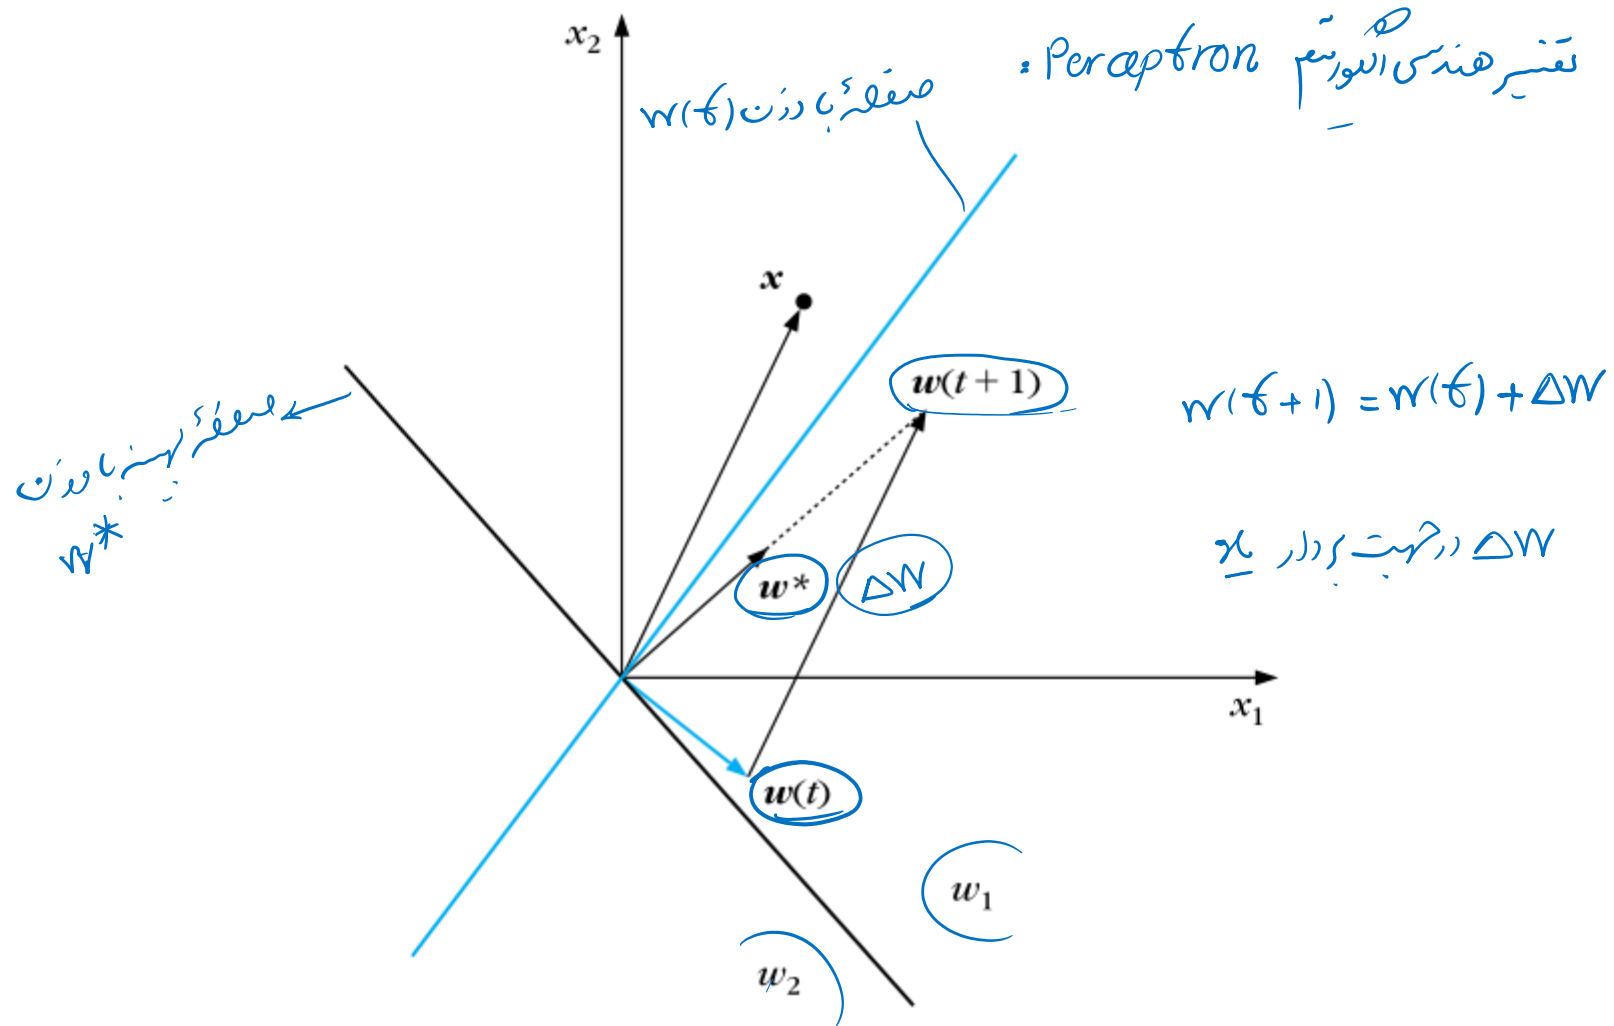


FIGURE 3.2

Geometric interpretation of the perceptron algorithm. The update of the weight vector is in the direction of \mathbf{x} in order to turn the decision hyperplane to include \mathbf{x} in the correct class.




FIGURE 3.3

An example of the perceptron algorithm. After the update of the weight vector, the hyperplane is turned from its initial location (dotted line) to the new one (full line), and all points are correctly classified.

الگوریتم پرسترون :

- مقدار دهی اولیه $w(0)$ به صورت تصادفی

- انتخاب ρ_0

- $t = 0$

حلقه تکرار

- $\gamma = \phi$

for $i = 1$ to N
 if $\sum_{x_i} w(t)^T x_i \geq 0$ then $\gamma = \gamma \cup \{x_i\}$
 end

حلقه for برای تشکیل نمونه های به اشتباه طبقه بندی شده
 با بردار وزن های $w(t)$


$$w(t+1) = w(t) - \rho_t \sum_{x \in \gamma} x$$

- تنظیم ρ_t

- $t = t + 1$

تا زمانی که $\gamma = \phi$

➤ An example:



$$\begin{aligned} \underline{w}(t+1) &= \underline{w}(t) + \rho_t \underline{x} \\ &= \underline{w}(t) - \rho_t \delta_x \underline{x} \quad (\delta_x = -1) \end{aligned}$$

پس برای:

- The perceptron algorithm **converges** in a **finite** number of iteration steps to a solution if

$$\lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k \rightarrow \infty,$$



$$\lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k^2 < +\infty$$

e.g.,: $\left| \rho_t = \frac{c}{t} \right|$

❖ A useful variant of the perceptron algorithm

⇒ Reward & Punishment تنبیه و پاداش

فرآه‌ای دبر الوریتم بر سرتون: \varnothing

$$\underline{w}(t+1) = \underline{w}(t) + \rho \underline{x}_{(t)}, \begin{cases} \underline{w}^T(t) \underline{x}_{(t)} \leq 0 \\ \underline{x}_{(t)} \in \omega_1 \end{cases} \quad \text{طبقه بندی به اشتباه}$$

$$\underline{w}(t+1) = \underline{w}(t) - \rho \underline{x}_{(t)}, \begin{cases} \underline{w}^T(t) \underline{x}_{(t)} \geq 0 \\ \underline{x}_{(t)} \in \omega_2 \end{cases}$$

$$\underline{w}(t+1) = \underline{w}(t) \quad \text{otherwise} \rightarrow \text{طبقه بندی به درستی}$$


نمونه‌ها را یک به یک به الوریتم اعمال می‌کنیم؛ اگر پس از پایان یافتن نمونه‌ها، الوریتم اشتباه نشد، دوباره نمونه‌ها را اعمال خواهیم کرد.

➤ It is a reward and punishment type of algorithm

مشق 3.2 :

$x: \omega_1$
 $0: \omega_2$

طبقه بندی خطی با استفاده از الگوریتم
برای رسیدن به فردا با دانش دسته‌بندی
کنید.
 ω_1
 ω_2
 $\underline{w}^T x \geq 0$



$\underline{w}(0) = [0, 0, 0]$ ، $\rho = 1$ تصادفی

حل :

مرحله اول

$\underline{w}^T(0) \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix} = 0 \xrightarrow{x} \underline{w}(1) = \underline{w}(0) + 1 \cdot \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix} = \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix}$

مرحله دوم

$\underline{w}^T(1) \begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix} = 1 > 0 \checkmark \rightarrow \underline{w}(2) = \underline{w}(1)$

مرحله سوم

$\omega_2 \leftarrow \underline{w}^T(2) \begin{bmatrix} 0 \\ -1 \\ 1 \end{bmatrix} = 1 > 0 \times \rightarrow \underline{w}(3) = \underline{w}(2) - 1 \cdot \begin{bmatrix} 0 \\ -1 \\ 1 \end{bmatrix} = \begin{bmatrix} -1 \\ 1 \\ 0 \end{bmatrix}$

مرحله چهارم

$\omega_2 \leftarrow \underline{w}^T(3) \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix} = -1 < 0 \checkmark \rightarrow \underline{w}(4) = \underline{w}(3)$

مرحله پنجم

$\underline{w}^T(4) \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix} = 1 > 0 \checkmark \rightarrow \underline{w}(5) = \underline{w}(4)$


$\underline{w}^T x = 0 \rightarrow [-1 \ 1 \ 0] \begin{bmatrix} x_1 \\ x_2 \\ 1 \end{bmatrix}$

$-x_1 + x_2 = 0$
 $x_1 = x_2$

$\dots \rightarrow \underline{w}(7) = \underline{w}(6) = \begin{bmatrix} -1 \\ 1 \\ 0 \end{bmatrix}$

❖ The perceptron

واحد پایه ای شبکه های عصبی (نورون)



w_i' s synapses or synaptic weights

w_0 threshold

- The network is called **perceptron** or **neuron**
- It is a **learning machine** that **learns** from the training vectors via the **perceptron algorithm**





FIGURE 3.5

The basic perceptron model. (a) A linear combiner is followed by the activation function. (b) The combiner and the activation function are merged together.


➤ **Example:** At some stage t the perceptron algorithm results in

$$w(t) \rightarrow w_1 = 1, w_2 = 1, w_0 = -0.5$$

$$\text{میزان} \rightarrow x_1 + x_2 - 0.5 = 0$$

شماره:

The corresponding hyperplane is



$$\underline{w}(t+1) = \underline{w}(t) - \rho_t \sum_{x \in X} \delta_x \underline{x}$$

$$\underline{w}(t+1) = \begin{bmatrix} 1 \\ 1 \\ -0.5 \end{bmatrix} - 0.7(-1) \begin{bmatrix} 0.4 \\ 0.05 \\ 1 \end{bmatrix} - 0.7(+1) \begin{bmatrix} -0.2 \\ 0.75 \\ 1 \end{bmatrix} = \begin{bmatrix} 1.42 \\ 0.51 \\ -0.5 \end{bmatrix}$$

الورتسم Pocket : (برای حالت صدهای که جدایی پذیر خصل نیستند)

شرف اصلی الورتسم بر پستون جدایی پذیر خصل بویست که صدهاست. اگر این فرض برقرار نباشد که در عمل مملو از این چنین است. الورتسم بر پستون همرا تودده شده. فداها در الورتسم که به راه حل پهنه میزگر شوند در این مولود استقاه می شود. که اگر از آنجا الورتسم که Pocket است.

تعداد نمونه‌هایی که به درسی طبعه بند شده اند.

$$w_s = w(0)$$

دوم الورتسم Pocket :

۱- مقداردهی اولیه بردار وزن $w(0)$ به صورت تصادفی و ذخیره آن با عنوان w_s ، مقداردهی شماره $h_s = 0$

۲- در هر گام k ، با استفاده از قانون پستون $w(k+1)$ را به هر کسوم با استفاده از این بردار وزن ، بردارهای آموزشی را به کسوم و مقدار بردارهایی که درست طبعه بندی شده اند را h می نامیم. اگر $h > h_s$

باشند ، w_s را به $w(k+1)$ جایگزین می کنیم ، h_s را با h جایگزین می کنیم.

$$h_s = h$$

$$w_s = w(k+1)$$

حالت چندانکه سه :

تاکنون حالت دو که سه را برداشتی کردیم. تعمیم به حالت \mathcal{M} که سه سه سراسر است :

$\mathcal{M}, \dots, 2, 1 = z$ برای هر یک از \mathcal{M} سه سه تعریف شده است .

بردار \underline{x} ها ω ($l+1$) بعدی به صورت زیر در \mathcal{M} سه سه طبقه بندی می شود اگر :

$$\underline{w}_z^T \underline{x} > \underline{w}_j^T \underline{x} ; \forall j \neq z$$

این شرط به ساختار Kesler میز می شود :

برای هر یک از بردارهای آموزشی متعلق به \mathcal{M} که $z = 1, 2, \dots, \mathcal{M}$ باشد ، $(\mathcal{M}-1)$ بردار آموزشی به

صورت زیر تعریف می کنیم :

$$\underline{x}_{zj} = [\underline{0}^T, \underline{0}^T, \dots, \underline{x}^T, \dots, -\underline{x}^T, \dots, \underline{0}^T]^T \quad (l+1) \mathcal{M} \times 1$$

همه بدون کاربرد صفرند غیر از z که برابر \underline{x}^T و z که برابر $-\underline{x}^T$ است .

بردار وزن ها :

$$\underline{w} = [\underline{w}_1^T, \dots, \underline{w}_{\mathcal{M}}^T]^T$$

$$\underline{w}^T \underline{x}_{1z} \geq \sum_{\omega \in \mathcal{M}} \omega$$

$$\underline{w}^T \underline{x}_{1z} \geq \sum_{\omega \in \mathcal{M}} \omega$$

با این تعریف :

$$\underline{w}^T \underline{x}_{zj} > 0 \rightarrow \underline{x} \in \omega ; \forall j = 1, 2, \dots, \mathcal{M} ; j \neq z$$

تعداد نمونه ها : $(\mathcal{M}-1)N$

پس این سه سه به طراحی طبقه بندی خطی در فضای $\mathcal{M} (l+1)$ بعدی تبدیل شده .

مثال : مسئله سه متغیره در فضای دو بعدی : بردارهای آموزشی :

$\omega_1 : [1, 1]^T, [2, 2]^T, [2, 1]^T$

$\omega_2 : [1, -1]^T, [1, -2]^T, [2, -2]^T$

$\omega_3 : [-1, 1]^T, [-1, 2]^T, [-2, 1]^T$

$\frac{(l+1)M \times 1}{3} = \frac{9 \times 1}{3}$

$\begin{cases} \underline{x} = [1, 1, 1]^T \\ \omega_1 \rightarrow i=1 \end{cases}$

$\begin{cases} x_{11} = [1, 1, 1, -1, -1, -1, 0, 0, 0]^T \quad 9 \times 1 \\ x_{12} = [1, 1, 1, 0, 0, 0, -1, -1, -1]^T \quad 9 \times 1 \end{cases}$

$\begin{cases} \underline{x} = [1, -2, 1]^T \\ \omega_2 \rightarrow i=2 \end{cases}$

$\begin{cases} x_{21} = [-1, 2, -1, 1, -2, 1, 0, 0, 0]^T \quad 9 \times 1 \\ x_{22} = [0, 0, 0, 1, -2, 1, -1, 2, -1]^T \quad 9 \times 1 \end{cases}$

$\begin{cases} \underline{x} = [-2, 1, 1]^T \\ \omega_3 \rightarrow i=3 \end{cases}$

$\begin{cases} x_{31} = [2, -1, -1, 0, 0, 0, -2, 1, 1]^T \quad 9 \times 1 \\ x_{32} = [0, 0, 0, 2, -1, -1, -2, 1, 1]^T \quad 9 \times 1 \end{cases}$

مسئله جدایی پذیر خطی است.

ساختار kernel :

بردار وزن \underline{w} :

$$\begin{cases} \underline{w}_1 = [w_{11}, w_{12}, w_{10}]^T \\ \underline{w}_2 = [w_{21}, w_{22}, w_{20}]^T \\ \underline{w}_3 = [w_{31}, w_{32}, w_{30}]^T \end{cases}$$

$\rightarrow \underline{W} = [\underline{w}_1^T, \underline{w}_2^T, \underline{w}_3^T]^T$

۱۸۶ بردار آموزشی، بردار \underline{w} استوار است
که سبب بردن را اجزای کنیم :

$\underline{w}_1 = [0.13, 3.6, 0.1, 0.0]^T$
 $\underline{w}_2 = [2.05, -3.16, -0.4, 1]^T$
 $\underline{w}_3 = [2.84, 1.28, -0.69, 1]^T$

3.4 روشهای کمینه مربعات :

جذابیت طبقه بندی های خطی در رگ آنهاست بنابراین در بسیاری از موارد با وجود اینکه فرض جدایی پذیر خطی برقرار نیست. از این طبقه بندی استفاده می شود. در این مورد طبقه بندی های خطی به راه حل زیر بهینه (sub optimal) منجر می شوند.

3.4.1 تخمین خطای مینیمم مربعات :

مسئله در دسترس : خروجی $y = \pm 1$

حل با استفاده از خطاها

بردار ورودی \underline{x} — طبقه بندی $\underline{w}^T \underline{x}$

تخمین هزینه $J(\underline{w}) = E[|y - \underline{w}^T \underline{x}|^2]$ MSE: Mean Square Error

MSE بین خروجی های واقعی و مطلوب desired true

خروجی مقصود $y(\underline{x}) = y = \pm 1$ ← خروجی مطلوب

minimize $\rightarrow \hat{\underline{w}} = \underset{\underline{w}}{\text{argmin}} J(\underline{w})$

3.28 $\rightarrow J(\underline{w}) = p(\omega_1) \int (1 - \underline{x}^T \underline{w})^2 p(\underline{x} | \omega_1) d\underline{x} + p(\omega_2) \int (1 + \underline{x}^T \underline{w})^2 p(\underline{x} | \omega_2) d\underline{x}$

$\frac{\partial J(\underline{w})}{\partial \underline{w}} = 0 \rightarrow 2E[\underline{x}(y - \underline{x}^T \underline{w})] = 0 \rightarrow \hat{\underline{w}} = R_x^{-1} E[\underline{x}y]$ 20

❖ Least Squares Methods

- If classes are linearly separable, the perceptron output results in ± 1
- If classes are NOT linearly separable, we shall compute the weights w_1, w_2, \dots, w_0

so that the **difference** between

- The actual output of the classifier, $\underline{w}^T \underline{x}$, and
- The desired outputs, e.g.
 - +1 if $\underline{x} \in \omega_1$
 - 1 if $\underline{x} \in \omega_2$

to be **SMALL**

➤ **SMALL**, in the **mean square** error sense, means to choose \underline{w} so that the cost function

- $J(\underline{w}) \equiv E[(y - \underline{w}^T \underline{x})^2]$ is minimum
- $\hat{\underline{w}} = \arg \min_{\underline{w}} J(\underline{w})$
- y the corresponding desired responses

➤ Minimizing

$J(\underline{w})$ w.r. to \underline{w} results in :

$$\begin{aligned}\frac{\partial J(\underline{w})}{\partial \underline{w}} &= \frac{\partial}{\partial \underline{w}} E[(y - \underline{w}^T x)^2] = 0 \\ &= 2E[\underline{x}(y - \underline{x}^T \underline{w})] \Rightarrow \\ E[\underline{x}\underline{x}^T] \underline{w} &= E[\underline{x}y] \Rightarrow\end{aligned}$$

$$\hat{\underline{w}} = R_x^{-1} E[\underline{x}y]$$

where R_x is the **autocorrelation matrix**

$$R_x \equiv E[\underline{x}\underline{x}^T] = \begin{bmatrix} E[x_1x_1] & E[x_1x_2] \dots & E[x_1x_l] \\ \dots\dots\dots & \dots\dots\dots & \dots\dots\dots \\ E[x_lx_1] & E[x_lx_2] \dots & E[x_lx_l] \end{bmatrix}$$

and $E[\underline{x}y] = \begin{bmatrix} E[x_1y] \\ \dots \\ E[x_ly] \end{bmatrix}$ the **crosscorrelation vector**




FIGURE 3.6

Interpretation of the MSE estimate as an orthogonal projection on the input vector elements' subspace.

➤ Multi-class generalization

تقسیم چند طبقه

- The goal is to compute M linear discriminant functions:

$$g_i(\underline{x}) = \underline{w}_i^T \underline{x} \quad i = 1, 2, \dots, M$$

according to the MSE.

- Adopt as desired responses y_i :

خروجی های مطلوب

$$y_i = 1 \quad \text{if } \underline{x} \in \omega_i$$
$$y_i = 0 \quad \text{otherwise}$$

- Let

$$\underline{y} = [y_1, y_2, \dots, y_M]^T$$

- And the matrix

ماتریس وزن

$$W = [\underline{w}_1, \underline{w}_2, \dots, \underline{w}_M]$$

- The goal is to compute W :

$$\hat{W} = \arg \min_W E \left[\left\| \underline{y} - W^T \underline{x} \right\|^2 \right] = \arg \min_W E \left[\sum_{i=1}^M \left(y_i - \underline{w}_i^T \cdot \underline{x} \right)^2 \right]$$

معدل M مسئله کمینه سازی MSE

- The above is equivalent to a number M of MSE minimization problems. That is:

Design each \underline{w}_i so that its desired output is 1 for $\underline{x} \in \omega_i$ and 0 for any other class.

➤ **Remark:** The MSE criterion belongs to a more general class of cost function with the following **important** property:

- The value of $g_i(\underline{x})$ is an **estimate, in the MSE sense**, of the **a-posteriori** probability $P(\omega_i | \underline{x})$, provided that the desired responses used during training are $y_i = 1, \underline{x} \in \omega_i$ and 0 otherwise.

- × ➤ **Mean square error regression:** Let $\underline{y} \in \mathfrak{R}^M$, $\underline{x} \in \mathfrak{R}^\ell$ be jointly distributed random vectors with a joint pdf $p(\underline{x}, \underline{y})$
- The goal: **Given** the value of \underline{x} **estimate** the value of \underline{y} . In the pattern recognition framework, given \underline{x} one wants to estimate the respective label $y = \pm 1$.

- The MSE estimate $\hat{\underline{y}}$ of \underline{y} given \underline{x} is defined as:

$$\hat{\underline{y}} = \arg \min_{\tilde{\underline{y}}} E \left[\|\underline{y} - \tilde{\underline{y}}\|^2 \right]$$

- It turns out that:

$$\hat{\underline{y}} = E[\underline{y} | \underline{x}] \equiv \int_{-\infty}^{+\infty} \underline{y} p(\underline{y} | \underline{x}) d\underline{y}$$

The above is known as the **regression** of \underline{y} given \underline{x} and it is, in general, a non-linear function of \underline{x} . If $p(\underline{x}, \underline{y})$ is **Gaussian** the **MSE regressor is linear**.

Sum of Error Squares Estimation

3.4.3 تخمین مجموع مربعات خطا

بهترین تقریب به MSE با عنوان مجموع مربعات خطا (Least Squares) LS

تابع هزینه

$$J(\underline{w}) = \sum_{i=1}^N (y_i - \underline{x}_i^T \underline{w})^2 \equiv \sum_{i=1}^N e_i^2$$

در MSE بیانین خطا در LS مجموع خطا

در MSE برای $E\{ \}$ به pdf نیاز است ولی در LS این شرط وجود ندارد.

Minimizing $\frac{\partial J(\underline{w})}{\partial \underline{w}} = 0$

$$\sum_{i=1}^N \underline{x}_i (y_i - \underline{x}_i^T \hat{\underline{w}}) = 0 \rightarrow \left(\sum_{i=1}^N \underline{x}_i \underline{x}_i^T \right) \hat{\underline{w}} = \sum_{i=1}^N \underline{x}_i y_i$$

ماتریس $X = \begin{bmatrix} \underline{x}_1^T \\ \underline{x}_2^T \\ \vdots \\ \underline{x}_N^T \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1l} \\ x_{21} & x_{22} & \dots & x_{2l} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nl} \end{bmatrix}_{N \times l}$, $\underline{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}_{N \times 1}$

$$(X^T X) \hat{\underline{w}} = X^T \underline{y} \rightarrow \hat{\underline{w}} = \underline{(X^T X)^{-1} X^T \underline{y}}$$

$X \hat{\underline{w}} = \underline{y}$
استفاده از این روش

$X^+ = X^{-1}$ اگر X مربعی باشد

X^+ شبیه داشتن ماتریس X معکوس است
به اندازه نمونه $N=l$

❖ SMALL in the **sum of error** squares sense means

$$\triangleright J(\underline{w}) = \sum_{i=1}^N (y_i - \underline{w}^T \underline{x}_i)^2$$

(y_i, \underline{x}_i) : training pairs that is, the input \underline{x}_i and its corresponding **class label** y_i (± 1).

$$\triangleright \frac{\partial J(\underline{w})}{\partial \underline{w}} = \frac{\partial}{\partial \underline{w}} \sum_{i=1}^N (y_i - \underline{w}^T \underline{x}_i)^2 = 0 \Rightarrow$$

برجسته
✓
+1 → ω₁
-1 → ω₂

$$\left(\sum_{i=1}^N \underline{x}_i \underline{x}_i^T \right) \underline{w} = \sum_{i=1}^N \underline{x}_i y_i$$

❖ Pseudoinverse Matrix

➤ Define

$$X = \begin{bmatrix} \underline{x}_1^T \\ \underline{x}_2^T \\ \dots \\ \underline{x}_N^T \end{bmatrix} \quad (\text{an } N \times l \text{ matrix})$$

$$\underline{y} = \begin{bmatrix} y_1 \\ \dots \\ y_N \end{bmatrix} \quad \text{corresponding desired responses}$$

➤ $X^T = [\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N]$ (an $l \times N$ matrix)

➤ $X^T X = \sum_{i=1}^N \underline{x}_i \underline{x}_i^T$

➤ $X^T \underline{y} = \sum_{i=1}^N \underline{x}_i y_i$

Thus
$$\left(\sum_{i=1}^N \underline{x}_i^T \underline{x}_i\right) \underline{\hat{w}} = \left(\sum_{i=1}^N \underline{x}_i^T \underline{y}_i\right)$$

$$(X^T X) \underline{\hat{w}} = X^T \underline{y} \Rightarrow$$

$$\underline{\hat{w}} = (X^T X)^{-1} X^T \underline{y}$$

$$= X^\# \underline{y}$$

$$X^\# \equiv (X^T X)^{-1} X^T$$

Pseudoinverse of X

➤ Assume $N=l \Rightarrow X$ square and invertible. Then

$$(X^T X)^{-1} X^T = X^{-1} X^{-T} X^T = X^{-1} \Rightarrow$$

$$X^\# = X^{-1}$$

- Assume $N > l$. Then, in general, there is no solution to satisfy all equations simultaneously:

$$X \underline{w} = \underline{y} : \begin{array}{l} \underline{x}_1^T \underline{w} = y_1 \\ \underline{x}_2^T \underline{w} = y_2 \\ \dots \\ \underline{x}_N^T \underline{w} = y_N \end{array} \quad N \text{ equations} > l \text{ unknowns}$$

- The “solution” $\underline{w} = X^\dagger \underline{y}$ corresponds to the minimum sum of squares solution

➤ Example:

$$\omega_1: \begin{bmatrix} 0.4 \\ 0.5 \end{bmatrix}, \begin{bmatrix} 0.6 \\ 0.5 \end{bmatrix}, \begin{bmatrix} 0.1 \\ 0.4 \end{bmatrix}, \begin{bmatrix} 0.2 \\ 0.7 \end{bmatrix}, \begin{bmatrix} 0.3 \\ 0.3 \end{bmatrix}$$

$$\omega_2: \begin{bmatrix} 0.4 \\ 0.6 \end{bmatrix}, \begin{bmatrix} 0.6 \\ 0.2 \end{bmatrix}, \begin{bmatrix} 0.7 \\ 0.4 \end{bmatrix}, \begin{bmatrix} 0.8 \\ 0.6 \end{bmatrix}, \begin{bmatrix} 0.7 \\ 0.5 \end{bmatrix}$$


مش:

ماتریک معادله
داده می

$$w_1 x_1 + w_2 x_2 + w_0 = 0$$

طبقه بندی خطی بر مبنای داده های مجموع مربعات کمینه (LS) طراحی کنید.

حل: $\hat{w} = (X^T X)^{-1} X^T \underline{y}$



$$X = \begin{bmatrix} 0.4 & 0.5 & 1 \\ 0.6 & 0.5 & 1 \\ 0.1 & 0.4 & 1 \\ 0.2 & 0.7 & 1 \\ 0.3 & 0.3 & 1 \\ 0.4 & 0.6 & 1 \\ 0.6 & 0.2 & 1 \\ 0.7 & 0.4 & 1 \\ 0.8 & 0.6 & 1 \\ 0.7 & 0.5 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ -1 \\ -1 \\ -1 \\ -1 \\ -1 \end{bmatrix} = \underline{y}$$

$$\blacktriangleright \quad X^T X = \begin{bmatrix} 2.8 & 2.24 & 4.8 \\ 2.24 & 2.41 & 4.7 \\ 4.8 & 4.7 & 10 \end{bmatrix}, \quad X^T \underline{y} = \begin{bmatrix} -1.6 \\ 0.1 \\ 0.0 \end{bmatrix}$$

$$\underline{w} = (X^T X)^{-1} X^T \underline{y} = \begin{bmatrix} -3.13 \\ 0.24 \\ 1.34 \end{bmatrix}$$

❖ The Bias – Variance Dilemma

A classifier $g(\underline{x})$ is a **learning machine** that tries to **predict** the class label y of \underline{x} . In practice, a **finite** data set D is used for its training. Let us write $g(\underline{x}; D)$. Observe that:

- For **some** training sets, $D = \{(y_i, \underline{x}_i), i = 1, 2, \dots, N\}$, the training may result to good estimates, for **some others** the result may be worse.
- The average performance of the classifier can be tested against the MSE optimal value, in the mean squares sense, that is:

$$E_D \left[\left(g(\underline{x}; D) - E[y | \underline{x}] \right)^2 \right]$$

where E_D is the mean over all possible data sets D .

- The above is written as:

$$E_D \left[\left(g(\underline{x}; D) - E[y | \underline{x}] \right)^2 \right] = \\ \left(E_D [g(\underline{x}; D)] - E[y | \underline{x}] \right)^2 + E_D \left[\left(g(\underline{x}; D) - E_D [g(\underline{x}; D)] \right)^2 \right]$$

- In the above, the **first** term is the contribution of the **bias** and the second term is the contribution of the **variance**.
- For a finite D , there is a trade-off between the two terms. **Increasing bias it reduces variance and vice versa**. This is known as **the bias-variance dilemma**.
- Using a **complex** model results in **low-bias** but a **high variance**, as one changes from one training set to another. Using a **simple** model results in **high bias** but **low variance**.

❖ LOGISTIC DISCRIMINATION

- Let an M -class task, $\omega_1, \omega_2, \dots, \omega_M$. In logistic discrimination, the logarithm of the **likelihood ratios** are modeled via **linear** functions, i.e.,

$$\ln\left(\frac{P(\omega_i | \underline{x})}{P(\omega_M | \underline{x})}\right) = w_{i,0} + \underline{w}_i^T \underline{x}, \quad i = 1, 2, \dots, M-1$$

- Taking into account that

$$\sum_{i=1}^M P(\omega_i | \underline{x}) = 1$$

it can be easily shown that the above is equivalent with modeling posterior probabilities as:

$$P(\omega_M | \underline{x}) = \frac{1}{1 + \sum_{i=1}^{M-1} \exp(w_{i,0} + \underline{w}_i^T \underline{x})}$$

$$P(\omega_i | \underline{x}) = \frac{\exp(w_{i,0} + \underline{w}_i^T \underline{x})}{1 + \sum_{i=1}^{M-1} \exp(w_{i,0} + \underline{w}_i^T \underline{x})}, i = 1, 2, \dots, M-1$$

➤ For the two-class case it turns out that

$$P(\omega_2 | \underline{x}) = \frac{1}{1 + \exp(w_0 + \underline{w}^T \underline{x})}$$

$$P(\omega_1 | \underline{x}) = \frac{\exp(w_0 + \underline{w}^T \underline{x})}{1 + \exp(w_0 + \underline{w}^T \underline{x})}$$

- The unknown parameters $\underline{w}_i, w_{i,0}, i = 1, 2, \dots, M-1$ are usually estimated by **maximum likelihood** arguments.
- Logistic discrimination is a useful tool, since it allows linear modeling and at the same time **ensures** posterior probabilities **to add to one**.

3.7 طبقه بندی ماشین بردار پشتیبان Support Vector Machine (SVM)


3.7.1: کلاس های جدایی پذیر خطی Seperable Classes

فرض کنید N بردار آموزشی x_1, x_2, \dots, x_N از دو کلاس ω_1 و ω_2 جدایی پذیر خطی

هدف: طراحی ابرصفحه ای که تمامی بردارهای آموزشی را به درستی طبقه بندی کند.

$$g(x) = w^T x + w_0 = 0$$

همانگونه که قبلاً گفته شد این ابرصفحه که الگوریتم پیدا میکند برای مثال الگوریتم پرسپکتیو به سبب این که این ابرصفحه ها همگرا می شوند.



generalization performance

6 دایمی تقسیم یافته

❖ Support Vector Machines

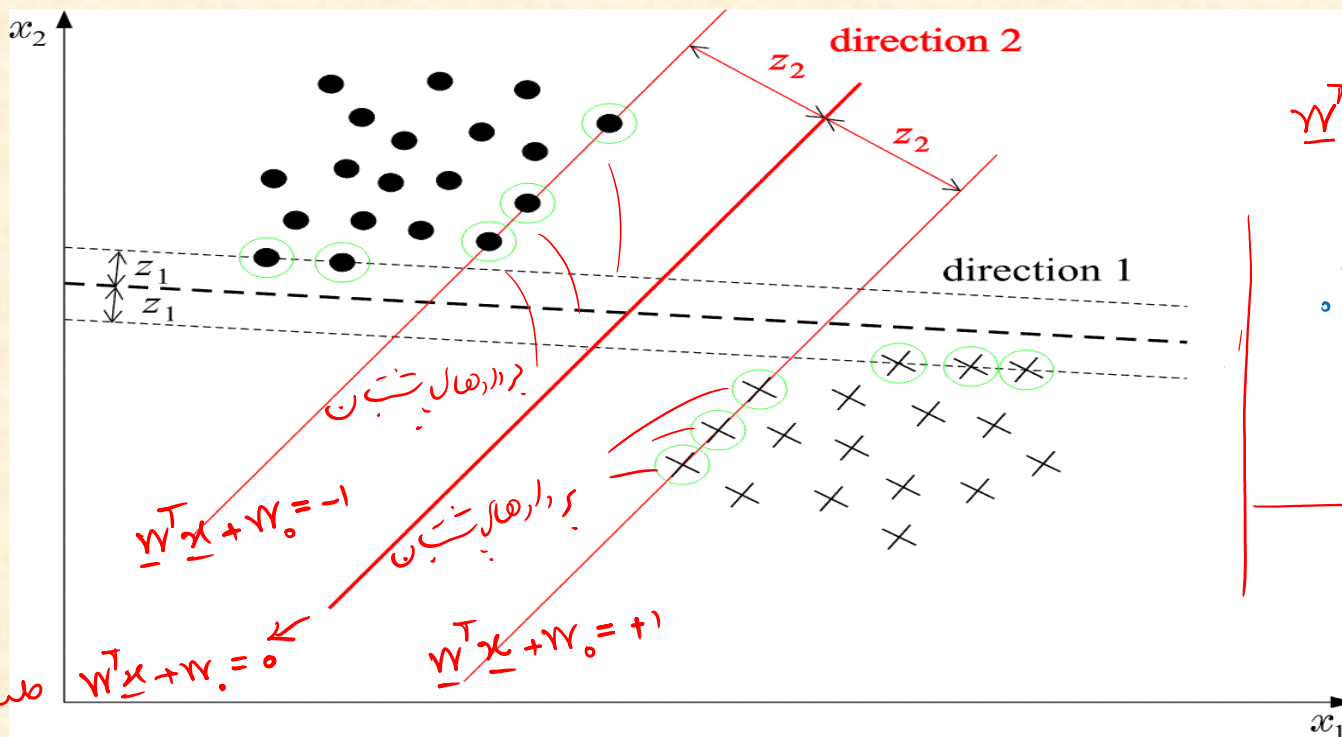
- The goal: Given two linearly separable classes, design the classifier

$$g(\underline{x}) = \underline{w}^T \underline{x} + w_0 = 0$$


margin
 SVM برای کلاس بیشترین حاشیه را می‌سازد
 عمل می‌کند

that leaves the **maximum margin** from both classes

100% → { 70% → Train
 30% → Test + Overfit
 70%
 30%
 cross validation



$$\underline{w}^T \underline{x} + w_0 = 0$$



➤ **Margin:** Each hyperplane is characterized by

- Its direction in space, i.e., \underline{w}
- Its position in space, i.e., w_0
- For **EACH** direction, \underline{w} , choose the hyperplane that **leaves the SAME distance** from the **nearest** points from each class. The margin is twice this distance.

- The distance of a point \hat{x} from a hyperplane is given by

$$z_{\hat{x}} = \frac{g(\hat{x})}{\|\underline{w}\|}$$

فاصله نقطه \hat{x} از صفحه: $g(\underline{x}) = 0$
 $g(\underline{x}) = \underline{w}^T \underline{x} + w_0 = 0$

- Scale, \underline{w} , w_0 , so that at the **nearest points** from each class the discriminant function is ± 1 :

$$|g(\underline{x})| = 1 \quad \{g(\underline{x}) = +1 \text{ for } \omega_1 \text{ and } g(\underline{x}) = -1 \text{ for } \omega_2\}$$

\underline{w} و w_0 را طوری مقیاس دهی که کمینه فاصله از هر دو کلاس مقدار ± 1 داشته باشند.

- Thus the **margin** is given by

$$\frac{1}{\|\underline{w}\|} + \frac{1}{\|\underline{w}\|} = \frac{2}{\|\underline{w}\|}$$

- Also, the following is valid

$$\underline{w}^T \underline{x} + w_0 \geq 1 \quad \forall \underline{x} \in \omega_1$$

$$\underline{w}^T \underline{x} + w_0 \leq -1 \quad \forall \underline{x} \in \omega_2$$

➤ SVM (linear) classifier

پهینه سازی مقید

$$g(\underline{x}) = \underline{w}^T \underline{x} + w_0$$

maximize $\frac{2}{\|\underline{w}\|}$

➤ Minimize

$$J(\underline{w}) = \frac{1}{2} \|\underline{w}\|^2$$

➤ Subject to

پهینه سازی مقید → $y_i (\underline{w}^T \underline{x}_i + w_0) \geq 1, i = 1, 2, \dots, N$

$$y_i = 1, \text{ for } \underline{x}_i \in \omega_1,$$

$$y_i = -1, \text{ for } \underline{x}_i \in \omega_2$$

➤ The above is justified since by minimizing $\|\underline{w}\|$

the margin $\frac{2}{\|\underline{w}\|}$ is maximised

- The above is a **quadratic optimization task**, subject to a set of linear inequality constraints. The **Karush-Kuhn-Tucker** conditions state that the **minimizer** satisfies:

KKT

پسوت (c)

- (1) $\frac{\partial}{\partial \underline{w}} L(\underline{w}, w_0, \underline{\lambda}) = \underline{0}$ تبع لاگرانژ
- (2) $\frac{\partial}{\partial w_0} L(\underline{w}, w_0, \underline{\lambda}) = 0$ ضرب لاگرانژ
- (3) $\lambda_i \geq 0, i = 1, 2, \dots, N$
- (4) $\lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1] = 0, i = 1, 2, \dots, N$
- Where $L(\bullet, \bullet, \bullet)$ is the **Lagrangian**

$$L(\underline{w}, w_0, \underline{\lambda}) \equiv \frac{1}{2} \underline{w}^T \underline{w} - \sum_{i=1}^N \lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1]$$

➤ The solution: from the above, it turns out that

- $$\underline{w} = \sum_{i=1}^N \lambda_i y_i \underline{x}_i$$

- $$\sum_{i=1}^N \lambda_i y_i = 0$$

➤ Remarks:

- The **Lagrange multipliers** can be either **zero** or **positive**. Thus,

$$- \underline{w} = \sum_{i=1}^{N_s} \lambda_i y_i \underline{x}_i$$

where $N_s \leq N_0$, corresponding to **positive** Lagrange multipliers

- From constraint (4) above, i.e.,

$$\lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1] = 0, \quad i = 1, 2, \dots, N$$

the vectors contributing to \underline{w} satisfy

$$\underline{w}^T \underline{x}_i + w_0 = \pm 1$$

- These vectors are known as **SUPPORT VECTORS** and are the **closest vectors**, from each class, to the classifier.
- Once \underline{w} is computed, w_0 is determined from conditions (4).
- The optimal hyperplane classifier of a support vector machine is **UNIQUE**.
- Although the solution is unique, the resulting Lagrange multipliers are **not** unique.

➤ Dual Problem Formulation

- The SVM formulation is a convex programming problem, with
 - Convex cost function
 - Convex region of feasible solutions
- Thus, its solution can be achieved by its dual problem, i.e.,

– maximize $L(\underline{w}, w_0, \underline{\lambda})$

– subject to

$$\underline{w} = \sum_{i=1}^N \lambda_i y_i \underline{x}_i$$

$$\sum_{i=1}^N \lambda_i y_i = 0$$

$$\underline{\lambda} \geq \underline{0}$$

- Combine the above to obtain

– maximize $\underline{\lambda}$ $(\sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{ij} \lambda_i \lambda_j y_i y_j \underline{x}_i^T \underline{x}_j)$

– subject to

$$\sum_{i=1}^N \lambda_i y_i = 0$$

$$\underline{\lambda} \geq \underline{0}$$


➤ Remarks:

- Support vectors enter via **inner products**

➤ Non-Separable classes

حالت دوام: کلاس های جدایی ناپذیر خطی:

در این حالت از آنجایی که هیچ ابرصفحه ای وجود ندارد که کلاس ها را از یکدیگر جدا کند، همواره نمونه های به اشتباه طبقه بندی می شوند.



داخل حاشیه ها ، تعدادی نمونه قرار گرفته اند :

سه دسته بردارهای y :

۱- بردارهای که خارج از باند قرار گرفته اند و به ارسطی طبقه بندی شده اند .

۲- بردارهای که داخل باند قرار گرفته اند و درست طبقه بندی شده اند (\square) و مدارله زیر را برآورده می کنند :

$$1 < y_j (\underline{w}^T x + w_0) \leq 0$$

۳- بردارهای که داخل باند قرار گرفته اند و به اشتباه طبقه بندی شده اند (\circ) و مدارله زیر را برآورده می کنند :

$$y_j (\underline{w}^T x + w_0) < 0$$

فرضه دسته را می توانیم با رابطه زیر بیان کرد :

$$z_j = 1 - y_j | \underline{w}^T x + w_0 |$$

به y_j ها مقیاسهای black گفته می شود .

$$\left. \begin{array}{l} \text{برای دسته اول : } z_j = 0 \\ \text{برای دسته دوم : } 0 < z_j \leq 1 \\ \text{برای دسته سوم : } z_j > 1 \end{array} \right\}$$

In this case, there is no hyperplane such that

$$\underline{w}^T \underline{x} + w_0 (><)1, \quad \forall \underline{x}$$

- Recall that the margin is defined as twice the distance between the following two hyperplanes

$$\underline{w}^T \underline{x} + w_0 = 1$$

and

$$\underline{w}^T \underline{x} + w_0 = -1$$

➤ The training vectors belong to one of three possible categories

1) Vectors **outside** the band which are **correctly** classified, i.e.,

$$y_i(\underline{w}^T \underline{x} + w_0) > 1$$

2) Vectors **inside** the band, and **correctly** classified, i.e.,

$$0 \leq y_i(\underline{w}^T \underline{x} + w_0) < 1$$

3) Vectors **misclassified**, i.e.,

$$y_i(\underline{w}^T \underline{x} + w_0) < 0$$

➤ All three cases above can be represented as

$$y_i(\underline{w}^T \underline{x} + w_0) \geq 1 - \xi_i$$

- 1) $\rightarrow \xi_i = 0$
- 2) $\rightarrow 0 < \xi_i \leq 1$
- 3) $\rightarrow 1 < \xi_i$

ξ_i are known as **slack variables**

➤ The goal of the optimization is now two-fold

- Maximize margin ۱- بیشینه کردن حاشیه هدف در این حالت:
- Minimize the number of patterns with $\xi_i > 0$,

One way to achieve this goal is via the cost

$$J(\underline{w}, w_0, \underline{\xi}) = \frac{1}{2} \|\underline{w}\|^2 + C \sum_{i=1}^N I(\xi_i)$$
۲- کمینه کردن تعداد نمونه های که

where C is a constant and

$\xi_i > 0$ دارند. (داخل یا بیرون کره)

$$I(\xi_i) = \begin{cases} 1 & \xi_i > 0 \\ 0 & \xi_i = 0 \end{cases}$$
تعداد نمونه های داخل یا بیرون کره

Regularization Parameter

$I(\cdot)$ is not differentiable. In practice, we use an approximation پارامتر C (پارامتر تنظیم) ثابت نیست است که پارامتر تنظیمی در این حالت

بیشینه سازی این تابع هزینه به دلیل ناپوشتمند در نتیجه دستور است بسیار این در عمل متداول است که

- $J(\underline{w}, w_0, \underline{\xi}) = \frac{1}{2} \|\underline{w}\|^2 + C \sum_{i=1}^N \xi_i$ به جای آن از توابع تقریبی استفاده شود:

• Following a similar procedure as before we obtain

► KKT conditions

حالت نه :

$$(1) \underline{w} = \sum_{i=1}^N \lambda_i y_i \underline{x}_i$$

$$(2) \sum_{i=1}^N \lambda_i y_i = 0$$

$$(3) C - \mu_i - \lambda_i = 0, i = 1, 2, \dots, N$$

$$(4) \lambda_i [y_i (\underline{w}^T \underline{x}_i + w_0) - 1 + \xi_i] = 0, i = 1, 2, \dots, N$$

$$(5) \mu_i \xi_i = 0, i = 1, 2, \dots, N$$

$$(6) \mu_i, \lambda_i \geq 0, i = 1, 2, \dots, N$$

➤ The associated dual problem

Maximize $\underline{\lambda} \left(\sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j \underline{x}_i^T \underline{x}_j \right)$

subject to

$$0 \leq \lambda_i \leq C, \quad i = 1, 2, \dots, N$$

$$\sum_{i=1}^N \lambda_i y_i = 0$$

➤ Remarks:


The only difference with the separable class case is the existence of C in the constraints

➤ Training the SVM

A major problem is the high computational cost. To this end, decomposition techniques are used. The rationale behind them consists of the following:

- Start with an arbitrary data subset (**working set**) that can fit in the memory. Perform optimization, via a general purpose optimizer.
- Resulting support vectors **remain** in the working set, while others are replaced by new ones (outside the set) that violate severely the KKT conditions.
- Repeat the procedure.
- The above procedure guarantees that the cost function decreases.
- Platt's **SMO algorithm** chooses a working set of two samples, thus **analytic** optimization solution can be obtained.

- مسئله M طبقه:



➤ Multi-class generalization

One against All:

Although theoretical generalizations exist, the most popular in practice is to look at the problem as M two-class problems (one against all).

- یکی در برابر همه:

One against One:

Binary Classifiers

شماره تعداد زیر طبقه بندیها

برای هر دو دسته یک طبقه بندی طراحی نکنیم

تعداد طبقه بندیها: $\frac{M(M-1)}{2}$

$\binom{M}{2}$

در این حالت برای هر یک از دسته ها دسته م را می تابع جدا شده می بیند $g_i(x)$ هستیم
 $g_i(x) > g_j(x)$; $i=1, \dots, M$; $\forall j \neq i$; $\forall x \in \mathcal{X}$
 یعنی در برابر دیگری


$g(x) = 0$; $\forall M$; w را از همه دسته های رسم
 جدا کنیم $i = \arg \max_k [g_k(x)]$
 assign x in w_i ; $\forall i$

دو مشکل: ۱- توابع نامشخص: توابعی که چند $g_i(x)$ دارند.

۲- آموزش نامتقارن asymmetric training

تعداد نمونه های متقی که نسبت بیشتر شود به M از تعداد دسته های زیاد

دسته ۱: ω_1
3.5



$w_1 = 1$
 $w_2 = w_0 = 0$

$\omega_1 : [1, 1]^T, [1, -1]^T$

$\omega_2 : [-1, 1]^T, [-1, -1]^T$

باردستی می خواهیم نشان دهیم

که خط $x_1 = 0$ از صفا

جدالنده است و این نتیجه به ازای

مجموعه های مختلف از ضرایب لاگرانژ قابل

دستیابی است.

$g(\underline{x}) = w_1 x_1 + w_2 x_2 + w_0 = 0$

FIGURE 3.12

In this example all four points are support vectors. The margin associated with $g_1(\mathbf{x}) = 0$ is smaller compared to the margin defined by the optimal $g(\mathbf{x}) = 0$.

شرایط لازم:

$$w_1 + w_2 + w_0 - 1 \geq 0$$

$$w_1 - w_2 + w_0 - 1 \geq 0$$

$$w_1 - w_2 - w_0 - 1 \geq 0$$

$$w_1 + w_2 - w_0 - 1 \geq 0$$

$$\mathcal{L}(w_1, w_2, w_0, \lambda) = \frac{w_1^2 + w_2^2}{2} - \lambda_1 (w_1 + w_2 + w_0 - 1) - \lambda_2 (w_1 - w_2 + w_0 - 1) - \lambda_3 (w_1 - w_2 - w_0 - 1) - \lambda_4 (w_1 + w_2 - w_0 - 1)$$

KKT:

$$\frac{\partial \mathcal{L}}{\partial w_1} = 0 \rightarrow w_1 = \lambda_1 + \lambda_2 + \lambda_3 + \lambda_4$$

$$\frac{\partial \mathcal{L}}{\partial w_2} = 0 \rightarrow w_2 = \lambda_1 - \lambda_2 - \lambda_3 + \lambda_4$$

$$\frac{\partial \mathcal{L}}{\partial w_0} = 0 \rightarrow \lambda_1 + \lambda_2 - \lambda_3 - \lambda_4 = 0$$

$$\lambda_1 (w_1 + w_2 + w_0 - 1) = 0$$

$$\lambda_2 (w_1 - w_2 + w_0 - 1) = 0$$

$$\lambda_3 (w_1 - w_2 - w_0 - 1) = 0$$

$$\lambda_4 (w_1 + w_2 - w_0 - 1) = 0$$

$$\lambda_1, \lambda_2, \lambda_3, \lambda_4 \geq 0$$

$$w_1 = 1$$

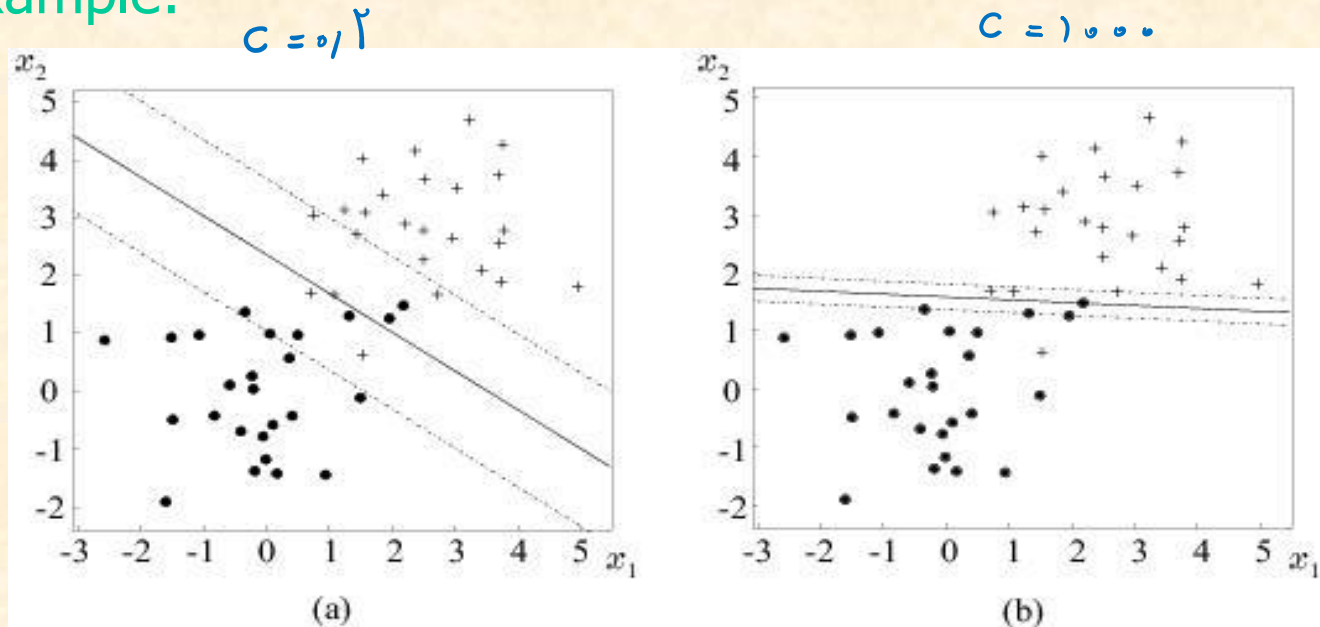
$$w_2 = w_0 = 0$$

$$\begin{cases} \lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 = 1 \\ \lambda_1 - \lambda_2 - \lambda_3 + \lambda_4 = 0 \\ \lambda_1 + \lambda_2 - \lambda_3 - \lambda_4 = 0 \end{cases}$$

پس جواب

تبدیل: تأثیر پارامتر تنظیم C در حالت جدایی ناپذیر خطی

➤ Example:



➤ Observe the effect of different values of C in the case of non-separable classes.

C کمتر \leftarrow margin بیشتر
 C بیشتر \leftarrow فاصله کمترینها را اصل پابند کمتر