

یادگیری ماشین
(۰۱-۸۰۵-۱۱-۱۳)
فصل سیزدهم

ماشین‌های بردار پشتیبان



دانشگاه شهید بهشتی

دانشکده‌ی مهندسی برق و کامپیوتر

پاییز ۱۳۹۴

احمد محمودی ازناوه

فهرست مطالب

- SVM
 - تاریخچه
 - معرفی
 - داده‌های جدایی‌پذیر خطی
- Soft Margin
- مجموعه‌های جدایی‌ناپذیر خطی
 - نگاشت 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.

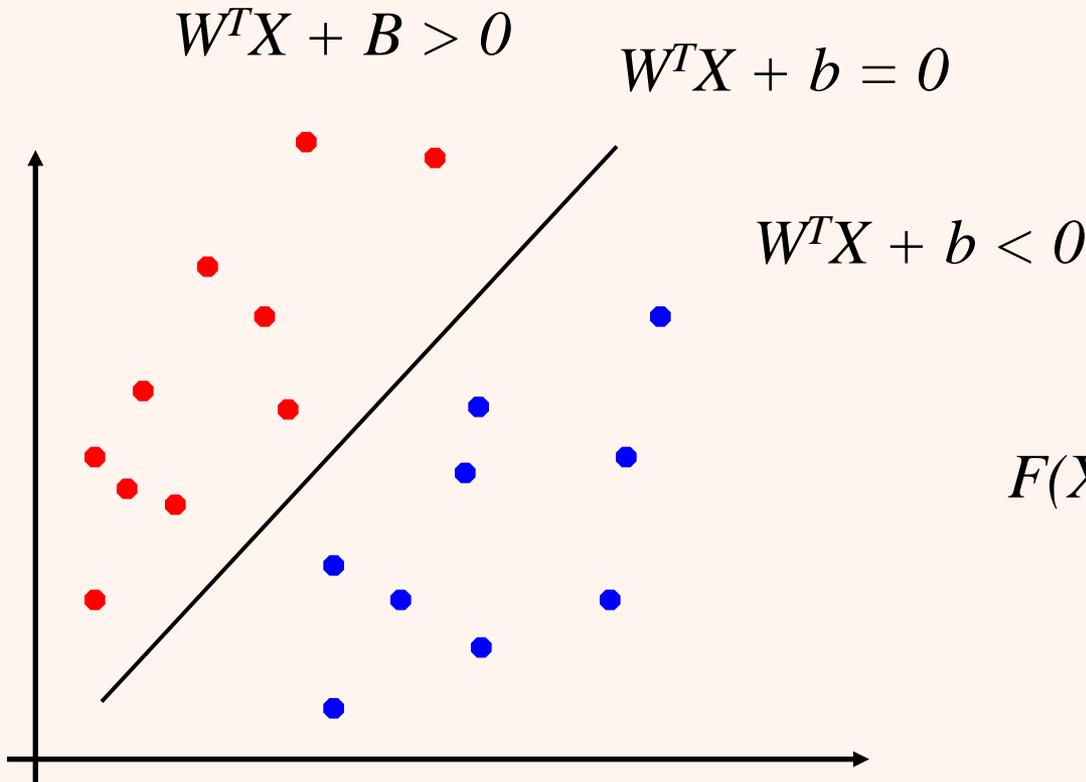


Cortes, C. and V. Vapnik (1995). "Support-vector networks." Machine Learning 20(3): 273-297.



معرفی

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



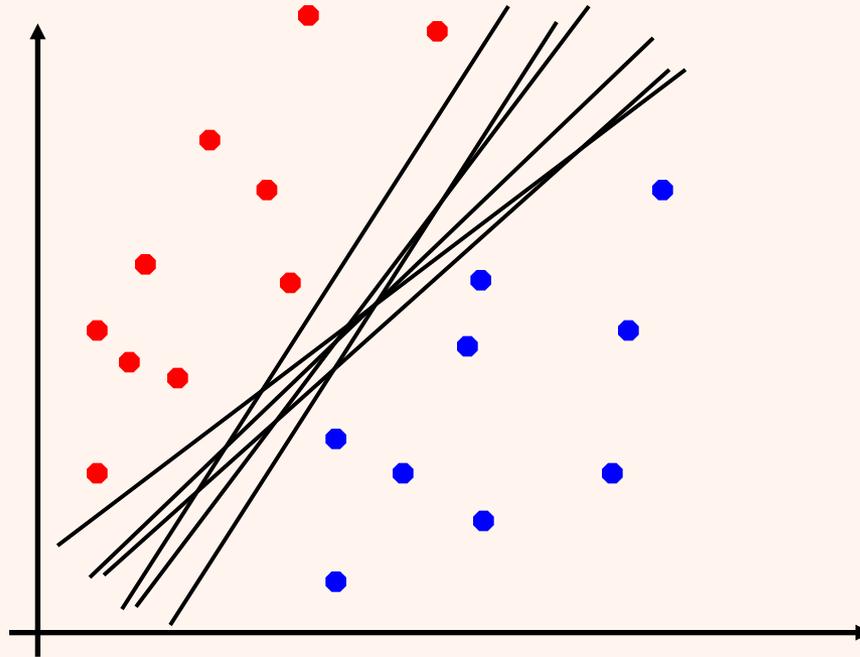
$$F(X) = \text{SIGN}(W^T X + b)$$



مرز بهینه

• سوال

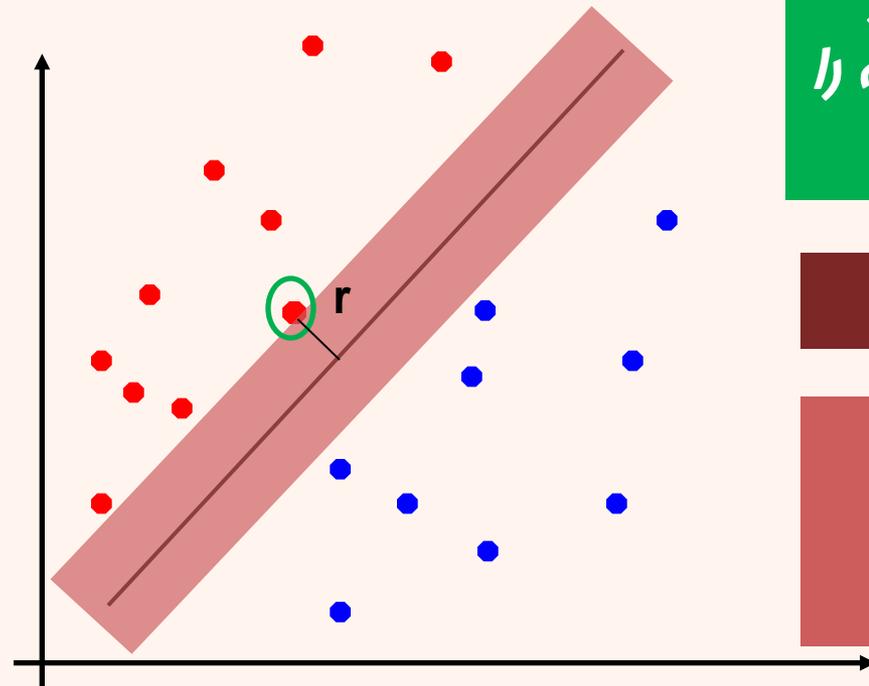
– کدام یک از مرزها، مرزی بهینه برای جداسازی است؟



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 ما کمینه نمودن r است.

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

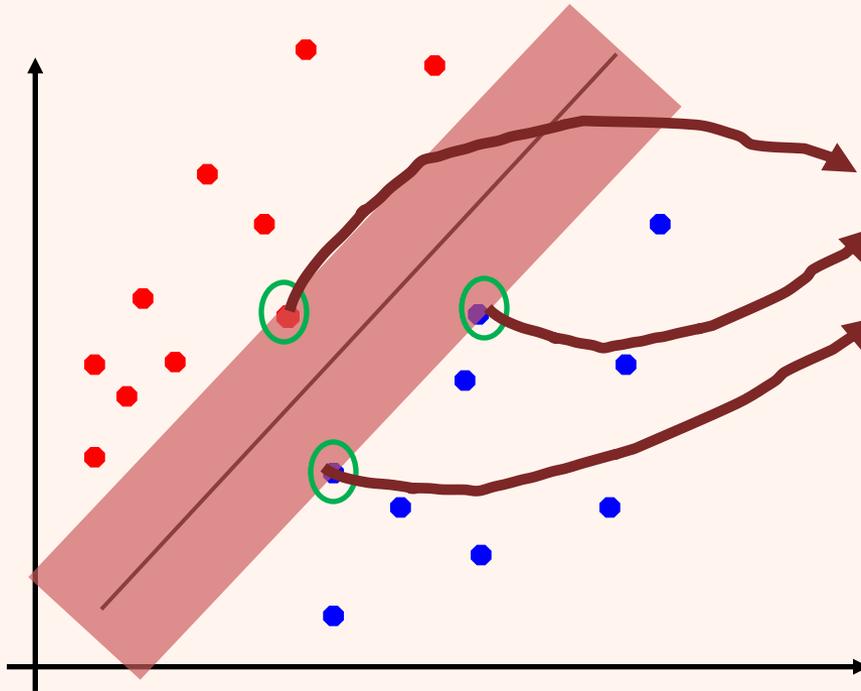


ماشین‌های ماکزیمم

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

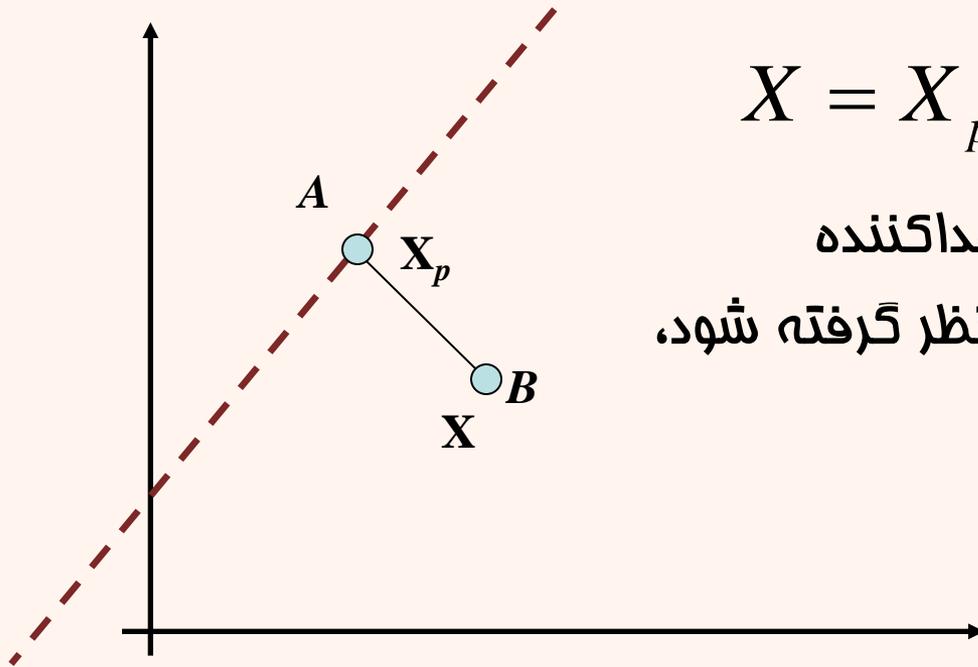
$$g(X) = W_{op}^T X + b_{op}$$

- $g(X)$ 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:

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

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

$$g(X) = \underbrace{W_{op}^T X_p + b_{op}} + r \frac{W_{op}}{\|W_{op}\|} W_{op}^T$$

روی مرز پس برابر با صفر

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

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



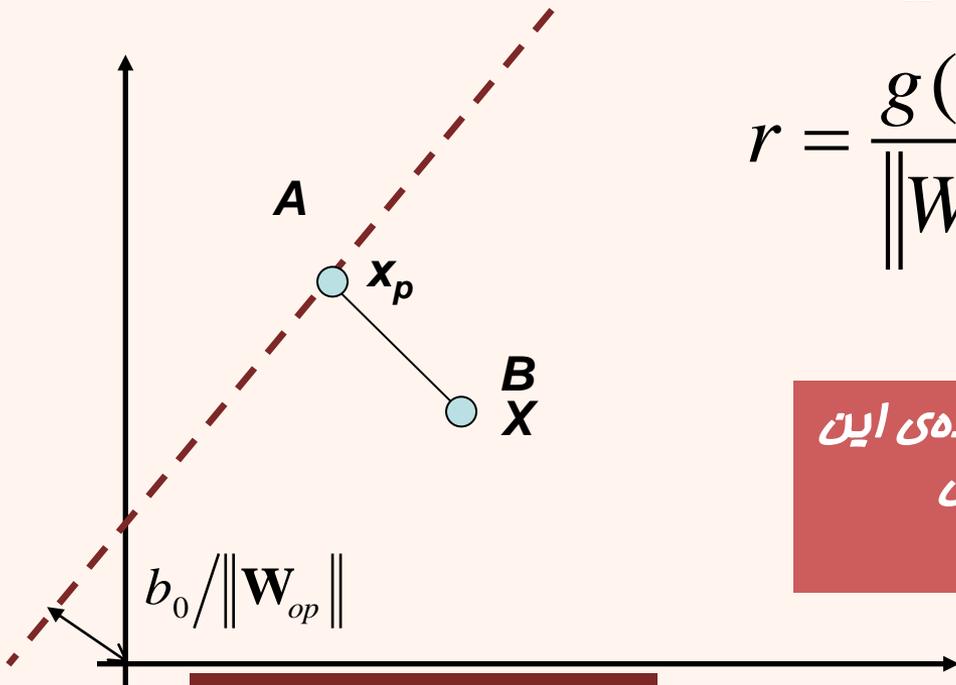
مرز جداسازی (ادامه...)

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

هدف ما کمینه 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 دهنده این است که مبدأ در کدام سمت خط مرزی هستیم.



فاصله از مبدأ مختصات

شبکه عصبی

مرز جداسازی (ادامه...)

مکان 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...)

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

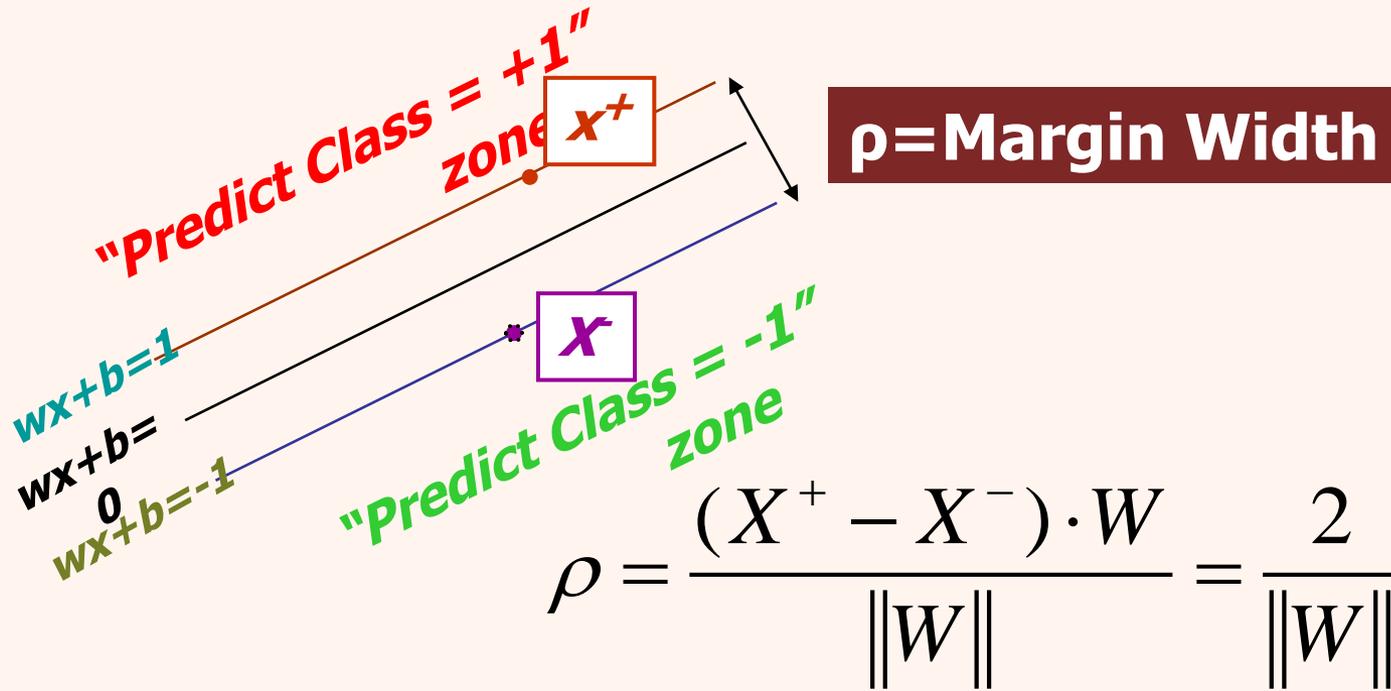
$$r = \frac{g(X^s)}{\|W_{op}\|} = \begin{cases} \frac{1}{\|W_{op}\|} \\ -\frac{1}{\|W_{op}\|} \end{cases}$$

- 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

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

– Φ یک تابع محدب (Convex Function) است.

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

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

این میزان بزرگ‌تر یا کوچک‌تر است



وزن‌ها و بایاس را به گونه‌ای بیابید که:

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

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



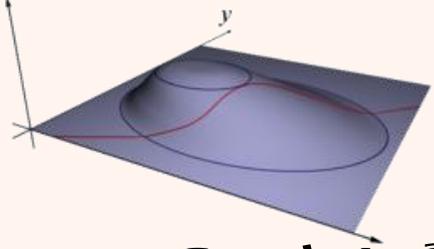
وزن‌ها و بایاس را به گونه‌ای بیابید که:

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

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 α 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 α_i برای الگوهای آموزشی متناظر با SVها رابطه‌ی زیر برقرار است:

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

• در نتیجه α_i متناظر با بردارهای پشتیبان غیرصفر 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 داشتهیم:

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

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

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

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

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



α_i ها وابسته به الگوهای X_i ، X_j و خروجی‌های 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 α ها می‌توان نسبت به α_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 α خواهیم داشت:

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

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

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



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 α_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

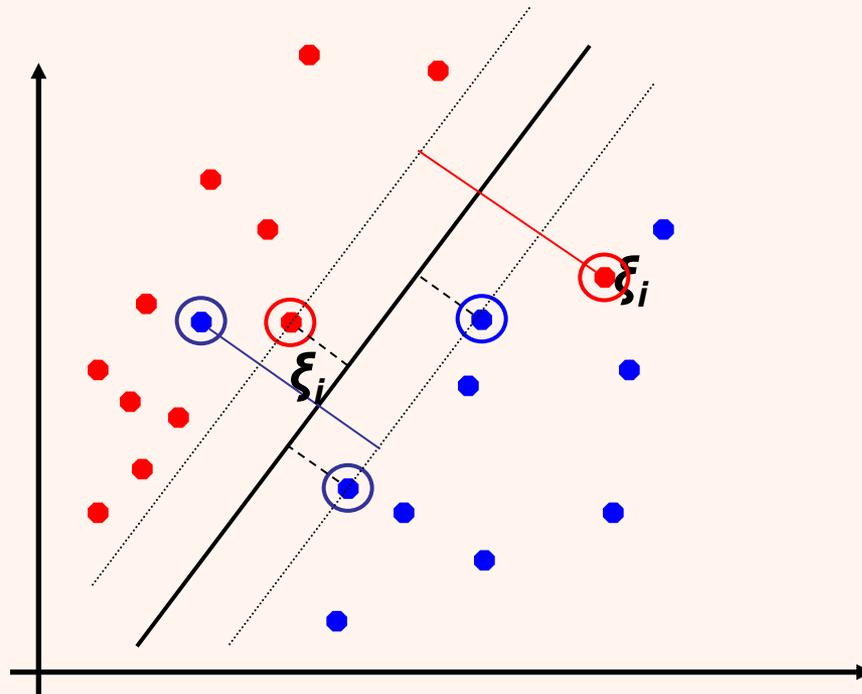
توجه:

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.

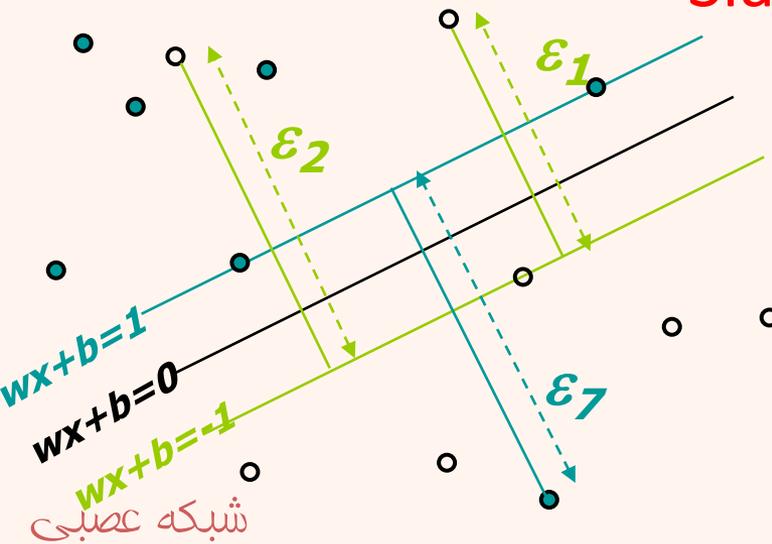
- ماشیهی جداسازی soft گفته می‌شود، در صورتی که برای برخی داده‌ها شرط زیر نقض شود:

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

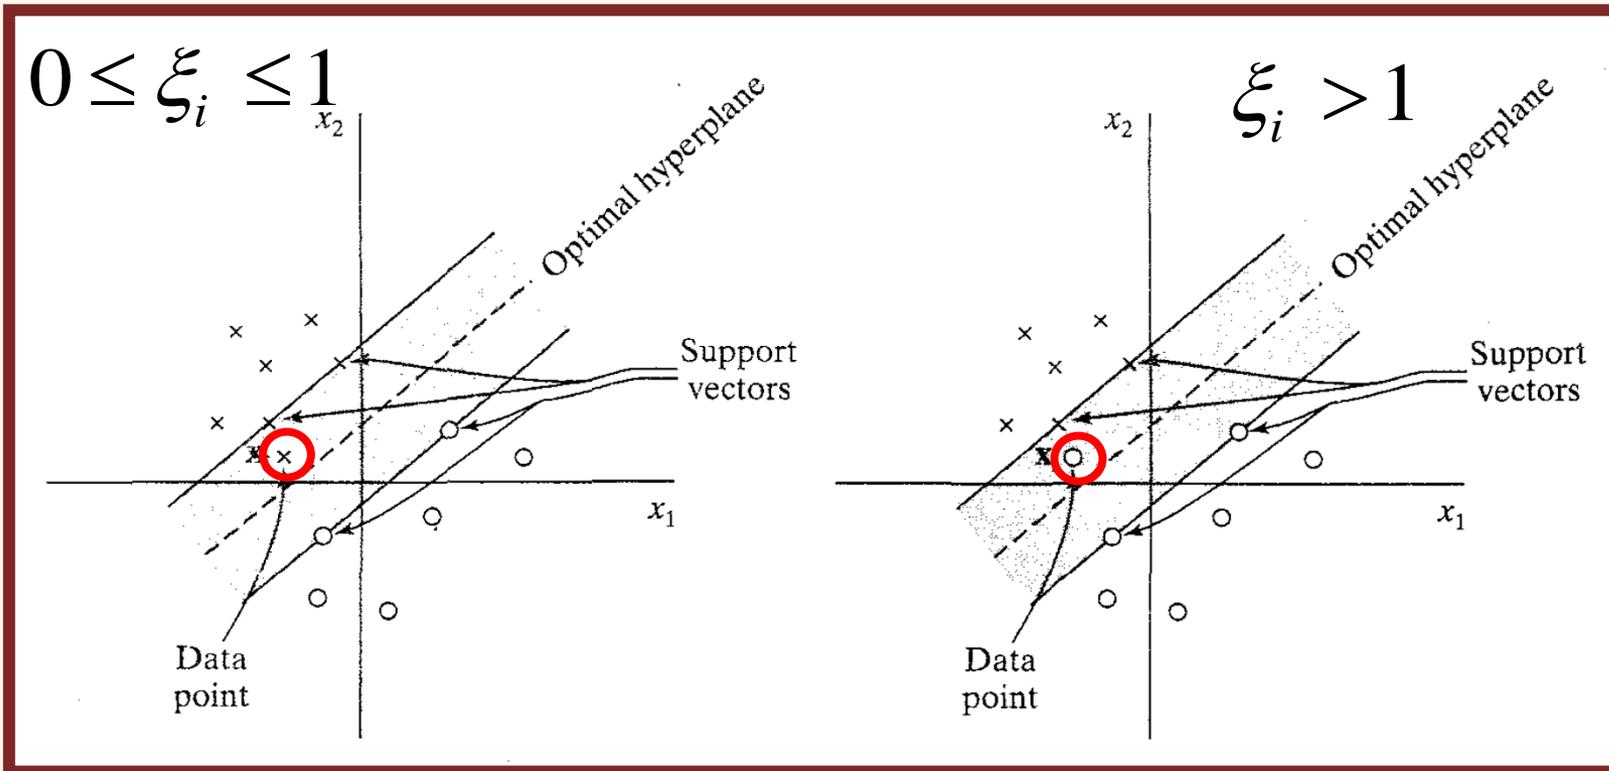
- با اضافه کردن یک **Slack Variable**

- مساله 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 طبقه‌بندی 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، ما 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 ξ را تضمین کند.



Soft Margin Classification

در نهایت ضرایب لاگراش 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

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

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

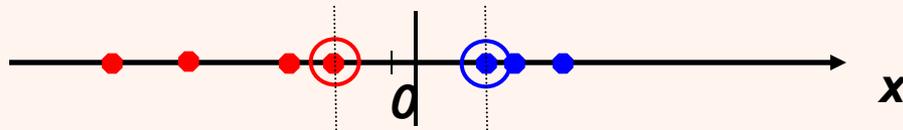
بقیه مراحل مانند حالت قبل خواهد بود:

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

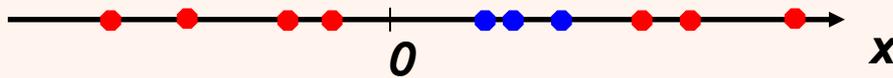


SVM غیرخطی

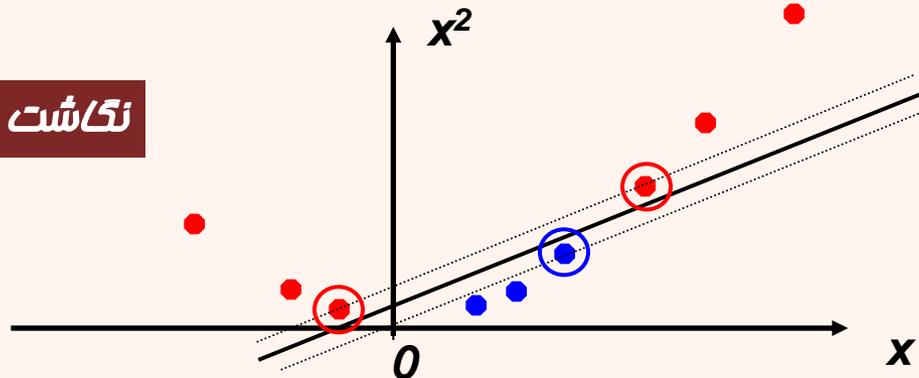
- برای داده‌هایی که قابلیت جداسازی خطی دارند، عملکرد سیستم بسیار خوب است.



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



نگاشت به یک فضای High Dimension

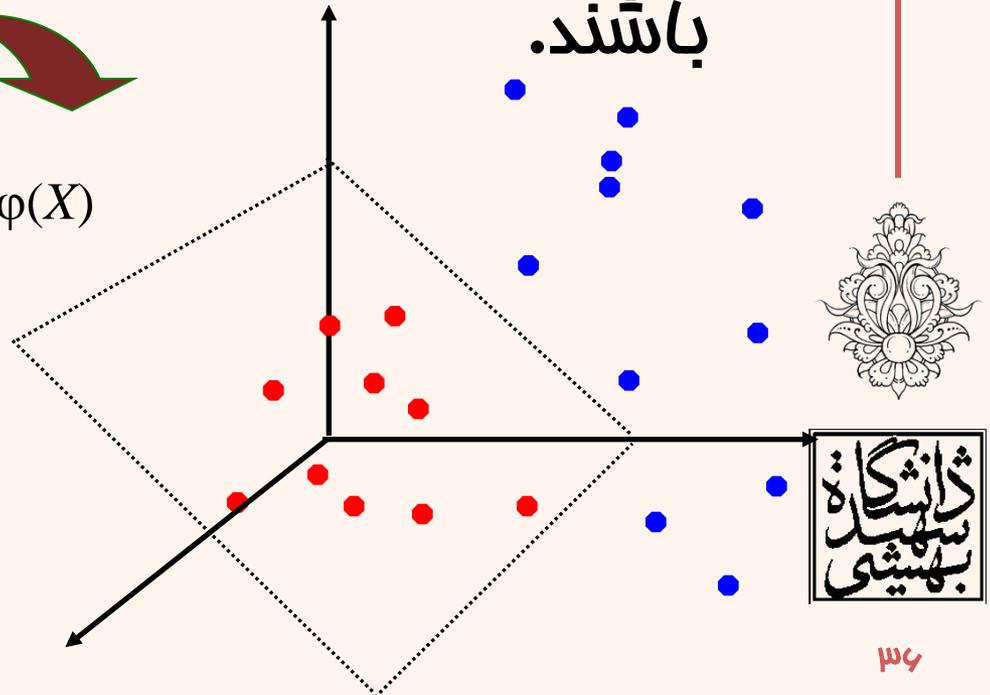
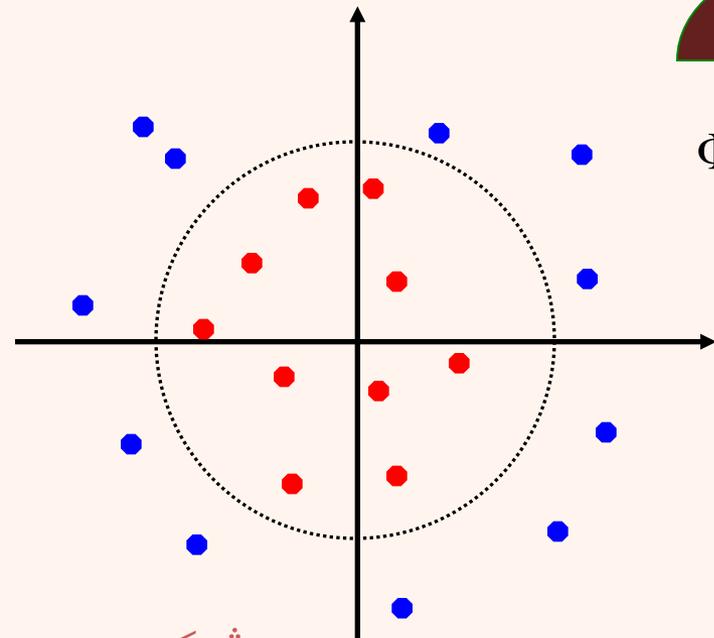


نگاشت به فضای بالاتر

- 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.

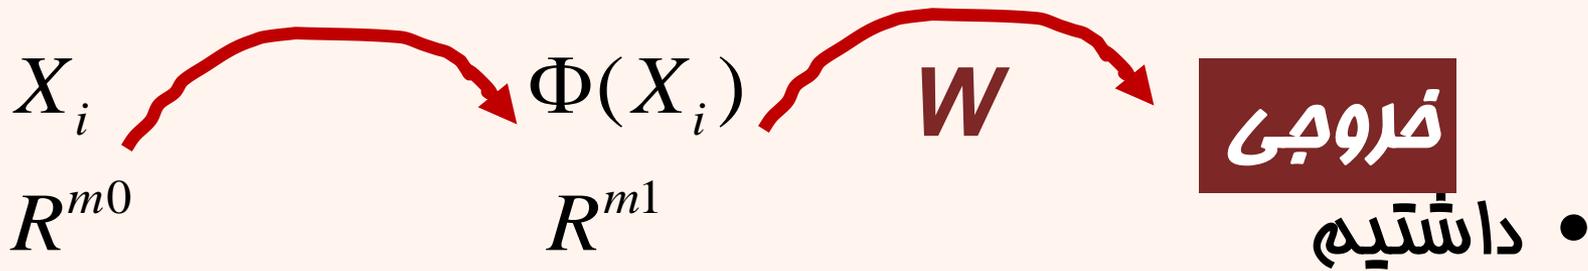


$$\Phi: X \rightarrow \phi(X)$$



ژانسیکاه
سپیدی
بهشتی

نگاشت به فضای بالاتر



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

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

$$\Phi(X) = [\varphi_1(X), \varphi_2(X), \dots, \varphi_{m1}(X)]^T$$

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

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



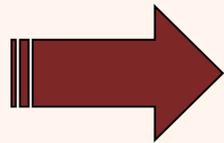
نگاشت به فضای بالاتر

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

• با فرض $\varphi_0(\mathbf{X}) = 1$

• خواهیم داشت:

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



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

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

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



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 $\varphi_i(X_i)$ در نظر گرفته می‌شود:

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

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

$\swarrow \quad \searrow$
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 در 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

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

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

$$K(X_i, X_j)$$

ماتریس متقارن

هدف یافتن ضرایب لاگراشر 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 قيود زیر

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

kernel trick

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

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

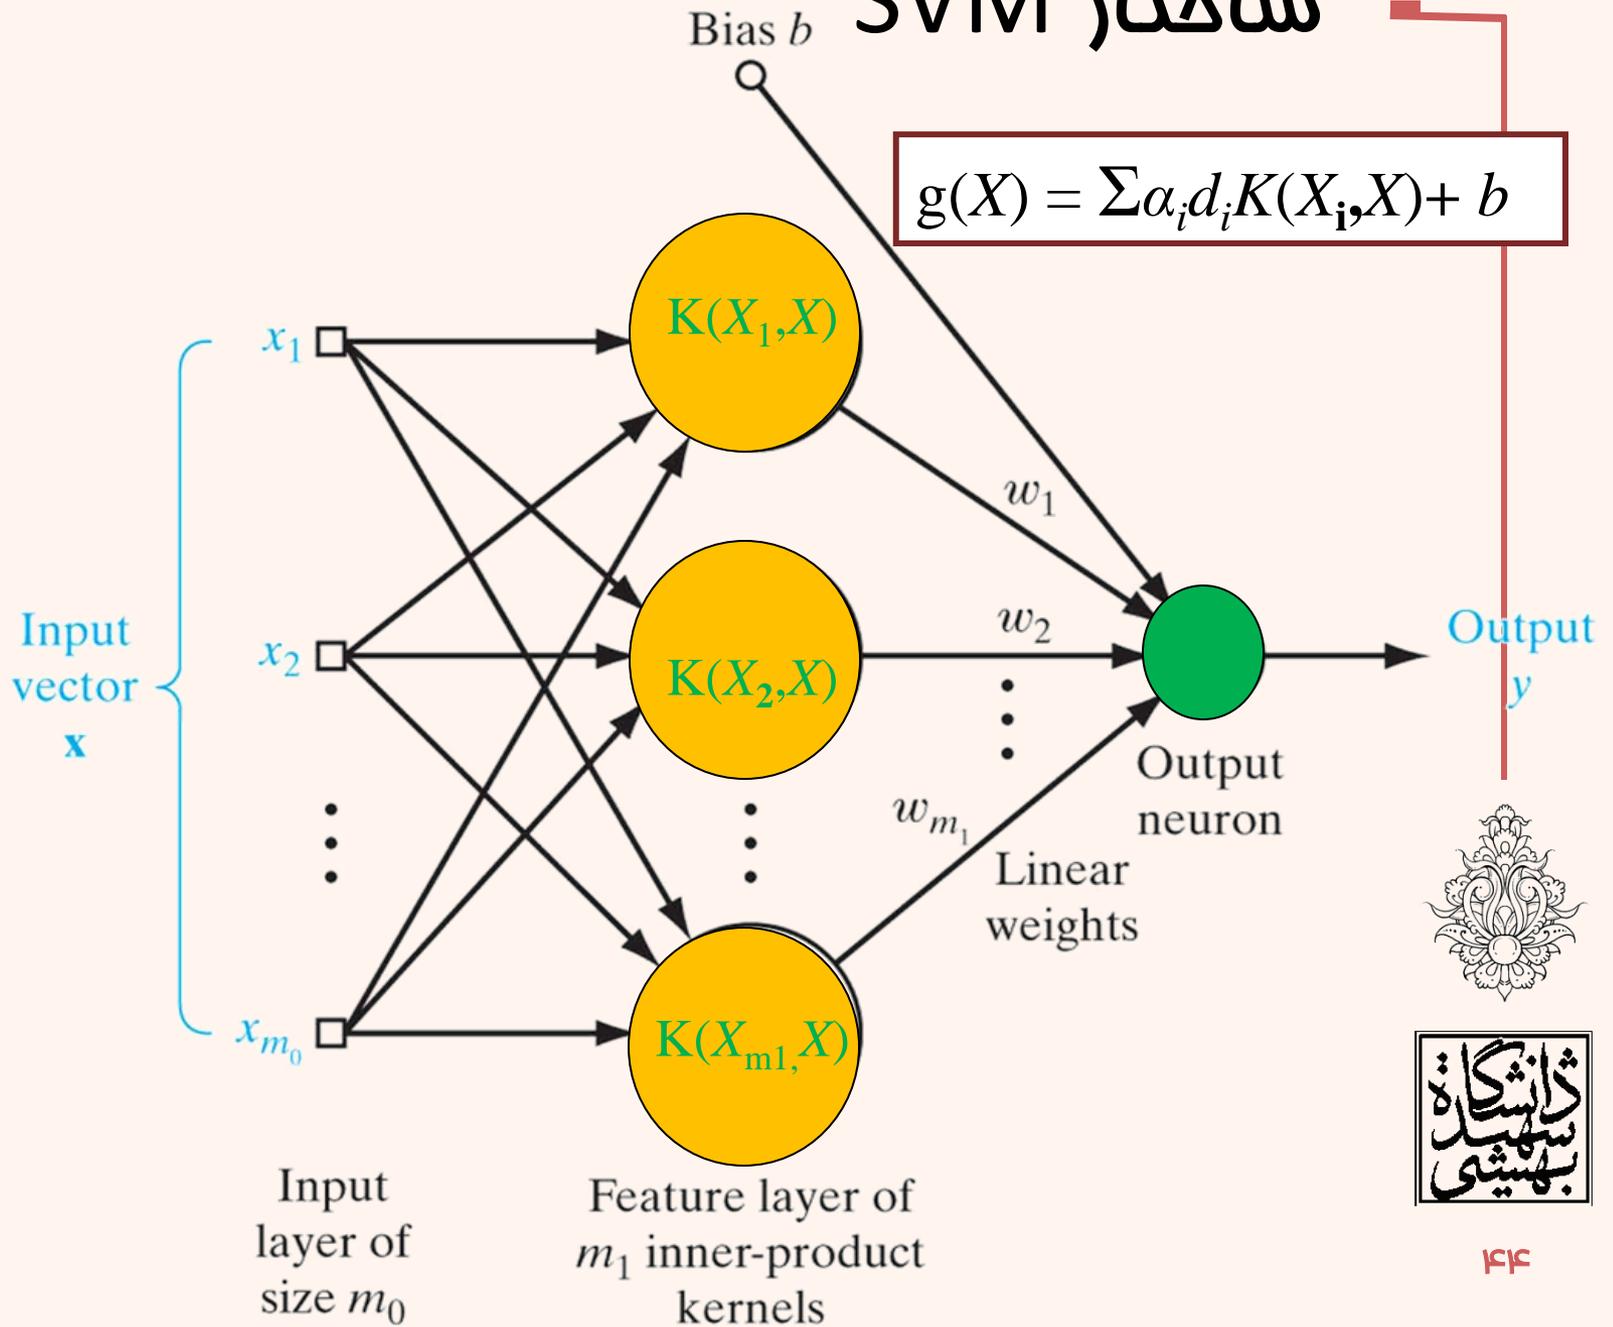
توابع نگاشت

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 σ^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 β_0 and β_1



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.



مثال XOR Problem

$$N = 4$$

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

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

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

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

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

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

• 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

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

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



XOR Problem

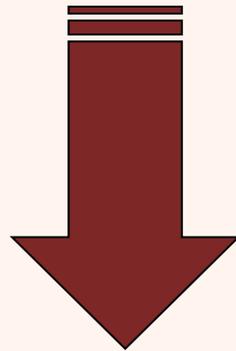
$$N = 4$$

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

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

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

• دست آوردن α_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 α 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

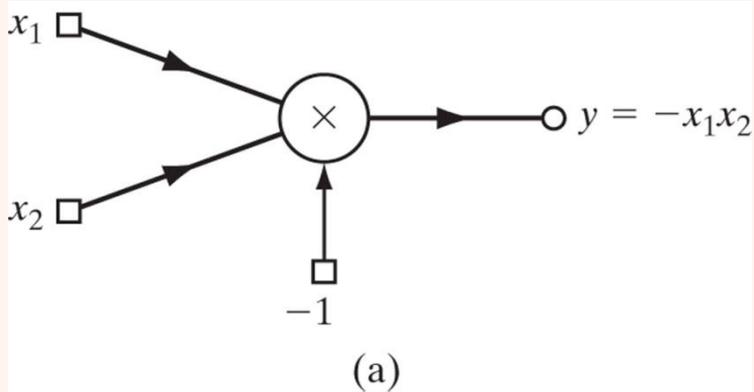
- رویه‌ی بهینه به وسیله‌ی رابطه‌ی زیر محاسبه می‌شود:

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

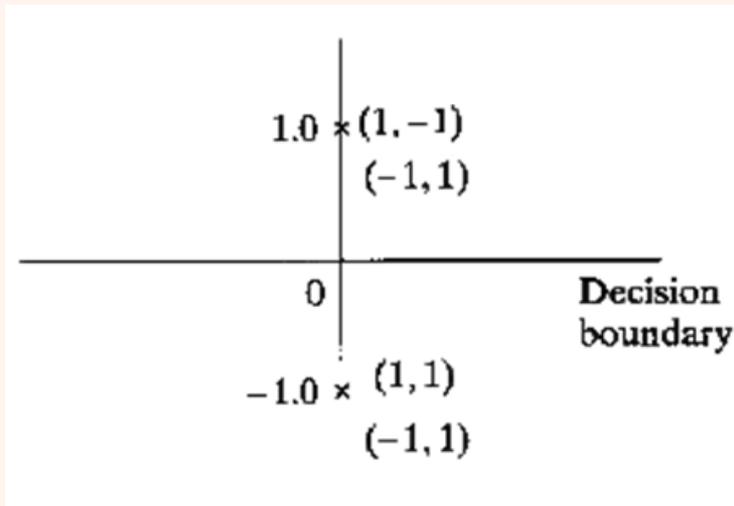
$$\begin{bmatrix} 0 & 0 & \frac{-1}{\sqrt{2}} & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ x_1^2 \\ \sqrt{2}x_1x_2 \\ x_2^2 \\ \sqrt{2}x_1 \\ \sqrt{2}x_2 \end{bmatrix} = 0 \quad \Rightarrow \quad -x_1x_2 = 0$$

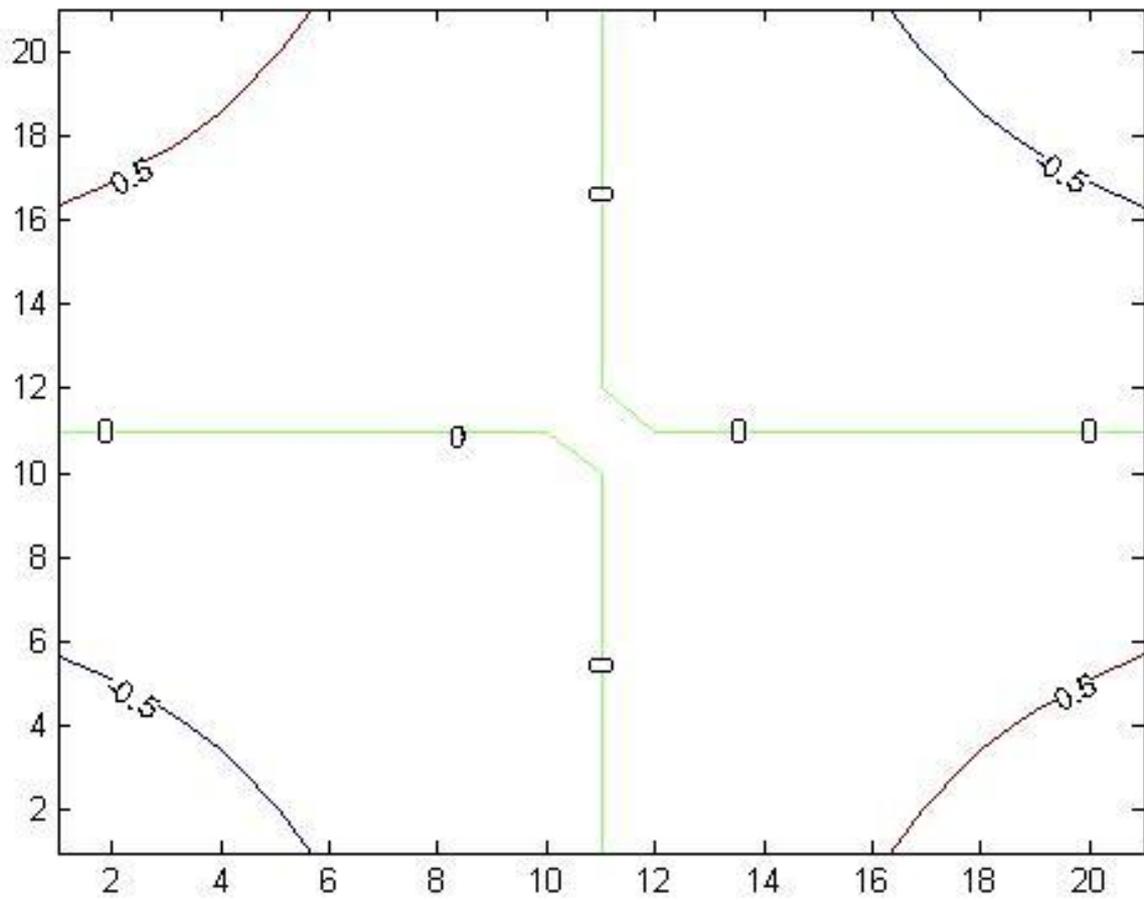


XOR Problem



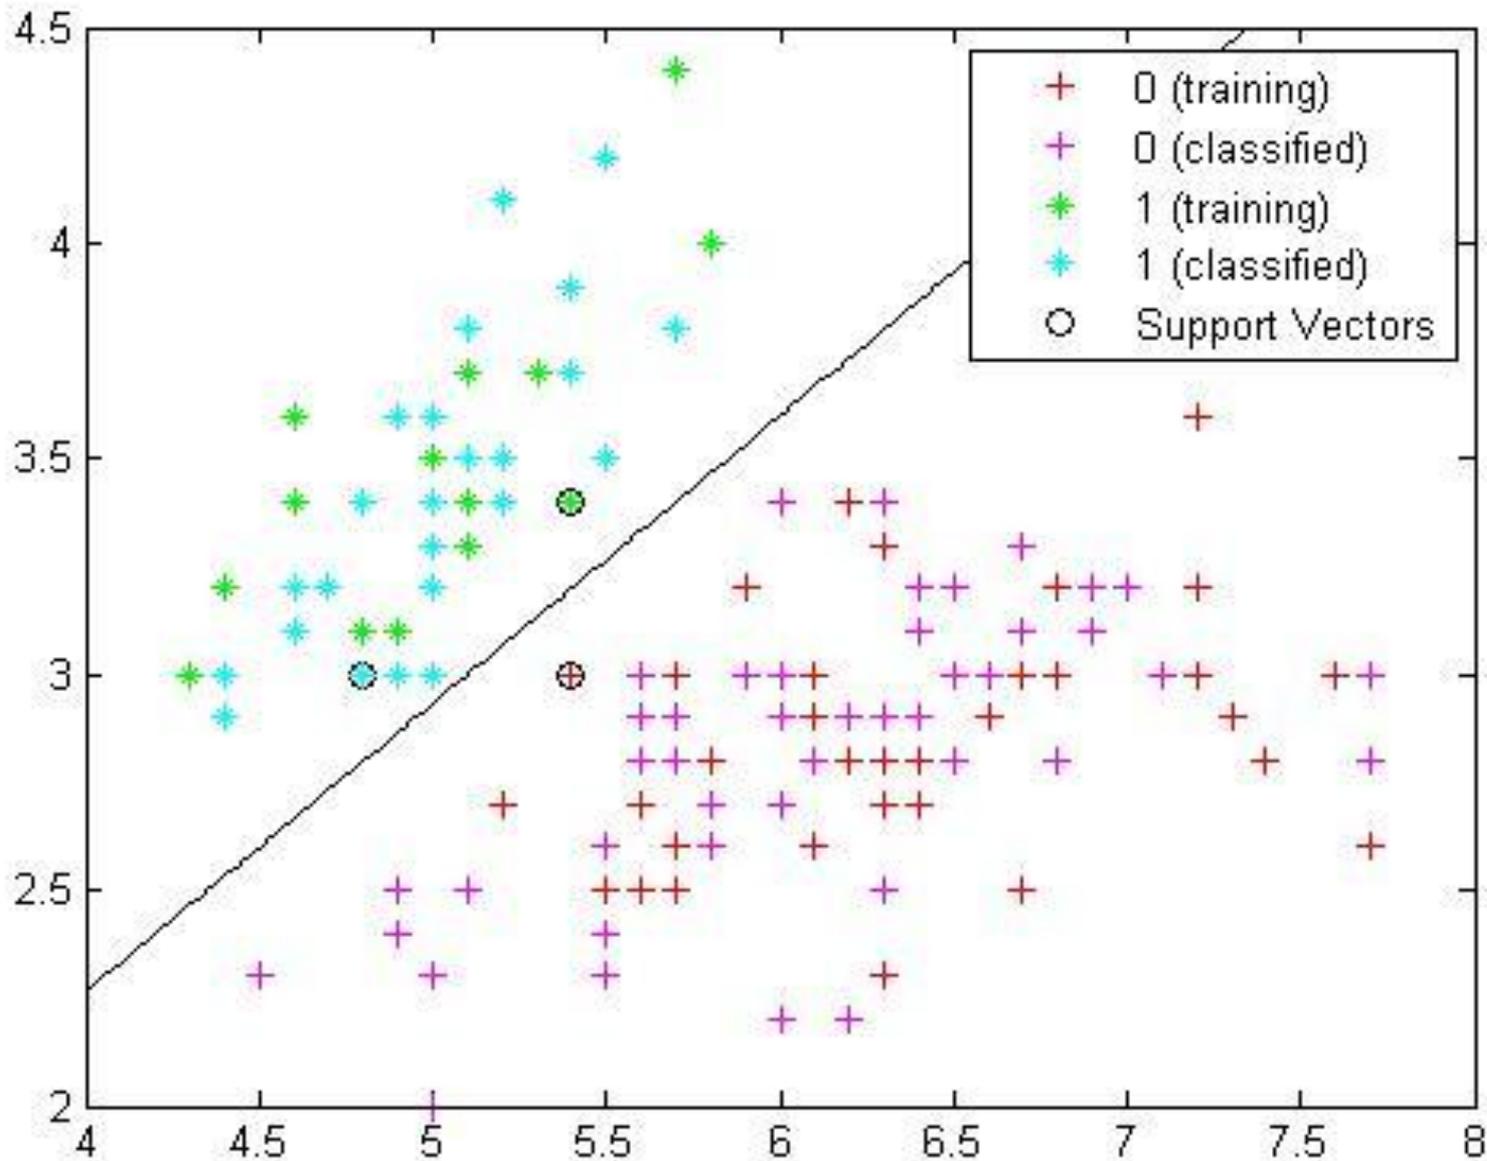
(a) Polynomial machine for solving the XOR problem. (b) Induced images in the feature space due to the four data points of the XOR problem.





```
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
```



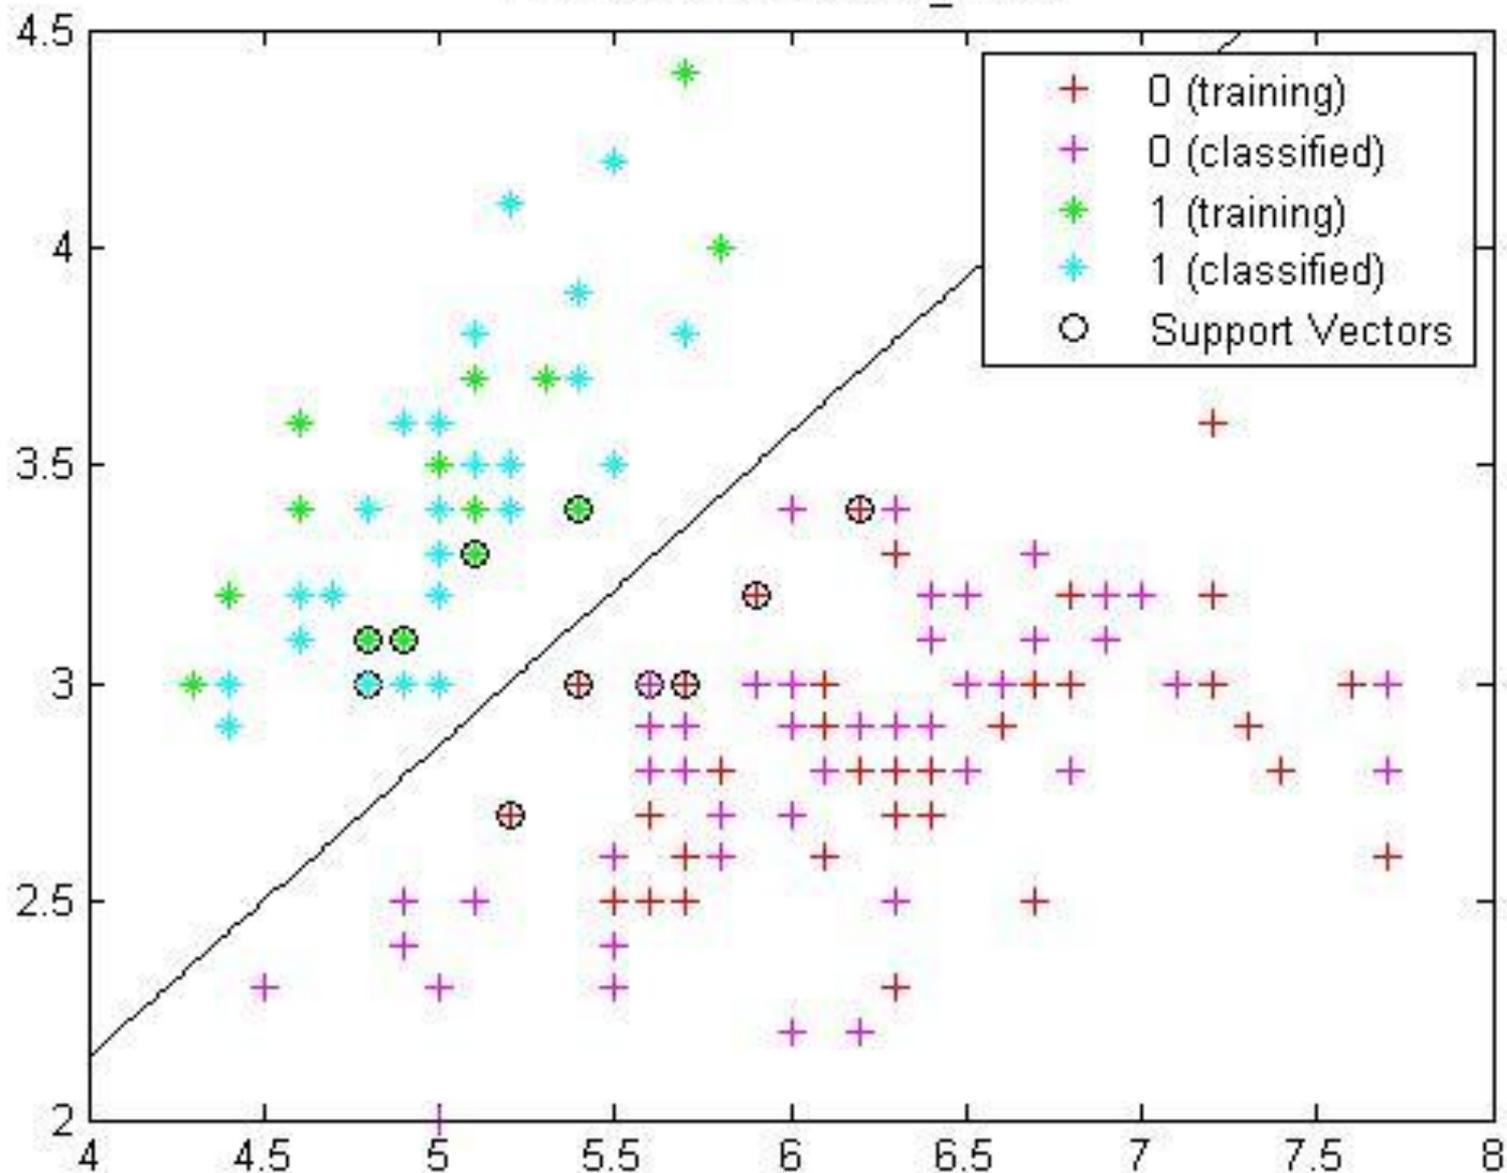




```
clear all;
close all;
load fisheriris
data = [meas(:,1), meas(:,2)];
groups = ismember(species,'setosa');
[train, test] = crossvalind('holdOut',groups);
cp = classperf(groups);
svmStruct = svmtrain(data(train,:),groups(train),'showplot',true);
title(sprintf('Kernel Function: %s',...
    func2str(svmStruct.KernelFunction),...
    '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
```



