


شناسایی آماری الگو  
بخش ششم  
(۰۱-۷۱۱-۱۰-۱۴۱)



دانشگاه شهید بهشتی  
پژوهشکده‌ی فضای مجازی  
بهار ۱۳۹۶  
احمد محمودی ازناوه

# فهرست مطالب

- ماشین بردار پشتیبان (SVM)
  - تاریخچه
  - معرفی
  - داده‌های جدایی‌پذیر خطی
- Soft Margin
- مجموعه‌های جدایی‌ناپذیر خطی
  - نگاهت به فضای با ابعاد بالا
  - Inner product kernel
- مثال XOR
- Matlab در SVM




# تاریخچه

- نسخه‌ی اولیه‌ی SVM توسط آقای Vladimir Vapnik ارائه شد.
- Vapnik با همکاری خانم Corinna Cortes استاندارد کنونی SVM را در سال ۱۹۹۳ پایه‌ریزی کرده و در سال ۱۹۹۵ منتشر نمودند.

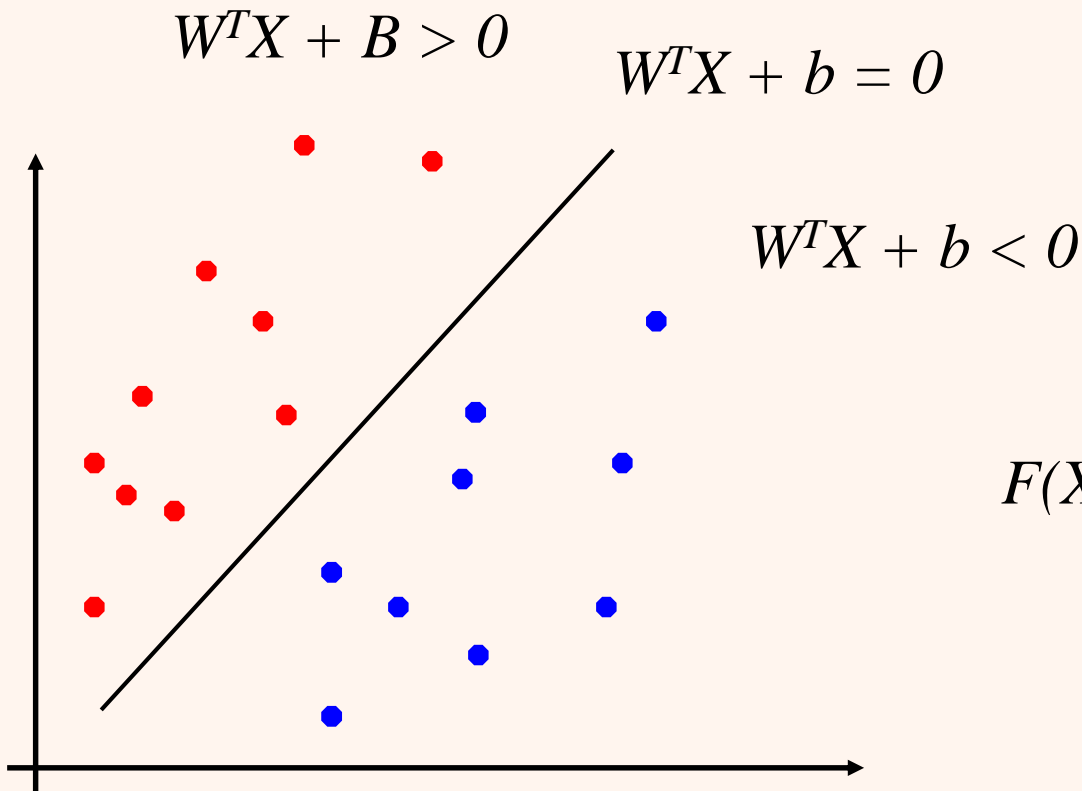


**Cortes, C. and V. Vapnik (1995). "Support-vector networks." Machine Learning 20(3): 273-297.**



# معرفی

- یک جداکننده خطی را می‌توان همانند شکل زیر در نظر گرفت.




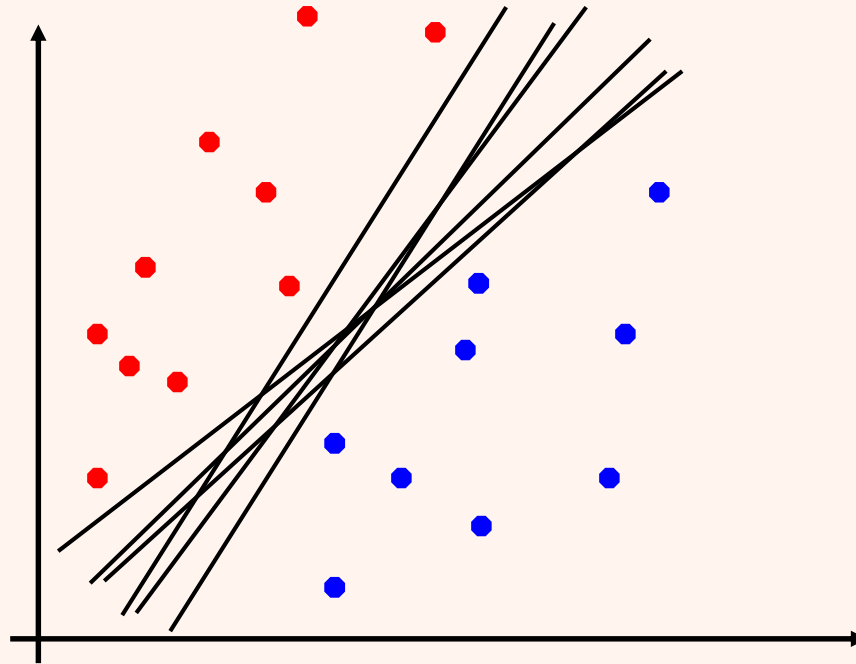
$$F(X) = \text{SIGN}(W^T X + b)$$



# مرز بهینه

## • سوال

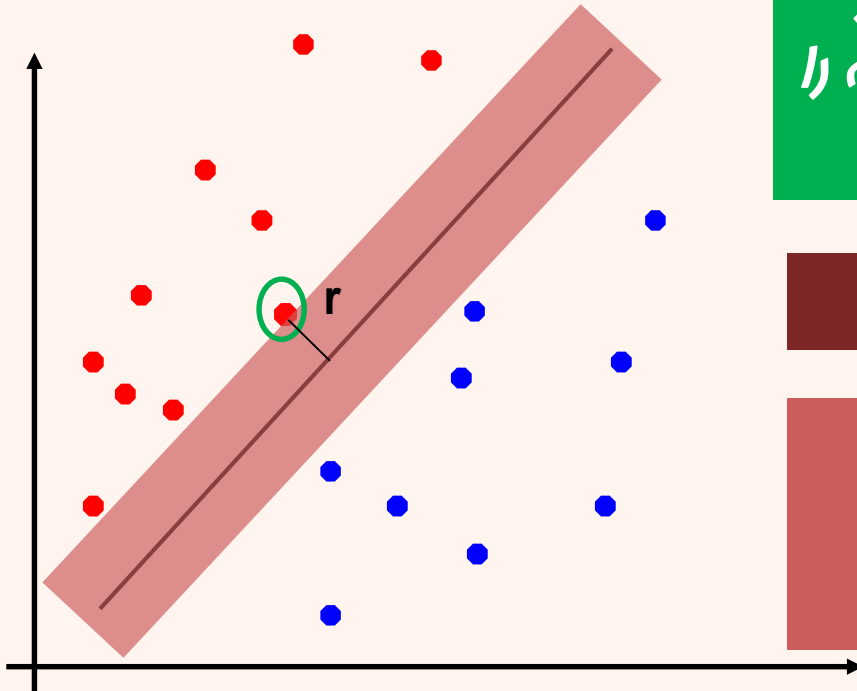
– کدام یک از مرزها، مرزی بهینه برای جداسازی است؟



# مرز جداسازی

- می‌خواهیم به گونه‌ای بهترین مرز جداسازی را به دست آوریم.

Margin of separation



فرض کنیم نزدیک‌ترین نقطه به مرز جداسازی در نظر گرفته شده و فاصله را  $r$  بنامیم.


هدف ماکزیم نمودن  $r$  است.

یک ماشیه مشخص می‌کنیم هر مرزی که ماشیهی پهن‌تری را نتیجه دهد، بهتر است.

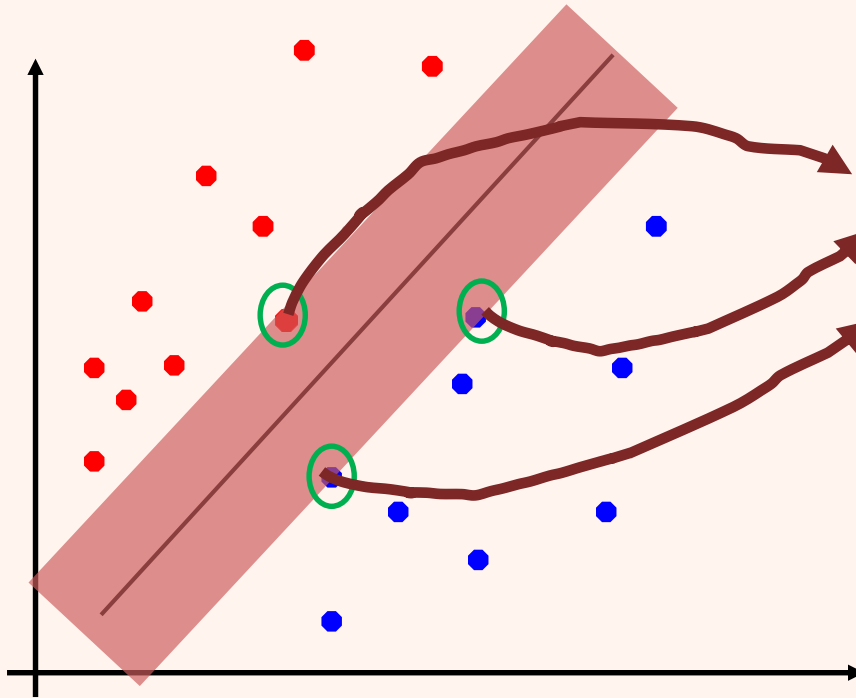
دانشگاه  
تهران  
بهشتی

# ماشین‌های ماکزیمم

- ماکزیمم نمودن ماشینیه (Margin) ایده‌ی خوبی است جهت جداسازی خطی، این شیوه را **LSVM** یا **Linear SVM** می‌نامند.
- در این حالت نمونه‌هایی که به روی مرز ماشینیه هستند، از اهمیت ویژه‌ای برخوردارند.
- بدین وسیله می‌توان از نمونه‌های دیگر صرف‌نظر کرد و تنها به نمونه‌های مهم روی مرز ماشینیه پرداخت.




- به نمونه‌های روی مرز ماشیه «بردار پشتیبان» می‌گویند.



بردارهای پشتیبان

Optimal hyperplane





# مرز جداسازی

- برای معادله‌ی مرز جداسازی داشتیم:


$$W^T X + b = 0$$

$$(X_i, d_i = +1) \quad W^T X_i + b > 0$$

$$(X_i, d_i = -1) \quad W^T X_i + b < 0$$

- فرض کنیم مرز بهینه توسط  $W_{op}$  و  $b_{op}$  مشخص شود.

- فرض: فرض کنیم نزدیک‌ترین نقطه به مرز جداسازی را در نظر گرفته، فاصله را « $r$ » بنامیم.



# مرز جداسازی (ادامه...)

## • هدف


- ماکزیمم نمودن فاصله یا همان  $\rho=2r$  است.
- برای نقاط روی مرز جداسازی بهینه داریم:

$$W_{op}^T X + b_{op} = 0$$

- برای نقاط خارج از مرز داریم:

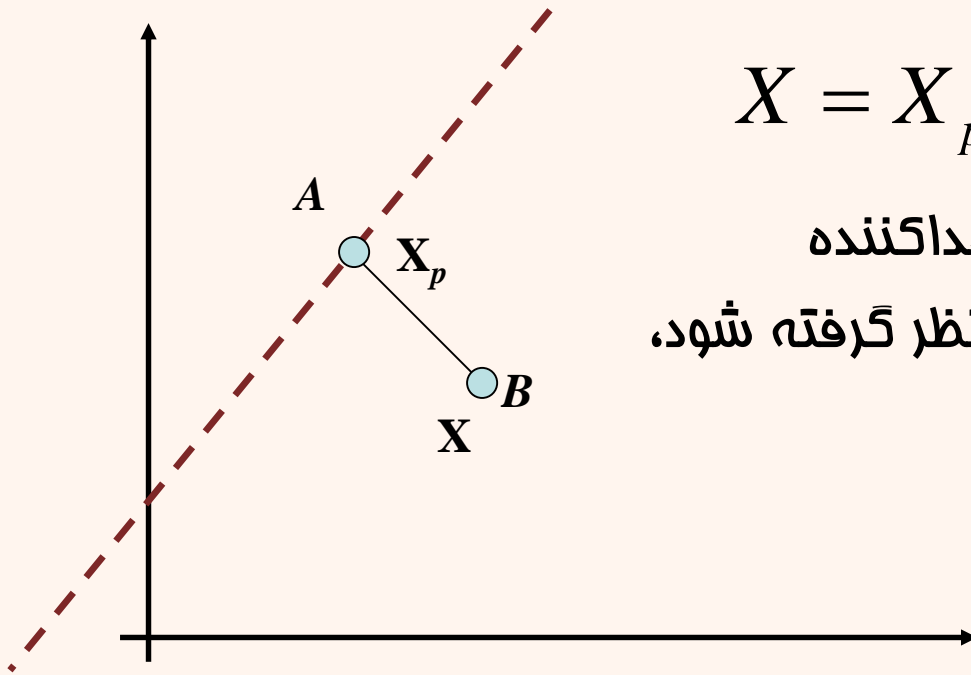
$$g(X) = W_{op}^T X + b_{op}$$

- $g(X)$  می‌تواند مثبت یا منفی باشد.



# مرز جداسازی (ادامه...)

- در صورتی که  $X$  بردار پشتیبان باشد، طبق شکل زیر خواهیم داشت:




$$X = X_p + \overrightarrow{AB}$$

- $AB$  در جهت عمود بر مرز جداکننده
- اگر اندازهی بردار  $AB=r$  در نظر گرفته شود، خواهیم داشت:

$$X = X_p + r \frac{W_{op}}{\|W_{op}\|}$$

$$\overrightarrow{AB} = r \frac{W_{op}}{\|W_{op}\|}$$



# مرز جداسازی (ادامه...)

$$g(X) = W_{op}^T X + b_{op}$$

• داشتهیم:

$$X = X_p + r \frac{W_{op}}{\|W_{op}\|}$$


$$g(X) = W_{op}^T \left[ X_p + r \frac{W_{op}}{\|W_{op}\|} \right] + b_{op}$$

$$g(X) = \underbrace{W_{op}^T X_p + b_{op}}_{\text{روی مرز پس برابر با صفر}} + r \frac{W_{op}}{\|W_{op}\|} W_{op}^T$$

روی مرز پس برابر با صفر

$$g(X) = r \frac{\|W_{op}\|^2}{\|W_{op}\|}$$

$$g(X) = r \|W_{op}\|$$



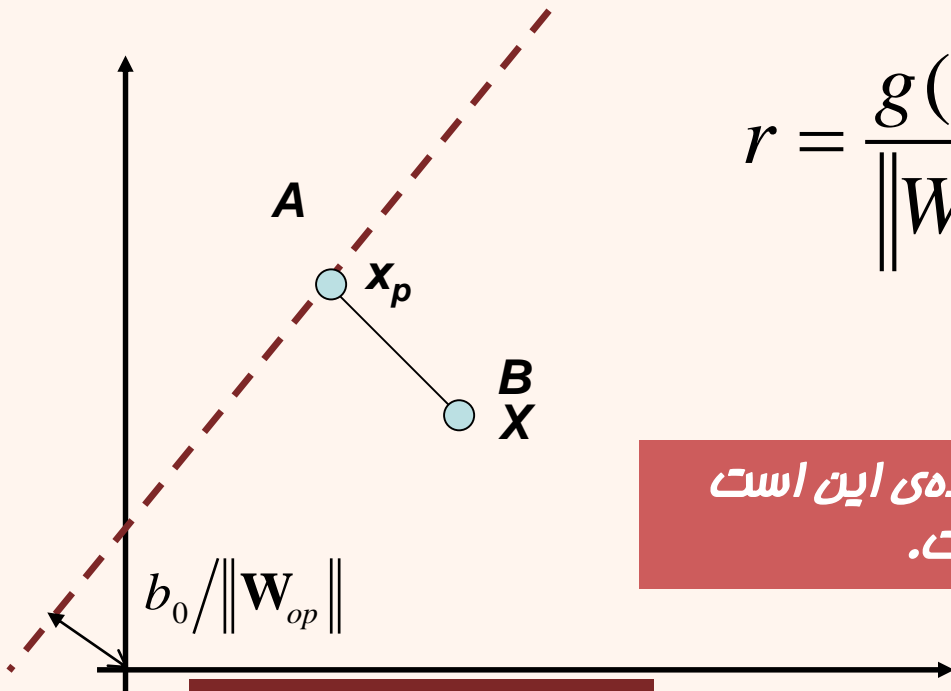
# مرز جداسازی (ادامه...)

$$g(X) = r \|W_{op}\|$$

هدف ماکزیمم نمودن  $r$  است.


در این حالت تمت شرایطی میباید  $W$  کمینه گردد.

$$r = \frac{g(X)}{\|W_{op}\|}$$



$$X=0$$
$$r = \frac{g(X)}{\|W_{op}\|} = \frac{b_{op}}{\|W_{op}\|}$$

مثبت یا منفی بودن  $b_{op}$  نشان دهندهی این است که مبدأ در کدام سمت خط مرزی است.



دانشگاه شهید بهشتی

فاصله از مبدأ مختصات

# مرز جداسازی (ادامه...)

مساله یافتن  $W_{op}$  و  $b_{op}$  است

• جداساز خطی را به صورت زیر در نظر می‌گیریم:

$$(X_i, +1) \quad W_{op}^T X_i + b_{op} \geq 1 \quad \text{for } d_i = +1$$

$$(X_i, -1) \quad W_{op}^T X_i + b_{op} \leq -1 \quad \text{for } d_i = -1$$


به صورت کلی داریم:

$$d_i (W_{op}^T X + b_{op}) \geq 1$$

• رابطه‌ی بالا برای تمامی الگوهای آموزشی برقرار است.

• و در نتیجه برای بردارهای پشتیبان

$$g(X^s) = W_{op}^T X^s + b_{op} = \pm 1$$




# مرز جداسازی (ادامه...)

$$g(X^s) = W_{op}^T X^s + b_{op} = \pm 1$$

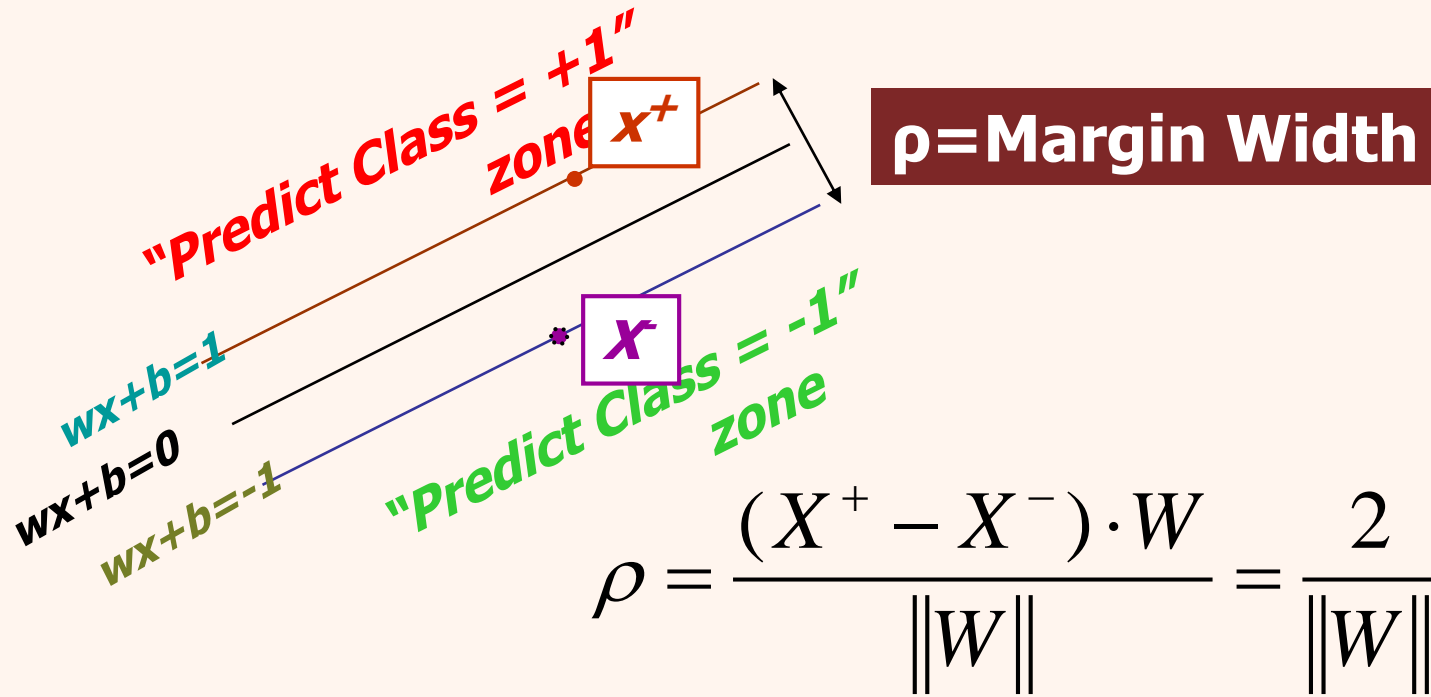
$$r = \frac{g(X^s)}{\|W_{op}\|} = \begin{cases} \frac{1}{\|W_{op}\|} \\ -\frac{1}{\|W_{op}\|} \end{cases}$$

- در نتیجه فاصله‌ی دو بردار پشتیبان در دو طرف مرز:

$$\rho = 2r = \frac{2}{\|W_{op}\|}$$




# جدایی پذیر خطی



می دانیم:

- $W \cdot X^+ + b = +1$
- $W \cdot X^- + b = -1$
- $W \cdot (X^+ - X^-) = 2$





# جدایی پذیر خطی

$$\rho = 2r = \frac{\|\pm 2\|}{\|W_{op}\|}$$

- با توجه به دو رابطه‌ی
- $d_i(W_{op}^T X + b_{op}) \geq 1$  به این نتیجه می‌رسیم که  $W_{op}$  می‌باید مینیمم گردد.

- این مسأله معادل مینیمم کردن


$$\Phi(W) = \frac{1}{2} W^T W$$

–  $\Phi$  یک تابع محدب (Convex Function) است.

– طبق رابطه‌ی  $d_i(W_{op}^T X_i + b_{op}) \geq 1$  برای  $N$  الگوی آموزشی شرط زیر می‌باید برقرار باشد:

$$\sum_{i=1}^N [d_i(W_{op}^T X_i + b_{op}) - 1]$$


این میزان بزرگ‌تر یا مساوی صفر است



وزن‌ها و بایاس را به گونه‌ای بیابید که:

$$\rho = \frac{2}{\|W\|} \text{ is maximized}$$

and for all  $(X_i, d_i), i=1..n : d_i(W^T X_i + b) \geq 1$



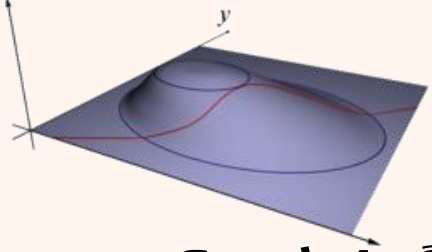
وزن‌ها و بایاس را به گونه‌ای بیابید که:

$$\Phi(W) = 1/2 \|W\|^2 = 1/2 W^T W \text{ is minimized}$$

and for all  $(X_i, d_i), i=1..n : d_i (W^T X_i + b) \geq 1$



# یافتن رویه‌ی بهینه



- رابطه‌ی لاگرانژ زیر تعریف می‌شود به گونه‌ای که هر دو قید ذکر شده را پوشش دهد:

$$J(W, b, \alpha) = \frac{1}{2} W^T W - \sum_{i=1}^N \alpha_i [d_i (W^T X_i + b) - 1]$$

**Lagrange multiplier (nonnegative)**

- برای به دست آوردن  $W_{op}$  و  $b_{op}$  نسبت به هر دو مشتق می‌گیریم.

$$\frac{\partial J}{\partial W} = 0 \Rightarrow W - \sum_{i=1}^N \alpha_i d_i X_i = 0$$


$$W_{op} = \sum_{i=1}^N \alpha_i d_i X_i$$

$$\frac{\partial J}{\partial b} = 0 \Rightarrow -\sum_{i=1}^N \alpha_i d_i = 0$$

$b_{op}$  به دست نمی‌آید

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

ولی یک قید می‌دهد



# یافتن رویه‌ی بهینه

• دو شرط برای  $\alpha$  خواهیم داشت:

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

$$\alpha_i [d_i (W^T X_i + b) - 1] = 0$$

Karush–Kuhn–Tucker (KKT)  
condition of optimization theory


صفر

غیر صفر

• به ازای هر  $\alpha_i$  برای الگوهای آموزشی متناظر با SVها رابطه‌ی زیر برقرار است:

$$d_i (W_{op}^T X_i + b_{op}) - 1 = 0$$

• در نتیجه  $\alpha_i$  متناظر با بردارهای پشتیبان غیر صفر خواهد بود.



# یافتن رویه‌ی بهینه

$$J(W, b, \alpha) = \frac{1}{2} \|W\|^2 - \sum_{i=1}^N \alpha_i [d_i (W^T X_i + b) - 1]$$

$$J(W, b, \alpha) = \frac{1}{2} W^T W - \sum_{i=1}^N \alpha_i d_i W^T X_i - \sum_{i=1}^N \alpha_i d_i b + \sum_{i=1}^N \alpha_i$$

• برای مقادیر بهینه داشتیم:


$$W_{op} = \sum_{i=1}^N \alpha_i d_i X_i$$

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

**Duality theorem**

• پس خواهیم داشت:

$$J(W_{op}, b_{op}, \alpha) = \frac{1}{2} W_{op}^T W_{op} - W_{op}^T W_{op} + 0 + \sum_{i=1}^N \alpha_i$$




# Dual Problem

$$J(W_{op}, b_{op}, \alpha) = \frac{1}{2} W_{op}^T W_{op} - W_{op}^T W_{op} + 0 + \sum_{i=1}^N \alpha_i$$

$$\left\{ \begin{array}{l} = \sum_{i=1}^N \alpha_i - \frac{1}{2} W_{op}^T W_{op} \\ \sum_{i=1}^N \alpha_i d_i = 0 \end{array} \right. = Q(\alpha)$$


مینیمم نمودن  $W$  همانند ماکزیمم نمودن  $Q$  است زیرا در  $W_{op}$  مقدار  $W$  کمترین میزان است و در این صورت است که کل عبارت ماکزیمم می‌شود.



# یافتن رویه‌ی بهینه

$$\begin{aligned} Q(\alpha) &= \sum_{i=1}^N \alpha_i - \frac{1}{2} W_{op}^T W_{op} \\ &= \sum_{i=1}^N \alpha_i - \frac{1}{2} \left[ \sum_{i=1}^N \alpha_i d_i X_i \right]^T \left[ \sum_{j=1}^N \alpha_j d_j X_j \right] \\ &= \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i d_i \alpha_j d_j X_i^T X_j \end{aligned}$$

$$\left\{ \begin{aligned} &= \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i d_i \alpha_j d_j X_i^T X_j \\ &\sum_{i=1}^N \alpha_i d_i = 0 \\ &\alpha_i \geq 0 \text{ for } i = 0, 1, \dots, N \end{aligned} \right.$$



$\alpha_i$  ها وابسته به الگوهای  $X_i$ ،  $X_j$  و خروجی های مرتبط است

# یافتن رویه‌ی بهینه

$$= \sum_{i=1}^N \alpha_i - \frac{1}{2} \left[ \sum_{i=1}^N \alpha_i d_i X_i \right]^T \left[ \sum_{j=1}^N \alpha_j d_j X_j \right]$$

بدون در نظر گرفتن قيود، جهت مناسبی  $\alpha$  ها می‌توان نسبت به  $\alpha_k$  مشتق گرفته برابر با صفر قرار داد.


$$\frac{\partial Q(\alpha)}{\partial \alpha_k} = 1 - \sum_{\substack{i=1 \\ i \neq k}}^N \alpha_i d_i d_k X_i^T X_k - \alpha_k d_k^2 X_k^T X_k = 0$$

$$M_{i,j} = X_i^T X_j$$

ضرب داخلی

$N$  معادله و  $N$  مجهول

$$\frac{\partial Q(\alpha)}{\partial \alpha_k} = 1 - d_k \sum_{i=1}^N \alpha_i d_i M_{i,k} = 0$$








# یافتن رویه‌ی بهینه

- پس از به دست آوردن  $\alpha$  خواهیم داشت:

$$W_{op} = \sum_{i=1}^N \alpha_i d_i X_i$$

$X^s = X$  support vector   $W_{op}^T X^s + b_{op} = \pm 1$

  $b_{op} = \pm 1 - W_{op}^T X^s$



# یافتن رویه‌ی بهینه

$$W = \sum \alpha_i d_i X_i \quad b = d_k - W^T X_k \text{ for any } X_k \text{ such that } \alpha_k \neq 0$$


هر  $\alpha_i$  مخالف صفر، نشان‌دهنده‌ی این است که  $X_i$  متناظرش یک بردار پشتیبان است.  
در این حالت تابع جداکننده همانند زیر است:

$$g(X) = \sum \alpha_i d_i \underbrace{X_i^T X}_b + b$$

ضرب داخلی دو بردار


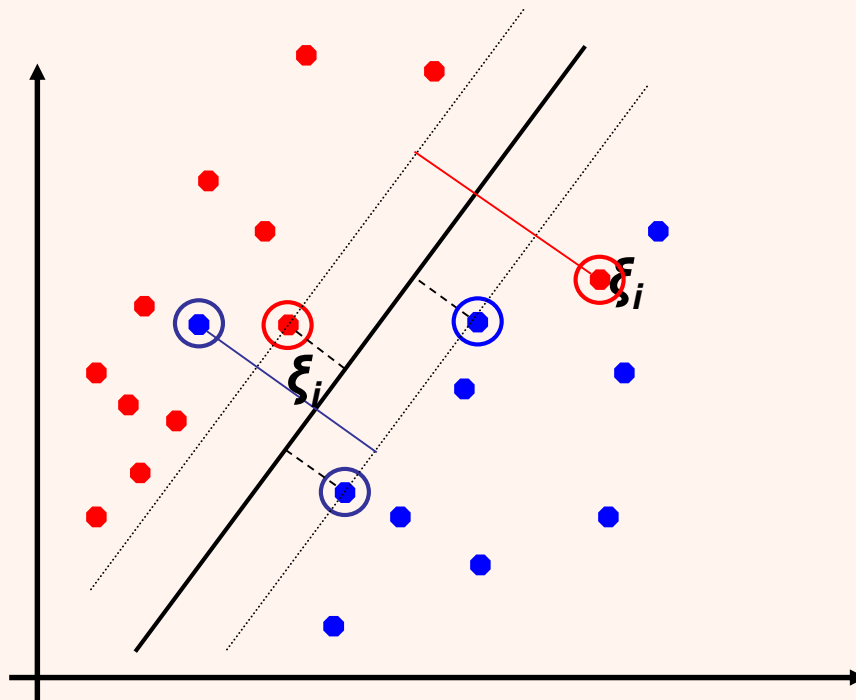
توجه:

حل مساله بهینه‌سازی وابسته به محاسبه ضرب داخلی بین تمامی نمونه‌های آموزشی است.



# Soft Margin

- SVM برای داده‌های جدایی‌پذیر خطی مورد بررسی قرار گرفت.
- حال اگر مجموعه‌ی داده‌های آموزش قابلیت جداسازی را نداشته باشند، چه خواهد شد؟ به بیان بهتر صحبت در مورد مسائل جدایی‌پذیر است که با نویز همراه هستند.



# Soft Margin

- مسأله‌ی **Hard Margin** را تبدیل به حل مسأله‌ی **Soft Margin** می‌شود.


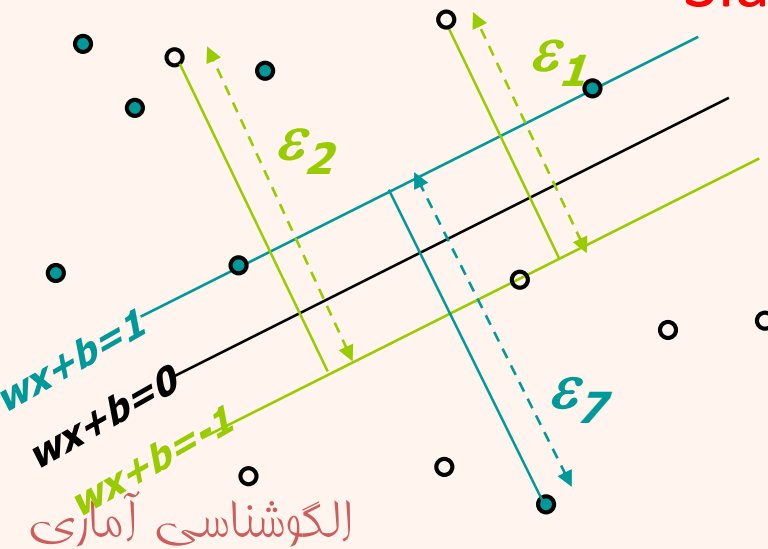
- ماشیهی جداسازی **soft** گفته می‌شود، در صورتی که برای برخی داده‌ها شرط زیر نقض شود:

$$d_i (W_{op}^T X + b_{op}) \geq 1$$

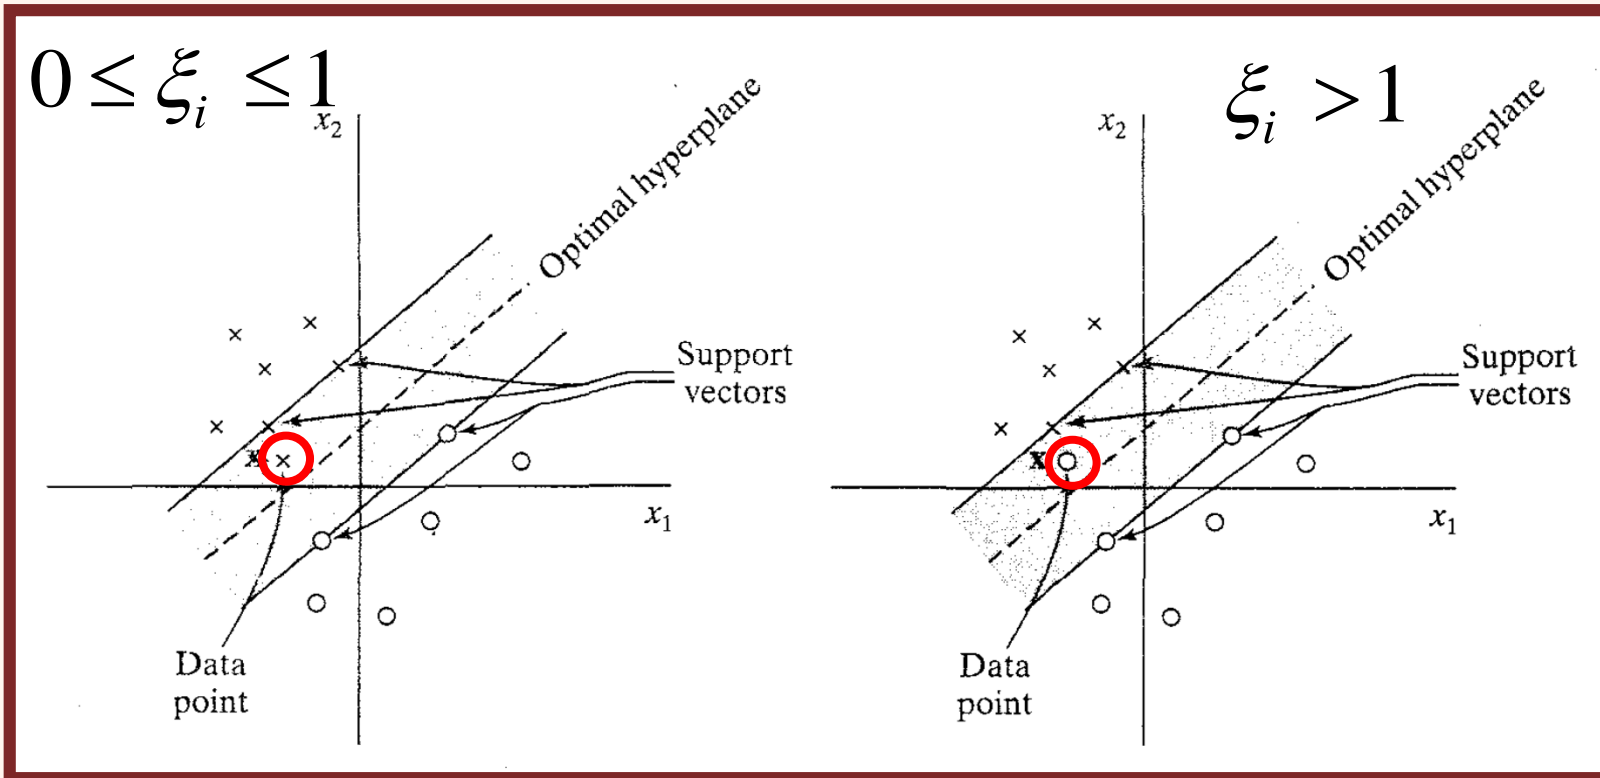
- با اضافه کردن یک **Slack Variable**

- مسأله را بار دیگر بررسی می‌کنیم.

- این متغیر میزان انحراف از شرط فوق را نشان می‌دهد.



# Soft Margin Classification



- دو حالت ممکن است رخ دهد:
- داده‌ی در کلاس درست ولی در ماشیه قرار گیرد.
- داده‌ی آموزشی به اشتباه دسته‌بندی شود.

$$d_i (W_{op}^T X + b_{op}) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N$$



# Soft Margin Classification


$$d_i(\mathbf{W}_{op}^T \mathbf{X} + b_{op}) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N$$

- در این حالت بردارهای پشتیبان آن‌هایی هستند که در رابطه‌ی تساوی در عبارت بالا صدق می‌کنند، حتی با وجود  $\xi > 0$

– در صورتی که داده‌های نویزی از مجموعه خارج شود، رویه‌ی جداکننده تخییر خواهد کرد.

- هدف یافتن «رویه‌ای جداکننده» است که در آن خطای طبقه‌بندی نادرست در آن مینیمم شود:

$$\Phi(\xi) = \sum_{i=1}^N I(\xi_i - 1) \quad I(\xi) = \begin{cases} 0 & \text{if } \xi \leq 0 \\ 1 & \text{if } \xi > 0 \end{cases}$$



# Soft Margin Classification

- با توجه به این که کمینه کردن چنین تابعی یک مسأله‌ی بهینه‌سازی **nonconvex** است و در رده‌ی NP-complete قرار می‌گیرد، آن را با تابع زیر تقریب می‌زنیم:

$$\Phi(\xi) = \sum_{i=1}^N \xi_i$$

- و در کل هدف می‌نیمیم کردن عبارت زیر است:

$$\Phi(W, \xi) = \frac{1}{2} W^T W + C \sum_{k=1}^R \xi_k$$

regularization parameter

این پارامتر نوعی مصالحه بین پیچیدگی ماشین و خطا برقرار می‌کند، هرچه **C** به صفر نزدیک‌تر باشد به این معناست که خطا اهمیت کم‌تری دارد و در نتیجه حاشیه بزرگ‌تر می‌شود. و هرچه بزرگ‌تر باشد، مساله به حالت **hard margin** نزدیک‌تر می‌شود.



# Soft Margin

- برای Hard Margin داشتیم:

Find  $W$  and  $b$  such that  
 $\Phi(W) = \frac{1}{2} W^T W$  is minimized and for all  $\{(X_i, d_i)\}$   
 $d_i (W^T X_i + b) \geq 1$

- با اضافه کردن Slack Variable داریم:

Find  $W$  and  $b$  such that  
 $\Phi(W) = \frac{1}{2} W^T W + C \sum \xi_i$  is minimized and for all  $\{(X_i, d_i)\}$   
 $d_i (W^T X_i + b) \geq 1 - \xi_i$  and  $\xi_i \geq 0$  for all  $i$






# یافتن رویه‌ی بهینه

- رابطه‌ی لاگرانژ زیر تعریف می‌شود به گونه‌ای که همه‌ی نیازمندی‌ها را پوشش دهد:

$$J(W, b, \xi, \alpha, \mu) = \frac{1}{2} W^T W + C \sum_i \xi_i - \sum_{i=1}^N \alpha_i [d_i (W^T X_i + b) - 1 + \xi_i] - \sum_i \mu_i \xi_i$$

- بخش آخر از این رو اضافه شده است که تا نامنفی بودن  $\xi$  را تضمین کند.



# Soft Margin Classification

در نهایت ضرایب لاگرانژ از عبارت زیر محاسبه خواهند شد:

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j X_i^T X_j$$


با در نظر گرفتن قیود زیر

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

$$0 \leq \alpha_i \leq C$$

بقیه مراحل مانند حالت قبل خواهد بود:

$$W_{op} = \sum_{i=1}^{N_s} \alpha_i d_i X_i$$



```

n = 20;
rand('seed',2);
X = 4* rand (2 ,n) ;
bt = -6;
wt = [4 ; -1];


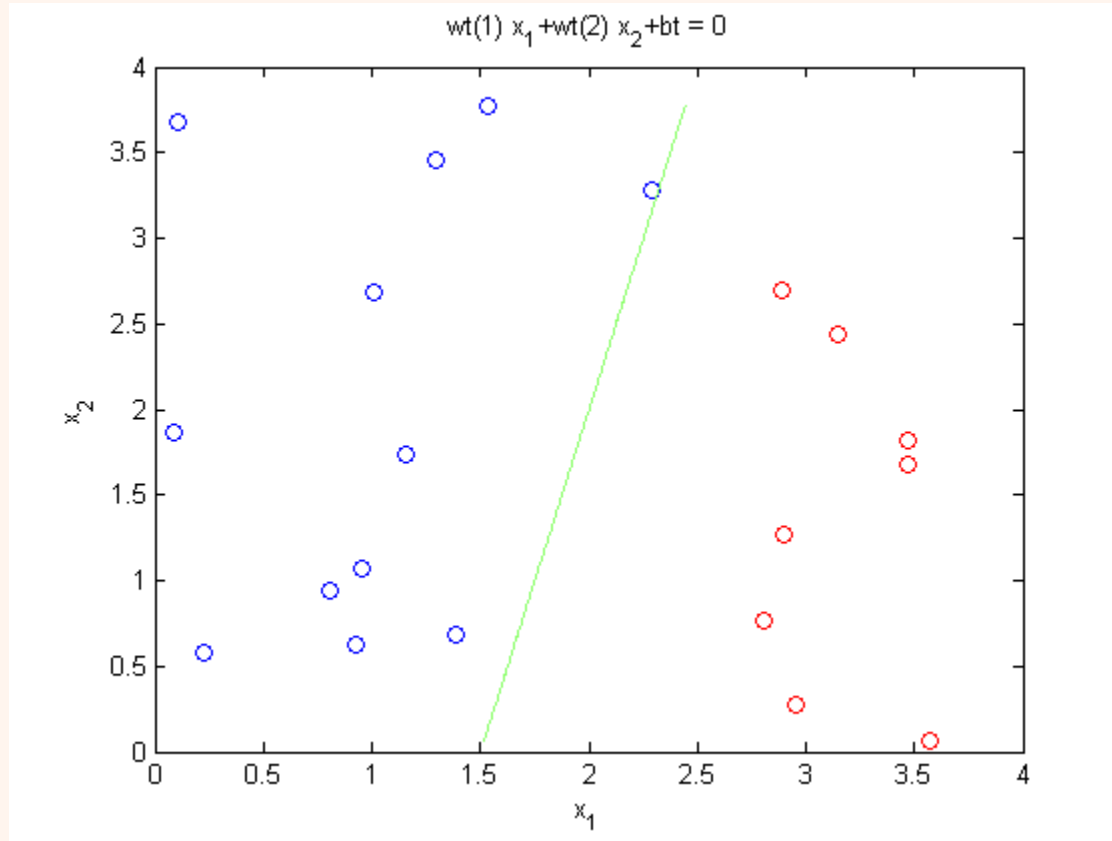
d = sign (wt (1) * X (1 ,:) + wt (2) * X (2 ,:) + bt) ;
x1min=min(X(1,:));
x1max=max(X(1,:));
x2min=min(X(2,:));
x2max=max(X(2,:));

figure;
axis([x1min x1max x2min x2max]);
plot (X (1 ,find (d ==1)) ,X (2 ,find (d ==1)) , ' or ' ) ;
hold on
plot (X( 1,find (d ==-1)) ,X(2, find (d ==-1)) , ' ob ' ) ;

Linet=@(x1,x2) wt(1)*x1+wt(2)*x2+bt;
ezplot(Linet,[x1min x1max x2min x2max]);


```

# مثال (ادامه...)



# مثال (ادامه...)

```
C=10;
H=zeros(n,n);
for k1=1:n
    for k2=1:n
        H(k1,k2)=d(k1)*d(k2)*X(:,k1) '*X(:,k2);
    end
end
f=-ones(n,1);
Aeq=d;
beq=0;
lb=zeros(n,1);
ub=C*ones(n,1);
alpha=quadprog(H,f,[],[],Aeq,beq,lb,ub)';
Svs=find(alpha> 1e-5);
w=0;
for k1=Svs
    w=w+alpha(k1)*d(k1)*X(:,k1);
end
b=mean(d(Svs)-w'*X(:,Svs));
```



# مثال (ادامه...)


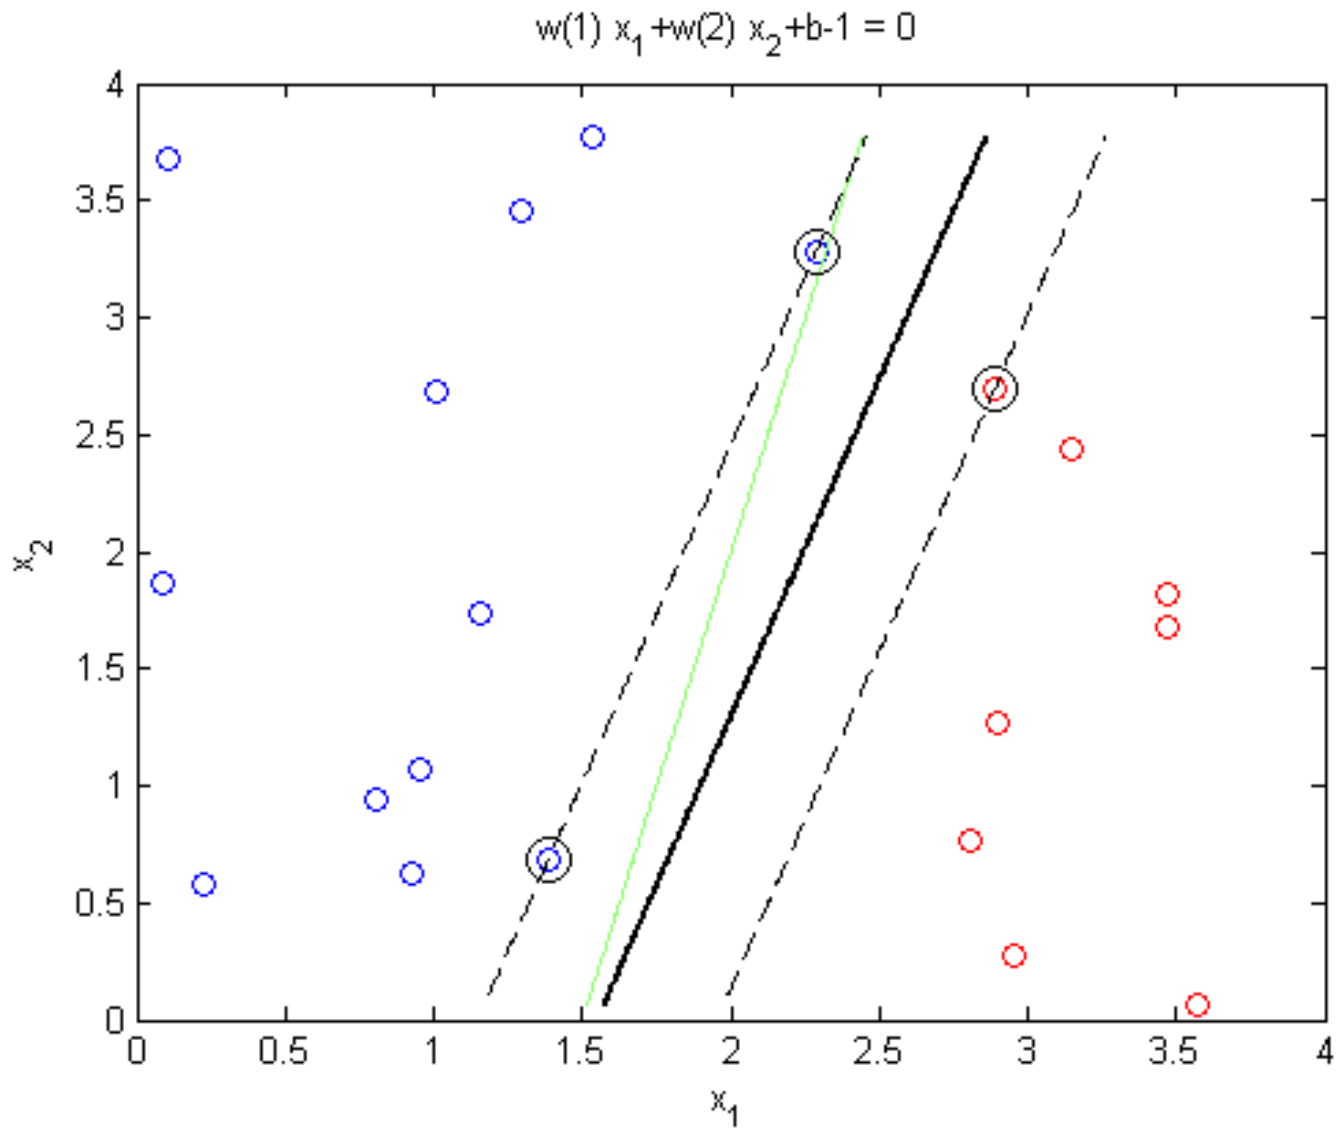
```
plot(X(1,Svs),X(2,Svs),'ko','MarkerSize',12);  
Line=@(x1,x2) w(1)*x1+w(2)*x2+b;  
LineA=@(x1,x2) w(1)*x1+w(2)*x2+b+1;  
LineB=@(x1,x2) w(1)*x1+w(2)*x2+b-1;
```

```
handle=ezplot(Line,[x1min x1max x2min x2max]);  
set(handle,'Color','k','LineWidth',2);
```

```
handleA=ezplot(LineA,[x1min x1max x2min x2max]);  
set(handleA,'Color','k','LineWidth',1,'LineStyle','--');
```

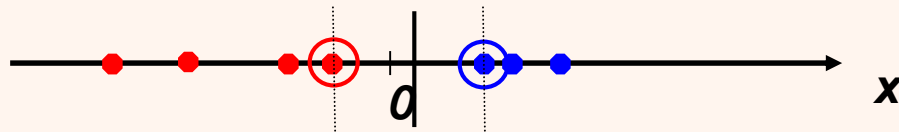
```
handleB=ezplot(LineB,[x1min x1max x2min x2max]);  
set(handleB,'Color','k','LineWidth',1,'LineStyle','--');
```



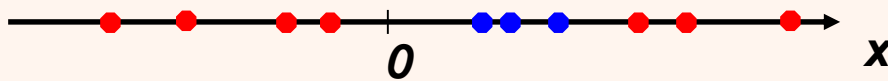


# SVM غیرخطی


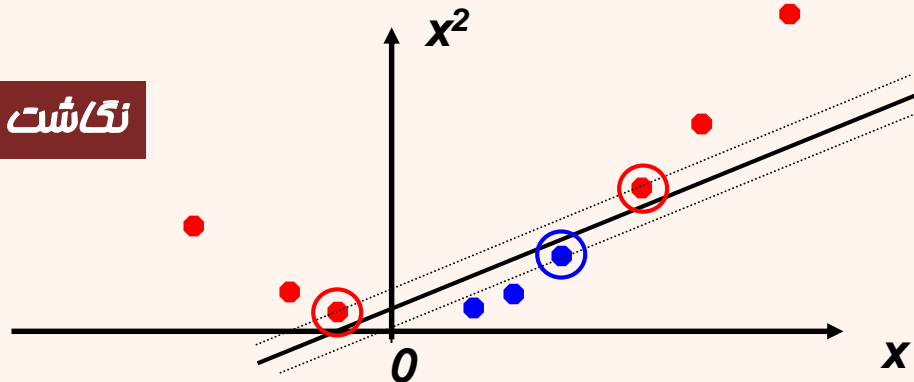
- برای داده‌هایی که قابلیت جداسازی خطی دارند، عملکرد سیستم بسیار خوب است.



- اگر داده‌ها به صورت‌های زیر باشد، مسأله چگونه حل می‌شود؟




نگاشت به یک فضای *High Dimension*




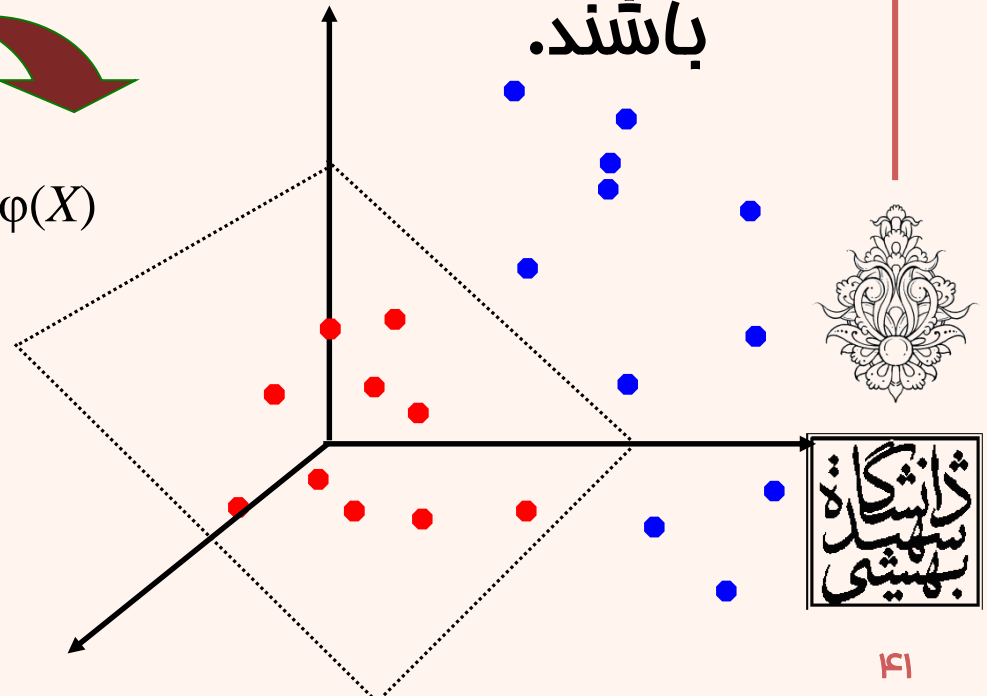
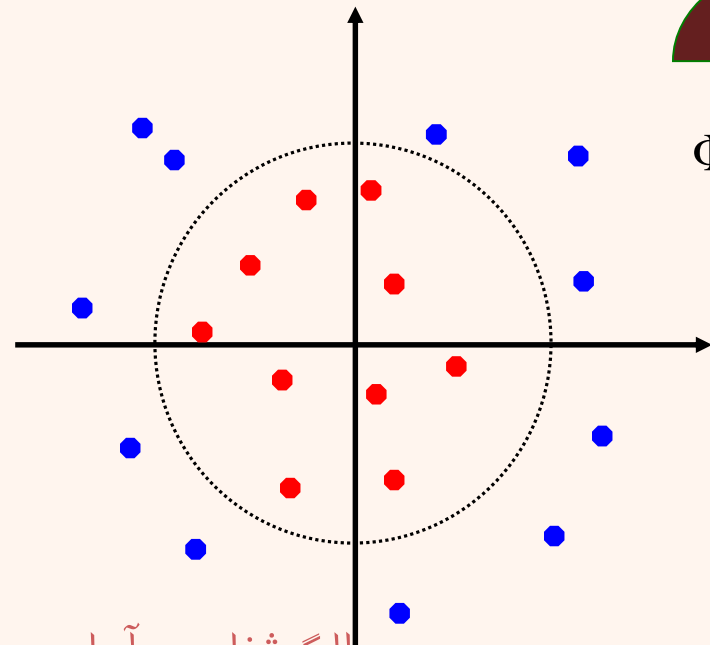


# نگاشت به فضای بالاتر

- همواره فضای ورودی می‌تواند به فضایی با ابعاد بالاتر نگاشت گردد.
- این نگاشت می‌تواند به صورتی باشد که در این فضای جدید ورودی‌ها قابلیت جداسازی داشته باشند.

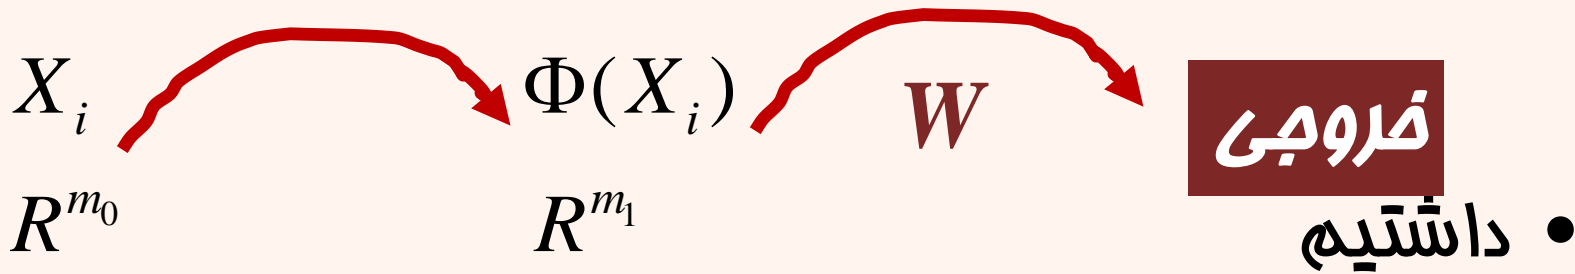


$$\Phi: X \rightarrow \phi(X)$$



راشگاه  
سپید  
بهشتی

# نگاشت به فضای بالاتر




$$W^T X + b = 0$$

- هنگامی که ورودی‌ها به فضای دیگری نگاشت شوند، برای نگاشت جدید خواهیم داشت:

$$\Phi(X) = [\varphi_1(X), \varphi_2(X), \dots, \varphi_{m_1}(X)]^T$$

- در این حالت هدف یافتن رویه‌ی جداسازی است به‌گونه‌ای که:

$$\sum_{j=1}^{m_1} w_j \varphi_j(X) + b = 0$$



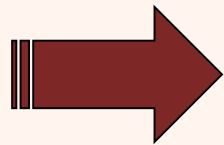
# نگاشت به فضای بالاتر

$$\sum_{j=1}^{m1} w_j \varphi_j(X) + b = 0$$

• با فرض  $\varphi_0(\mathbf{X}) = 1$

• خواهیم داشت:


$$\sum_{j=0}^{m1} w_j \varphi_j(X) = 0$$



$$W^T \Phi(X) = 0$$

$$\Phi(X) = [1, \Phi(X)]^T$$

$$W = [b = w_0, w_1, w_2, \dots, w_{m1}]^T$$



# نگاشت به فضای بالاتر


- در این مرحله تمامی شروط و قیودی که برای جداسازی خطی در نظر گرفتیم وجود دارد تنها به ازای  $X_i$  ها  $\Phi(X_i)$  در نظر گرفته می‌شود:

$$d_i \sum_{j=0}^{m_1} w_j \varphi_j(X_i) - 1 \geq 0$$

$$W_{opt} = \sum_{i=1}^N \alpha_i \cdot d_i (\Phi(X_i))$$

↓ ↓                      ↓  
اسکالر                       $m_1 \times 1$

$$W_{opt}^T \Phi(X) = 0 \quad \Rightarrow \quad \sum_{i=1}^N \alpha_i \cdot d_i \Phi^T(X_i) \Phi(X) = 0$$



# نگاشت به فضای بالاتر


$$\sum_{i=1}^N \alpha_i \cdot d_i \Phi^T(X_i) \Phi(X) = 0$$

$$K(X_i, X_j) = \varphi(X_i)^T \varphi(X_j)$$

$$\sum_{i=1}^N \alpha_i \cdot d_i K(X_i, X) = 0$$

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(X_i, X_j)$$

تابع kernel، تابعی است که معادل ضرب داخلی دو بردار خصیصه است.



# مثال

$$\mathbf{x}=[x_1 \ x_2];$$

$$K(\mathbf{x}_i, \mathbf{x}_j)=(1 + \mathbf{x}_i^T \mathbf{x}_j)^2,$$

$$K(\mathbf{x}_i, \mathbf{x}_j)= \boldsymbol{\varphi}(\mathbf{x}_i)^T \boldsymbol{\varphi}(\mathbf{x}_j):$$


$$\begin{aligned} K(\mathbf{x}_i, \mathbf{x}_j) &= (1 + \mathbf{x}_i^T \mathbf{x}_j)^2 = 1 + x_{i1}^2 x_{j1}^2 + 2 x_{i1} x_{j1} x_{i2} x_{j2} + x_{i2}^2 x_{j2}^2 + 2x_{i1} x_{j1} + 2x_{i2} x_{j2} \\ &= [1 \ x_{i1}^2 \ \sqrt{2} x_{i1} x_{i2} \ x_{i2}^2 \ \sqrt{2} x_{i1} \ \sqrt{2} x_{i2}]^T [1 \ x_{j1}^2 \ \sqrt{2} x_{j1} x_{j2} \ x_{j2}^2 \ \sqrt{2} x_{j1} \ \sqrt{2} x_{j2}] \\ &= \boldsymbol{\varphi}(\mathbf{x}_i)^T \boldsymbol{\varphi}(\mathbf{x}_j), \end{aligned}$$

$$\text{where } \boldsymbol{\varphi}(X) = [1 \ x_1^2 \ \sqrt{2} x_1 x_2 \ x_2^2 \ \sqrt{2} x_1 \ \sqrt{2} x_2]$$

## Mercer's theorem:

Every semi-positive definite symmetric function is a kernel

$K(X_1, X_1)$	$K(X_1, X_2)$	$K(X_1, X_3)$	...	$K(X_1, X_n)$
$K(X_2, X_1)$	$K(X_2, X_2)$	$K(X_2, X_3)$		$K(X_2, X_n)$
...	...	...	...	...
$K(X_n, X_1)$	$K(X_n, X_2)$	$K(X_n, X_3)$	...	$K(X_n, X_n)$



# نگاشت به فضای بالاتر

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j \underbrace{\Phi(X_i) \Phi(X_j)}_{K(X_i, X_j)}$$

$$K_{N \times N} = \left\{ K(X_i, X_j) \right\}_{i,j=1}^N$$

ماتریس متقارن

هدف یافتن ضرایب لاگرانژ بیشینه در عبارت زیر است:

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(X_i, X_j)$$

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

با در نظر گرفتن قیود زیر

$$0 \leq \alpha \leq C$$

kernel trick

در صورت یافتن تابع kernel مناسب بدون این که درگیر مشکلات فضای با ابعاد بالا (نسبت ابعاد) شویم، تنها از نتیجه این نگاشت بهره می‌بریم.



$$g(X) = \sum \alpha_i d_i K(X_i, X) + b$$

TABLE 6.1 Summary of Mercer Kernels

Type of support vector machine	Mercer kernel $k(\mathbf{x}, \mathbf{x}_i), i = 1, 2, \dots, N$	Comments
Polynomial learning machine	$(\mathbf{x}^T \mathbf{x}_i + 1)^p$	Power $p$ is specified <i>a priori</i> by the user
Radial-basis-function network	$\exp\left(-\frac{1}{2\sigma^2} \ \mathbf{x} - \mathbf{x}_i\ ^2\right)$	The width $\sigma^2$ , common to all the kernels, is specified <i>a priori</i> by the user
Two-layer perceptron	$\tanh(\beta_0 \mathbf{x}^T \mathbf{x}_i + \beta_1)$	Mercer's theorem is satisfied only for some values of $\beta_0$ and $\beta_1$


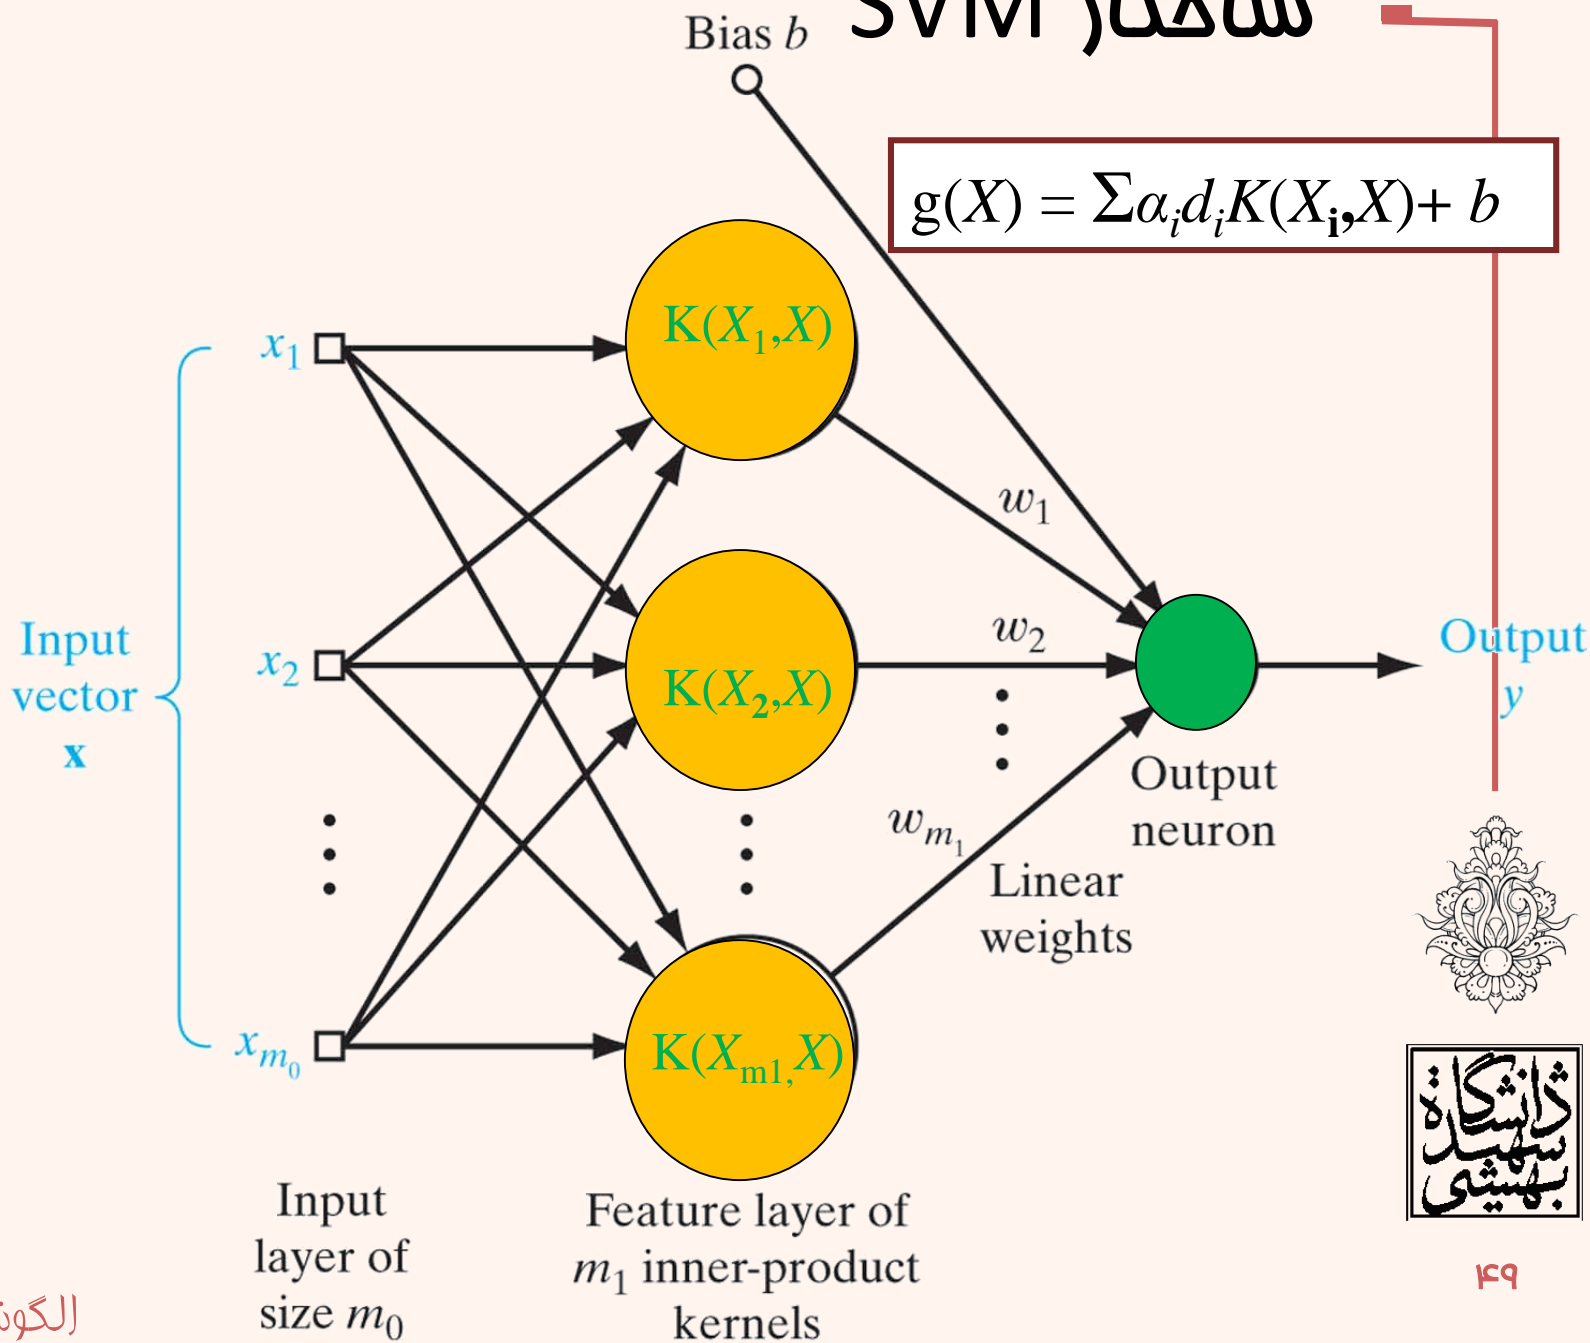
**chi-squared kernel**

$$k(x, y) = 1 - \sum_{i=1}^n \frac{(x_i - y_i)^2}{\frac{1}{2}(x_i + y_i)}$$






# ساختار SVM



## چند نکته

- SVM به گونه‌ای است که به شیوه‌های رایج برای طراحی شبکه‌های RBF و MLP نیازی ندارد.
  - در SVM، ابعاد فضای خصیصه توسط بردارهای پشتیبان مشخص می‌شود.
  - تعداد توابع شعاعی مورد استفاده و مراکز آن به صورت خودکار مشخص می‌گردد (RBF network).
  - تعداد لایه‌های مخفی و وزن‌ها به صورت خودکار مشخص می‌شود. (two-layer perceptron)
- پیچیدگی مسئله به ابعاد داده‌ها بستگی ندارد.



# XOR Problem مثال

$$X_1 = [-1 \ -1] \rightarrow d_1 = -1$$

$$X_2 = [-1 \ 1] \rightarrow d_2 = +1$$

$$X_3 = [1 \ -1] \rightarrow d_3 = +1$$


$$X_4 = [1 \ 1] \rightarrow d_4 = -1$$

$$N = 4$$

$$K(X, X_i) = \Phi^T(X) \cdot \Phi(X_i)$$

$$K(X, X_i) = (1 + X^T X_i)^2$$

• نمونه‌های آموزشی دو بعدی هستند.



# XOR Problem


$$X_i = [x_{i1} \ x_{i2}]$$

$$X = [x_1 \ x_2]$$

$$K(X, X_i) = (1 + X^T X_i)^2$$

$$\begin{aligned} &= (1 + [x_{i1} \ x_{i2}] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix})^2 = (1 + x_{i1}x_1 + x_{i2}x_2)^2 \\ &= 1 + x_1^2 x_{i1}^2 + 2x_1 x_2 x_{i1} x_{i2} + x_{i2}^2 x_2^2 + 2x_1 x_{i1} + 2x_2 x_{i2} \end{aligned}$$

- حال اگر بخواهیم پاسخ به دست آمده را با ضرب داخلی دو بردار  $\phi(X)$  و  $\phi(X_i)$  نشان دهیم خواهیم داشت:




# XOR Problem

$$= 1 + x_1^2 x_{i_1}^2 + 2x_1 x_2 x_{i_1} x_{i_2} + x_{i_2}^2 x_2^2 + 2x_1 x_{i_1} + 2x_2 x_{i_2}$$

$$\boldsymbol{\varphi}(X) = [1, x_1^2, \sqrt{2}x_1 x_2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2]^T$$

$$\boldsymbol{\varphi}(x_i) = [1 + x_{i_1}^2, \sqrt{2}x_{i_1} x_{i_2}, x_{i_2}^2, \sqrt{2}x_{i_1}, \sqrt{2}x_{i_2}]^T \quad i=1,2,3,4$$




# XOR Problem

$$\boldsymbol{\varphi}(\mathbf{x}) = [1, x_1^2, \sqrt{2}x_1x_2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2]^T$$

$$\boldsymbol{\varphi}(x_i) = [1 + x_{i1}^2, \sqrt{2}x_{i1}x_{i2}, x_{i2}^2, \sqrt{2}x_{i1}, \sqrt{2}x_{i2}]^T \quad i=1,2,3,4$$

$$\begin{array}{l} X_1 = [-1 \ -1] \\ X_2 = [-1 \ 1] \\ X_3 = [1 \ -1] \\ X_4 = [1 \ 1] \end{array} \left[ \begin{array}{cccccc} 1 & 1 & \sqrt{2} & 1 & -\sqrt{2} & -\sqrt{2} \\ 1 & 1 & -\sqrt{2} & 1 & -\sqrt{2} & \sqrt{2} \\ 1 & 1 & -\sqrt{2} & 1 & \sqrt{2} & -\sqrt{2} \\ 1 & 1 & \sqrt{2} & 1 & \sqrt{2} & \sqrt{2} \end{array} \right]$$




# XOR Problem

$$K_{4 \times 4} = \begin{bmatrix} 1 & 1 & \sqrt{2} & 1 & -\sqrt{2} & -\sqrt{2} \\ 1 & 1 & -\sqrt{2} & 1 & -\sqrt{2} & \sqrt{2} \\ 1 & 1 & -\sqrt{2} & 1 & \sqrt{2} & -\sqrt{2} \\ 1 & 1 & \sqrt{2} & 1 & \sqrt{2} & \sqrt{2} \end{bmatrix} \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ \sqrt{2} & -\sqrt{2} & -\sqrt{2} & \sqrt{2} \\ 1 & 1 & 1 & 1 \\ -\sqrt{2} & -\sqrt{2} & \sqrt{2} & \sqrt{2} \\ -\sqrt{2} & \sqrt{2} & -\sqrt{2} & \sqrt{2} \end{bmatrix}$$

$$K(X, X_i) = (1 + X^T X_i)^2$$

$$K_{4 \times 4} = \begin{bmatrix} 9 & 1 & 1 & 1 \\ 1 & 9 & 1 & 1 \\ 1 & 1 & 9 & 1 \\ 1 & 1 & 1 & 9 \end{bmatrix}$$



# XOR Problem



$$N = 4$$

$$Q(\alpha) = \sum_{i=1}^4 \alpha_i - \frac{1}{2} \sum_{i=1}^4 \sum_{j=1}^4 \alpha_i \alpha_j d_i d_j K(X_i, X_j)$$

$$Q(\alpha) = \alpha_1 + \alpha_2 + \alpha_3 + \alpha_4$$

$$- \frac{1}{2} (9\alpha_1^2 + 9\alpha_2^2 + 9\alpha_3^2 + 9\alpha_4^2 - 2\alpha_1\alpha_2 - 2\alpha_1\alpha_3 + 2\alpha_1\alpha_4 + 2\alpha_2\alpha_3 - 2\alpha_2\alpha_4 - 2\alpha_3\alpha_4)$$

• دست آوردن  $\alpha_i$  ها بهینه منجر به روابط زیر می شود:





# XOR Problem

$$1 - 9\alpha_1 + \alpha_2 + \alpha_3 + \alpha_4 = 0$$


$$1 + \alpha_1 - 9\alpha_2 - \alpha_3 + \alpha_4 = 0$$

$$1 + \alpha_1 - \alpha_2 - 9\alpha_3 - \alpha_4 = 0$$

$$1 - \alpha_1 + \alpha_2 + \alpha_3 - 9\alpha_4 = 0$$

$$\alpha_i = \frac{1}{8}$$

$$Q(\alpha) = \frac{1}{4}$$



- بنابراین هر چهار ورودی، بردار پشتیبان هستند.
- پس از محاسبه  $\alpha$  ها  $W_{opt}$  را محاسبه می‌کنیم:



# XOR Problem

• جهت محاسبه‌ی اندازه‌ی وزن بهینه داریم:


$$\frac{1}{2} \|\mathbf{w}_{opt}\|^2 = \frac{1}{4} \quad \Rightarrow \quad \|\mathbf{w}_{opt}\| = \frac{1}{\sqrt{2}}$$

• داشتیم:

$$\mathbf{w}_{opt} = \sum_{i=1}^N \alpha_i \cdot d_i(\varphi_j(X_i))$$

$$\mathbf{w}_o = \frac{1}{8} [-\varphi(\mathbf{x}_1) + \varphi(\mathbf{x}_2) + \varphi(\mathbf{x}_3) - \varphi(\mathbf{x}_4)]$$

$$= \frac{1}{8} \left[ - \begin{bmatrix} 1 \\ 1 \\ \sqrt{2} \\ 1 \\ -\sqrt{2} \\ -\sqrt{2} \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ -\sqrt{2} \\ 1 \\ -\sqrt{2} \\ \sqrt{2} \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ -\sqrt{2} \\ 1 \\ \sqrt{2} \\ -\sqrt{2} \end{bmatrix} - \begin{bmatrix} 1 \\ 1 \\ \sqrt{2} \\ 1 \\ \sqrt{2} \\ \sqrt{2} \end{bmatrix} \right] = \begin{bmatrix} 0 \\ 0 \\ -1/\sqrt{2} \\ 0 \\ 0 \\ 0 \end{bmatrix}$$




# XOR Problem

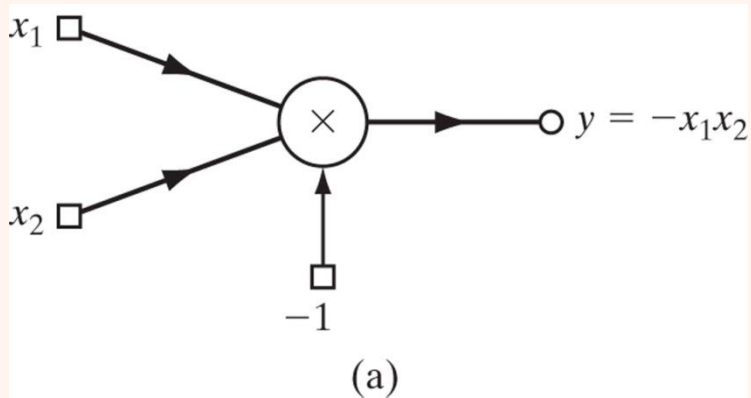
- رویه‌ی بهینه به وسیله‌ی رابطه‌ی زیر محاسبه می‌شود:

$$W_{opt}^T \varphi(X) = 0$$


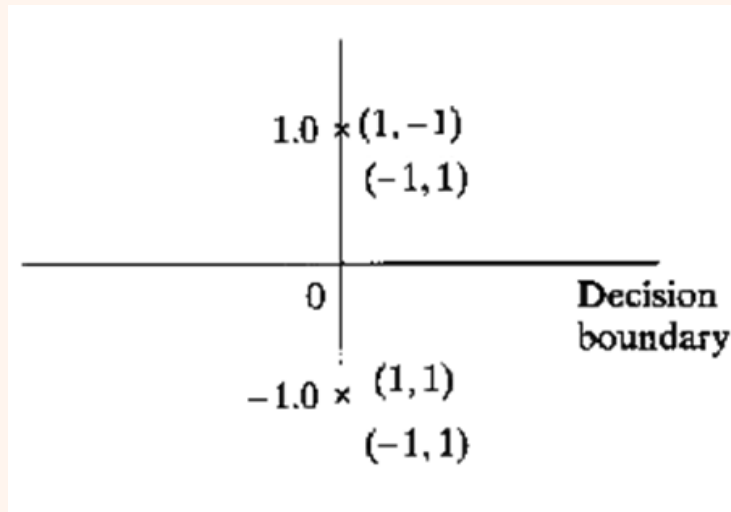
$$\begin{bmatrix} 0 & 0 & \frac{-1}{\sqrt{2}} & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ x_1^2 \\ \sqrt{2}x_1x_2 \\ x_2^2 \\ \sqrt{2}x_1 \\ \sqrt{2}x_2 \end{bmatrix} = 0 \quad \Rightarrow \quad -x_1x_2 = 0$$


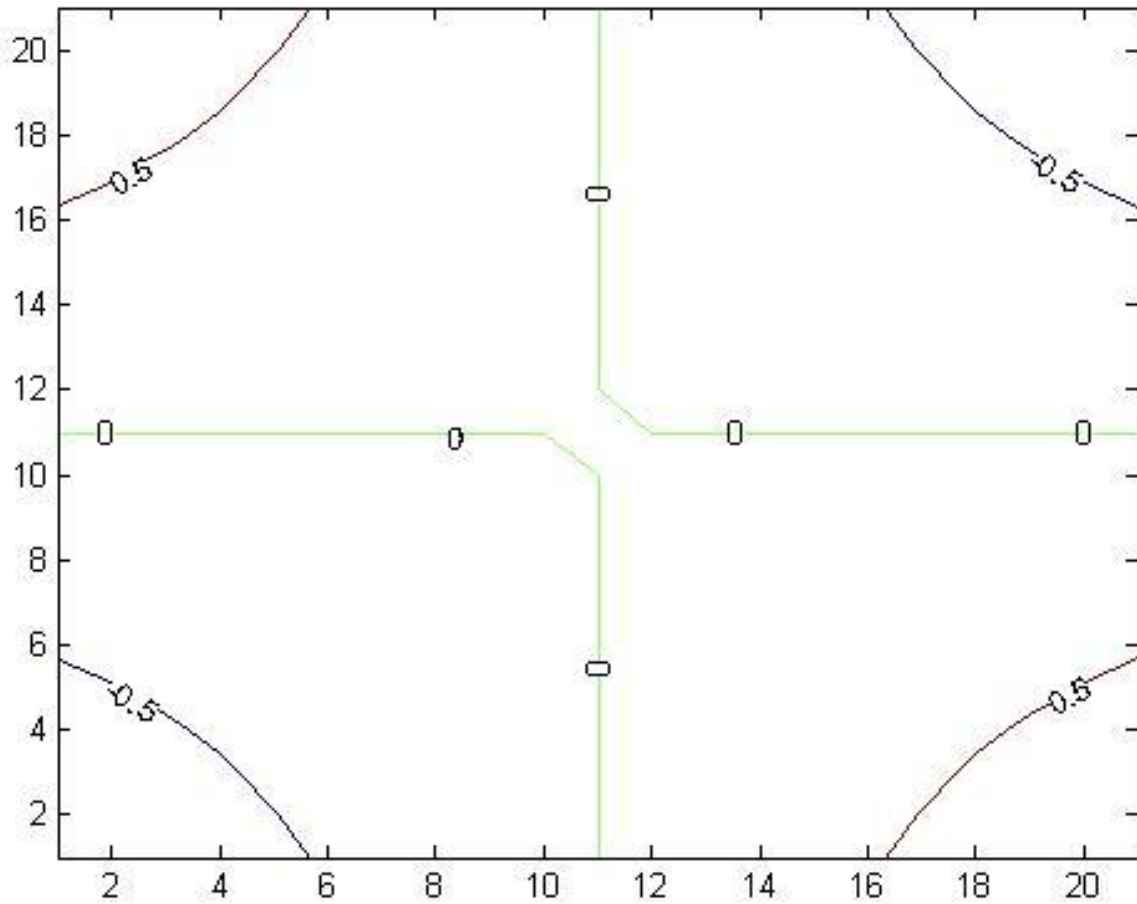


# XOR Problem



(a) Polynomial machine for solving the XOR problem. (b) Induced images in the feature space due to the four data points of the XOR problem.

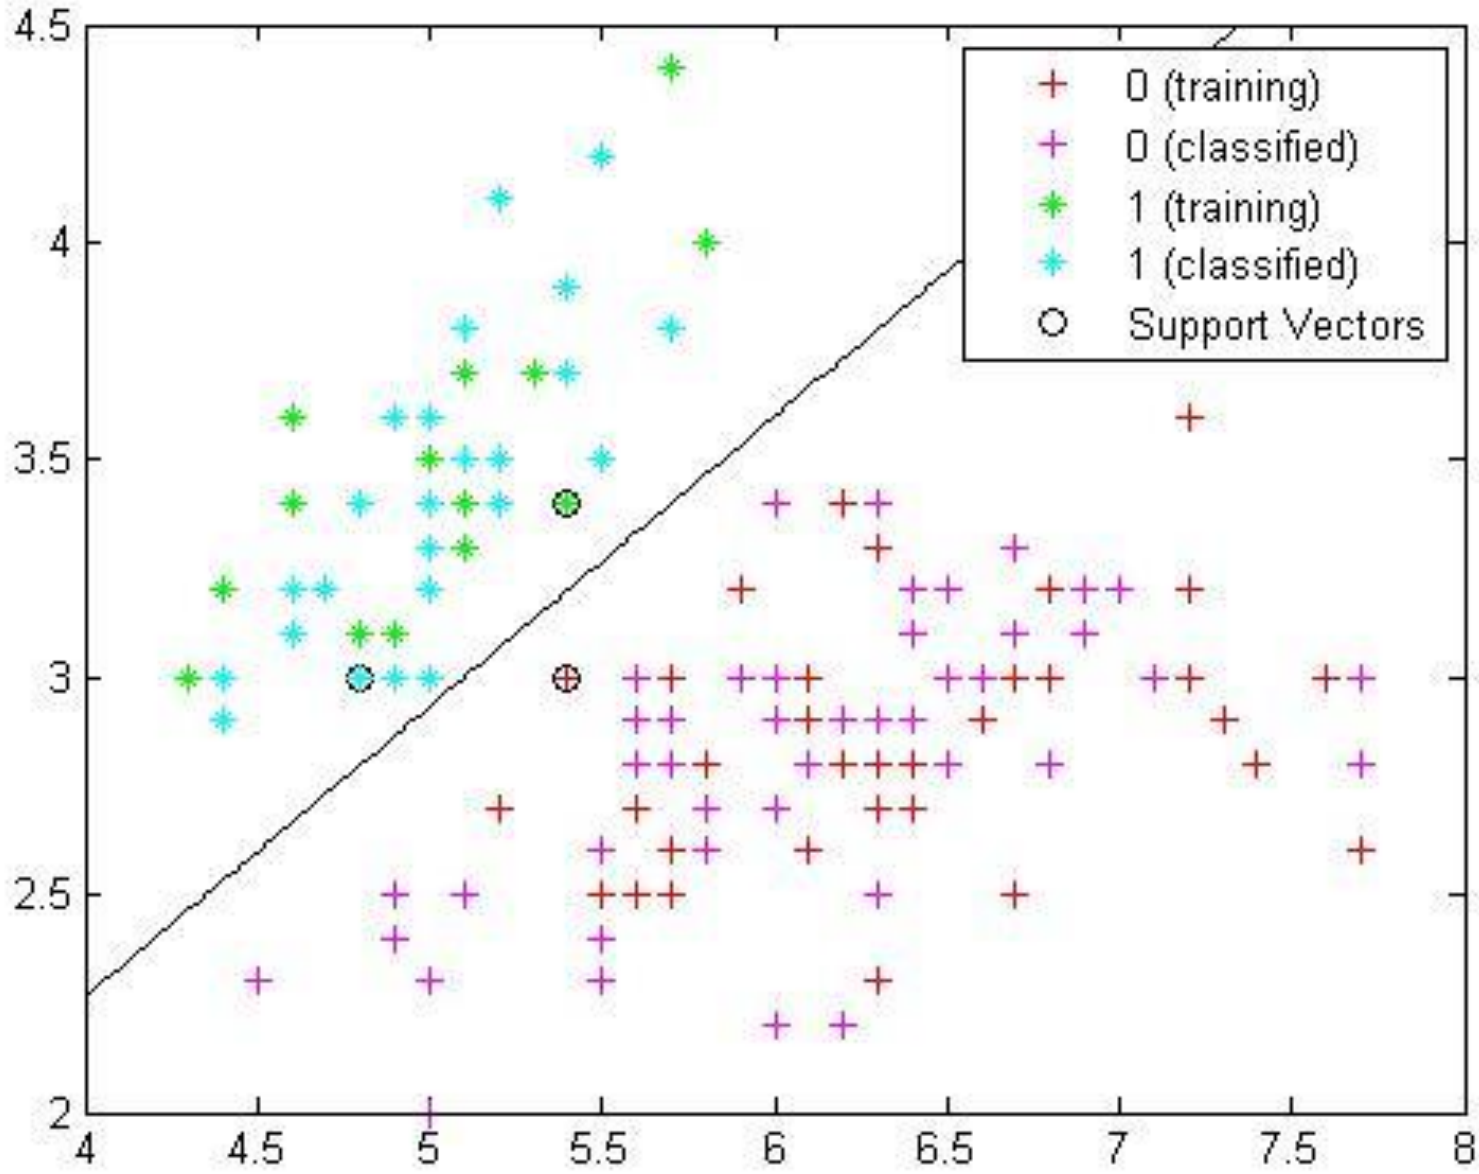




# مثال

```
clear all;
close all;
load fisheriris
data = [meas(:,1), meas(:,2)];
groups = ismember(species,'setosa');
[train, test] = crossvalind('holdOut',groups);
cp = classperf(groups);
svmStruct =
svmtrain(data(train,:),groups(train),'showplot',true,'boxconstraint',1e6);
title(sprintf('Kernel Function: %s',...
    func2str(svmStruct.KernelFunction),...
    'interpreter','none'));
classes = svmclassify(svmStruct,data(test,:), 'showplot',true);
classperf(cp,classes,test);
cp.CorrectRate
```





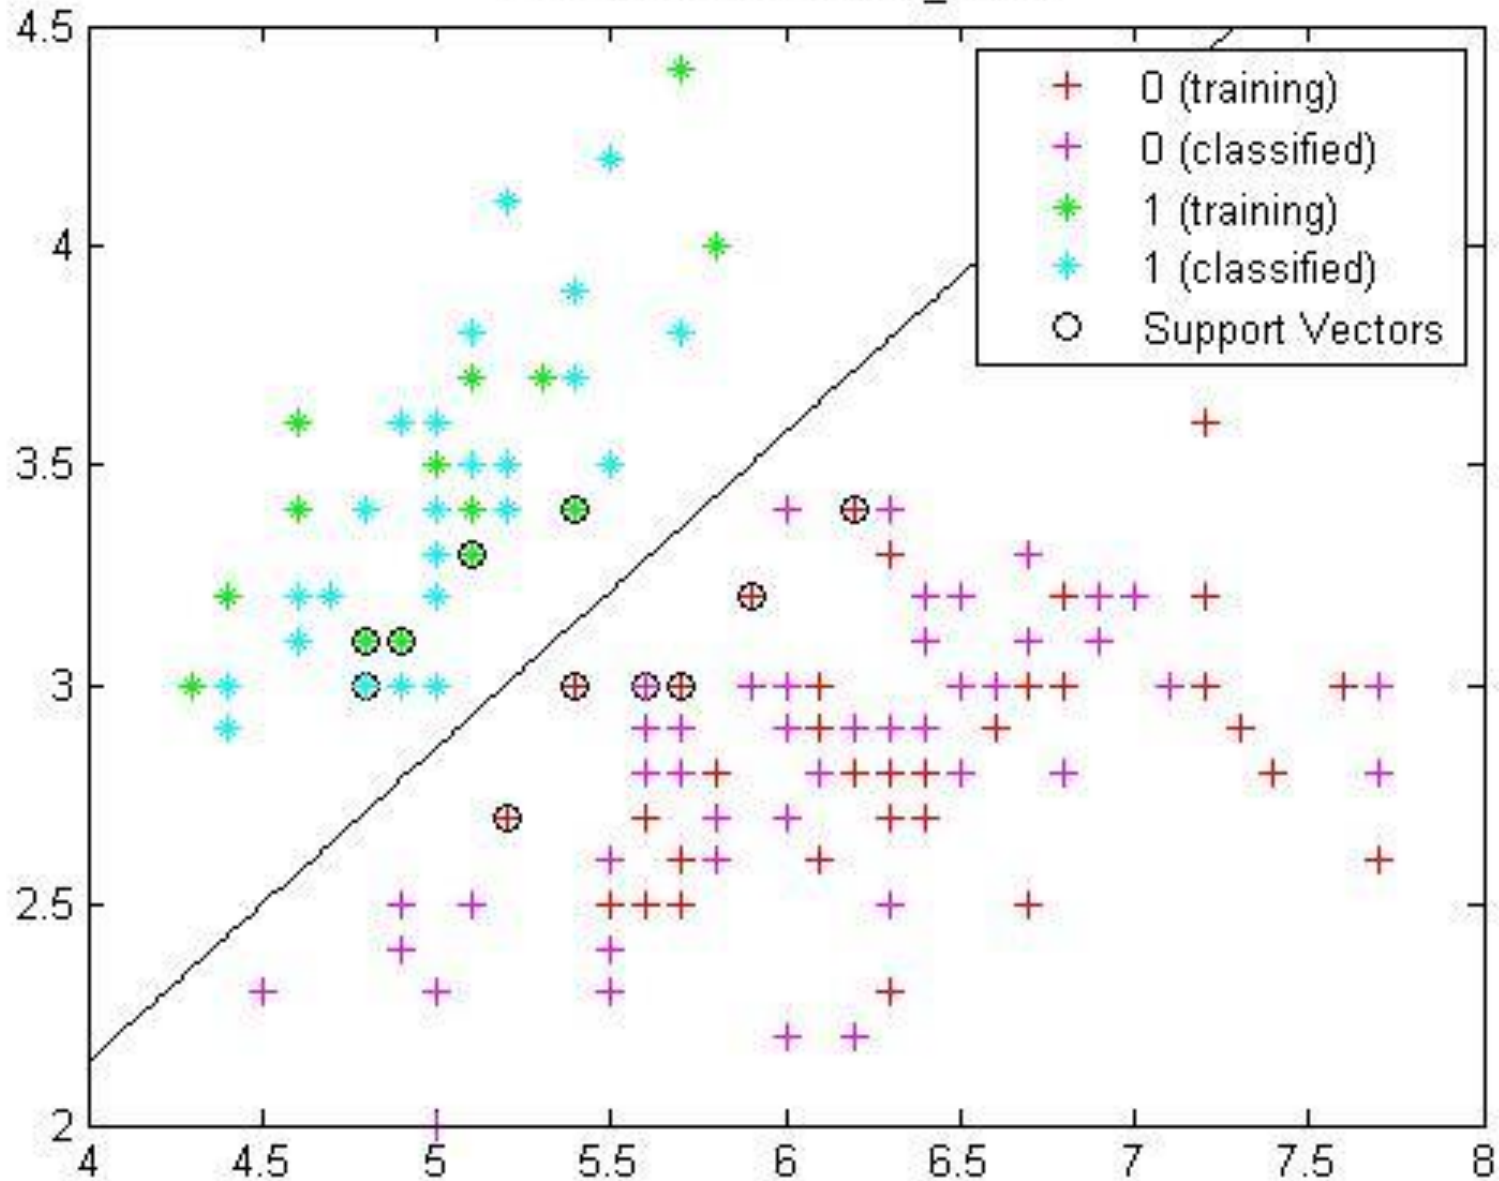


```
clear all;
close all;
load fisheriris
data = [meas(:,1), meas(:,2)];
groups = ismember(species,'setosa');
[train, test] = crossvalind('holdOut',groups);
cp = classperf(groups);
svmStruct = svmtrain(data(train,:),groups(train),'showplot',true);
title(sprintf('Kernel Function: %s',...
    func2str(svmStruct.KernelFunction),...
    'interpreter','none'));
classes = svmclassify(svmStruct,data(test,:), 'showplot',true);
classperf(cp,classes,test);
cp.CorrectRate
```






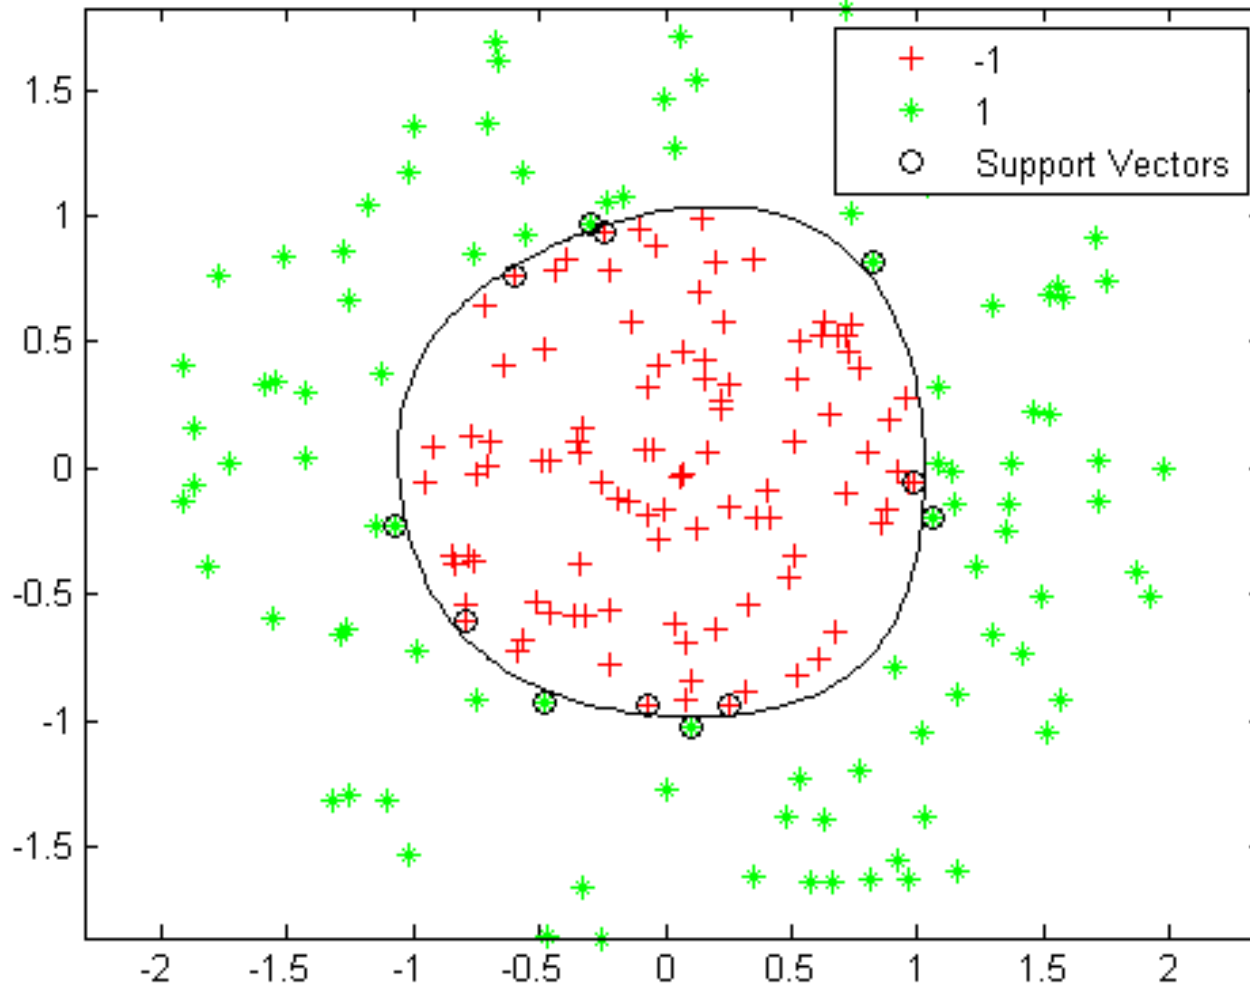
Kernel Function: linear\_kernel





```
r = sqrt(rand(100,1)); % radius
t = 2*pi*rand(100,1); % angle
data1 = [r.*cos(t), r.*sin(t)]; % points
r2 = sqrt(3*rand(100,1)+1); % radius
t2 = 2*pi*rand(100,1); % angle
data2 = [r2.*cos(t2), r2.*sin(t2)]; % points
plot(data1(:,1),data1(:,2),'r.')
plot(data2(:,1),data2(:,2),'b.')
axis equal
data3 = [data1;data2];
theclass = ones(200,1);
theclass(1:100) = -1;
c1 = svmtrain(data3,theclass,'Kernel_Function','rbf',...
    'boxconstraint',Inf,'showplot',true);
hold on
axis equal
```





# ساخت کرنل‌های جدید


- براساس کرنل‌های موجود به سادگی می‌توان کرنل‌های جدید ساخت:

– هر تابع  $K(\dots)$  یک کرنل است چنانچه معادل ضرب داخلی بردارهای حاصل از نگاشت باشد.

$$K(x, y) = c_1 K_1(x, y) + c_2 K_2(x, y), c_1 \geq 0, c_2 \geq 0$$

$$\phi(x) = (\sqrt{c_1} \phi_1(x), \sqrt{c_2} \phi_2(x))$$

$$\phi(x) \cdot \phi(y) = c_1 \phi_1(x) \cdot \phi_1(y) + c_2 \phi_2(x) \cdot \phi_2(y)$$



# ساخت کرنل‌های جدید (ادامه...)

$$K(x, y) = K_1(x, y) \cdot K_2(x, y)$$


$$\phi(x) = (\phi_{1,i}(x)\phi_{2,j}(x))_{i \in \{1, \dots, n\}, j \in \{1, \dots, m\}}$$

$$\phi(x) \cdot \phi(y) = \sum_{i,j} \phi_{1,i}(x)\phi_{2,j}(x)\phi_{1,i}(y)\phi_{2,j}(y)$$

$$= \sum_i (\phi_{1,i}(x)\phi_{1,i}(y) \sum_j \phi_{2,j}(x)\phi_{2,j}(y))$$

$$= \sum_i (\phi_{1,i}(x)\phi_{1,i}(y)K_2(x, y))$$

$$= K_1(x, y) \cdot K_2(x, y)$$



# ساخت کرنل‌های جدید (ادامه...)

$$k(x, z) = k_1(f(x), f(z)), \text{ where } f : X \rightarrow X.$$

$$k(x, z) = g(x)g(z), \text{ for } g : X \rightarrow R.$$

$$k(x, z) = f(k_1(x, z)),$$

$$k(x, z) = \exp(\tilde{k}(x, z))$$

$$k(x, z) = \exp\left(\frac{-\|x-z\|^2}{\sigma^2}\right)$$

