

اللَّهُ

أَكْرَمُ



عنوان سمینار:

طبقه بندی با استفاده از ماشین بردار پشتیبان

classification by support vector machine

ارائه دهنده: زهره منوچهری

۲۵ خرداد ۱۳۹۴

# رئوس مطالب

3

۱- تعریف هوش مصنوعی و یادگیری ماشین

۲- تعریف ماشین بردار پشتیبان

۳- تاریخچه

۴- ایده اصلی ماشین بردار پشتیبان

۵- فرموله کردن مسدله

۶- دسته بندی داده های جدید

۷- svm های غیر خطی

۸- تابع کرنل

۹- مزایا و معایب svm

۱۰- خلاصه روش اجرا

۱۱- بررسی یک مقاله

۱۲- منابع مورد استفاده

# هوش مصنوعی

4

❖ هوش مصنوعی به هوشی که یک ماشین از خود نشان می دهد و یا به دانشی در کامپیوتر که سعی در ایجاد آن دارد گفته می شود.

❖ هوش مصنوعی علم و مهندسی ایجاد ماشینهایی با هوش ، با به کارگیری از کامپیوتر و الگوگیری از درک هوش انسانی و یا حیوانی و نهایتاً دستیابی به مکانیزم هوش مصنوعی در سطح هوش انسانی می باشد.

# توانمندی های هوش مصنوعی در پزشکی

## ۲- سیستم های تخصصی اطلاعات آزمایشگاه

این سیستم ها نتایج مربوط به بیماری ها را به طور اتوماتیک تفسیر و نتایج مربوط به آن را اعلام می کنند.

## ۴- هوش مصنوعی به جای پزشک در بخش مراقبت های ویژه

تیم مهندسين يك سيستم هوشمندی را ایجاد کردند تا همانند مغز یک پزشک ، نشانه های حیاتی بیمار را کنترل و سپس آن را ارزیابی و مقدار مناسب دارو های مختلف مورد نیاز را به بیمار می رساند.

## ۱- شناسایی و تشخیص بیماری

هنگامی که بیماری فرد پیچیده و نادر است یا تشخیص بیماری بر اساس بی تجربگی بوده سیستم می تواند در تشخیص به پزشک کمک کند

## ۳- تشخیص و تفسیر تصاویر پزشکی

مثلا سیستم می تواند تصاویر غیر طبیعی MRI یا انژیو گرافی غیر طبیعی را برای متوجه نمودن پزشک علامت دار کند.



# یادگیری ماشین

6

▶ یادگیری ماشین زمینه نسبتاً جدیدی از هوش مصنوعی است که در حال حاضر دوران رشد و تکامل خود را می‌گذراند. یادگیری ماشین یک زمینه تحقیقاتی بسیار فعال در علوم کامپیوتر است.

▶ علوم مختلفی با یادگیری ماشین در ارتباط هستند از جمله:

هوش مصنوعی، روانشناسی، فلسفه، تئوری اطلاعات، آمار و احتمالات، تئوری کنترل و ...

# تعریف یادگیری ماشین:

7

► یادگیری ماشین عبارت است از اینکه چگونه می توان برنامه ای نوشت که از طریق تجربه یادگیری کرده و عملکرد خود را بهتر کند.

در یادگیری ماشین با استفاده از تئوری اطلاعات ، مدل های ریاضی ساخته می شود که می توانند برای استنتاج استفاده شوند.

یادگیری با ناظر

یادگیری بدون ناظر

یادگیری تقویتی

یادگیری نیمه نظارتی

دسته بندی یادگیری



# یادگیری با ناظر

9

یادگیری تحت نظارت، یک روش عمومی در یادگیری ماشین است که در آن به یک سیستم، مجموعه‌ای از جفت‌های ورودی - خروجی ارائه شده و سیستم تلاش می‌کند تا تابعی از ورودی به خروجی را فرا گیرد. یادگیری تحت نظارت نیازمند تعدادی داده ورودی به منظور آموزش سیستم است.



## مثالی از یادگیری با ناظر

یک data base شامل قیمت ۵ خانه و مساحت خانه ها وجود دارد چگونه می توان نرخ خانه ها را بر اساس تابعی از اندازه آنها یاد گرفت؟

مساحت	قیمت
۵۶۰	۳۷
۱۰۱۲	۷۹
۸۹۳	۷۶
۲۱۹۶	۱۳۰
۹۳۶	۸۲

Input feature

مساحت خانه =  $x(i)$

Output feature

قیمت خانه =  $y(i)$

عمل یادگیری:

با داشتن یک مجموعه یادگیری می‌خواهیم تابعی بصورت  $y \rightarrow h:x$  یاد بگیریم که  
می‌تواند مقدار  $y$  را بخوبی حدس بزند. این تابع فرضیه و یا hypothesis نامیده می‌شود.

# انواع یادگیری

**Classification**: ماشین یاد می گیرد ورودی ها را به دسته های از پیش تعیین شده نسبت دهد.

**Clustering** : سیستم یادگیر کشف می کند که کدام ورودیها با هم در یک دسته قرار می گیرند.

**numeric prediction** : ماشین یاد می گیرد به جای تعیین دسته بندی یک ورودی مقدار عددی آن را پیش بینی نماید.

# رگرسیون و دسته بندی

## رگرسیون:

وقتی که تابع هدف بصورت پیوسته باشد مسئله یادگیری یک مسئله رگرسیون خواهد بود. مثل یادگیری رابطه قیمت و مساحت خانه ها

## دسته بندی (classification):

وقتی که  $\gamma$  بتواند تعداد محدودی مقدار گسسته بگیرد مسئله یادگیری یک مسئله دسته بندی خواهد بود. مثل: آیا خانه مورد نظر یک آپارتمان است؟



## تعریف: ماشین بردار پشتیبان

▶ ماشین بردار پشتیبان (support vector machines) یکی از روش های یادگیری با نظارت است که از آن برای طبقه بندی و رگرسیون استفاده می شود.

▶ این روش از جمله روشهای نسبتاً جدیدی است که در سال های اخیر کارایی خوبی نسبت به روش های قدیمی تر برای طبقه بندی از جمله شبکه های عصبی پرسپترون نشان داده است.

## تاریخچه

15

الگوریتم svm اولیه در سال ۱۹۶۳ توسط  
Vladimir vapnik ابداع شد و در سال  
۱۹۹۵ توسط او و همکارش corenna  
cortes برای حالت غیر خطی تعمیم داده  
شد.

# ایده اصلی

16

► با فرض اینکه دسته ها بصورت خطی جداپذیر باشند، ابرصفحه هائی با حداکثر حاشیه (maximum margin) را بدست می آورد که دسته ها را جدا کنند.

► در مسایلی که داده ها بصورت خطی جداپذیر نباشند داده ها به فضای با ابعاد بیشتر نگاشت پیدا می کنند تا بتوان آنها را در این فضای جدید بصورت خطی جدا نمود.

# مفهوم ابر صفحه

17

➤ <sup>1</sup> ابر صفحه یک مفهوم در هندسه است، یک تعمیم از یک صفحه در تعداد متفاوتی از

ابعاد. یک ابر صفحه یک زیر فضای  $k$  بعدی در یک فضای  $n$  بعدی تعریف می کند که

$k < n$ . مثلاً خط یک ابر صفحه یک بعدی در یک فضا با هر تعداد بعد است. در سه بعد،

صفحه یک ابر صفحه دوبعدی است و به همین ترتیب برای فضاهای با ابعاد بالاتر

ابر صفحه تعریف می شود.

➤ hyperplane


## عمل جداسازی خطی


► در SVM یک داده به صورت یک بردار  $P$  بعدی (یا یک لیست از  $P$  عدد) دیده می شود و ما می خواهیم بدانیم می توان چنین نقاطی را با یک ابرصفحه  $P-1$  بعدی جدا کرد. این عمل جداسازی خطی نامیده می شود. ابرصفحه های بسیاری وجود دارند که می توانند داده ها را جدا کنند. الگوریتم های مختلفی از جمله پرسپترون می توانند این جداسازی را انجام دهند. سوال اینجاست که چه ابرصفحه ای را انتخاب کنیم؟





# Which of the linear separators is optimal?

19










# Maximizing the Margin






# ایده SVM برای جدا سازی دسته ها


24

دو صفحه مرزی موازی با صفحه دسته بندی رسم کرده و آندو را آنقدر از هم دور میکنیم که به داده ها برخورد کنند.

صفحه دسته بندی که بیشترین فاصله را از صفحات مرزی داشته باشد، بهترین جدا کننده خواهد بود.




معادله خط در حالت دو بعدی



$$w_1 X_1 + w_2 X_2 + b = 0$$

معادله خط در حالت n بعدی




$$\sum_{i=0}^n w_i . x_i + b = 0$$

$$\vec{w}^T . \vec{x} + b = 0$$

# چرا حداکثر حاشیه؟


26

بر طبق قضیه ای در تئوری یادگیری اگر مثالهای آموزشی بدرستی دسته بندی شده باشند، از بین جداسازهای خطی، آن جداسازی که حاشیه داده های آموزشی را حداکثر میکند خطای تعمیم را حداقل خواهد کرد.



## بردار پشتیبان

➤ نزدیکترین داده های آموزشی به ابر صفحه های جدا کننده  
بردار پشتیبان نامیده می شوند.



## فرموله کردن مسئله:

28

تعدادی داده ی آموزشی داریم، یک مجموعه از نقاط به فرم:

$$D = \{(x_i, y_i) | x_i \in \mathbb{R}^p, y_i \in \{1, -1\}\} \quad i = 1, \dots, n$$

که  $y_i$  می تواند 1 یا -1 باشد، که مشخص می کند نقطه  $x_i$  متعلق به چه کلاسی است. هر  $x_i$  یک بردار  $p$  بعدی است. می خواهیم جداکننده ماکزیمم حاشیه ای پیدا کنیم که نقاطی که  $y_i$  آنها برابر 1 است از نقاطی که  $y_i$  آنها -1 است جدا کند. هر ابرصفحه می تواند به صورت یک مجموعه از نقاط  $x$  که در رابطه زیر صدق می کنند نوشته شود:

$$\langle w, x \rangle + b = 0$$

$$w_1x_1 + w_2x_2 \dots + w_nx_n + b = 0$$

► می‌خواهیم مقادیر  $w, b$  را بگونه‌ای پیدا کنیم که:

► نمونه‌های آموزشی را بدقت دسته‌بندی کند.

► با این فرض که داده‌ها بصورت خطی جدا پذیر باشند فاصله بین

ابر صفحه‌های موازی یعنی **پهنای حاشیه** را حداکثر نماید.


## معادلات ابر صفحه ها

این ابر صفحه های موازی می توانند با معادله های زیر توصیف شوند:

$$W.X + b \geq 1 \quad \forall x_i \text{ with } y_i = 1$$

9


$$W.X + b \leq -1 \quad \forall x_i \text{ with } y_i = -1$$





با استفاده از روابط هندسی پهناى حاشیه برابر است با  $\frac{2}{\|w\|}$  . بنابراین می خواهیم  $\|w\|$  را مینیمم کنیم. همچنین می خواهیم از قرارگرفتن نقاط در حاشیه جلوگیری کنیم. محدودیت زیر را نیز اضافه می کنیم:  
 برای هر  $i$  :

$$\rightarrow W \cdot X + b \geq 1 \quad \forall x_i \text{ with } y_i = 1$$



$$y_i(w \cdot x_i + b) \geq 1$$

$$\rightarrow W \cdot X + b \leq -1 \quad \forall x_i \text{ with } y_i = -1$$

► حل مسئله بهینه سازی  $\frac{2}{\|w\|}$  مشکل است، زیرا به  $\|w\|$  بستگی دارد. خوشبختانه می توان معادله را با توجه به رابطه  $\|w\| = \frac{1}{2} \|w\|^2$  بدون تغییر راه حل، جایگزین کرد (  $w$  و  $b$  های یکسانی بدست خواهد آمد).

## هدف

- Minimise  $\|w\|^2$
- Subject to :  $y_i (\langle w, x_i \rangle + b) \geq 1$  for all  $i$ 
  - Note that  $\|w\|^2 = w^T w$

این یک مسئله **quadratic programming** با محدودیت هائی بصورت نامعادلات خطی است. روشهای شناخته شده ای برای چنین مسئله هائی بوجود آمده اند.

## ضرایب لاگرانژ

ضرایب لاگرانژ یک استراتژی برای پیدا کردن مینیمم یا ماکزیمم یک تابع با توجه به محدودیت ها است.

$$\begin{cases} \left. \frac{\partial}{\partial \mathbf{x}} (f(\mathbf{x}) + \alpha g(\mathbf{x})) \right|_{\mathbf{x}=\mathbf{x}_0} = 0 \\ g(\mathbf{x}) = 0 \end{cases} \quad \begin{cases} \left. \frac{\partial}{\partial \mathbf{x}} (f(\mathbf{x}) + \sum_{i=1}^n \alpha_i g_i(\mathbf{x})) \right|_{\mathbf{x}=\mathbf{x}_0} = 0 \\ g_i(\mathbf{x}) = 0 \quad \text{for } i = 1, \dots, m \end{cases}$$

➤ در مواردیکه  $g_i(\mathbf{x}) \leq 0$  ضریب لاگرانژ  $\alpha_i$  باید مثبت شود.

$$\min_{\mathbf{x}} f(\mathbf{x}) \quad \text{subject to} \quad g_i(\mathbf{x}) \leq 0 \quad \text{for } i = 1, \dots, m$$

$$\begin{cases} \left. \frac{\partial}{\partial \mathbf{x}} (f(\mathbf{x}) + \sum_i \alpha_i g_i(\mathbf{x})) \right|_{\mathbf{x}=\mathbf{x}_0} = 0 \\ g_i(\mathbf{x}) \leq 0 \quad \text{for } i = 1, \dots, m \end{cases}$$

## راه حل معادله

► باید تابع لاگرانژ زیر را می نیم کنیم:

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

wrt.constraint  $\alpha_i \geq 0, i = 1, \dots, N$

و بنابراین از این تابع نسبت به  $w$  و  $b$  مشتق می گیریم:

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i = \mathbf{0}$$

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{\partial b} = \sum_{i=1}^N \alpha_i y_i = 0$$

$$KKT \text{ cond} : \alpha_i [y_i (\mathbf{w}\mathbf{x}_i + b) - 1] = 0$$

# The Dual Problem


اگر ما  $\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i$  و  $\sum_{i=1}^n \alpha_i y_i = 0$  را در لاگرانژ قرار دهیم خواهیم داشت:

$$\begin{aligned} \mathcal{L} &= \frac{1}{2} \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i^T \sum_{j=1}^n \alpha_j y_j \mathbf{x}_j + \sum_{i=1}^n \alpha_i \left( 1 - y_i \left( \sum_{j=1}^n \alpha_j y_j \mathbf{x}_j^T \mathbf{x}_i + b \right) \right) \\ &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j + \sum_{i=1}^n \alpha_i - \sum_{i=1}^n \alpha_i y_i \sum_{j=1}^n \alpha_j y_j \mathbf{x}_j^T \mathbf{x}_i - b \sum_{i=1}^n \alpha_i y_i \\ &= -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j + \sum_{i=1}^n \alpha_i \end{aligned}$$

که این تنها تابعی از  $\alpha_j$  خواهد بود.

به این دلیل dual Problem نامیده می شود چون اگر  $\mathbf{w}$  را پیدا کنیم همه  $\alpha_i$  بدست می آیند و بالعکس.

ضرایب  $\alpha_i$  متغیرهای دو گان (dual variables) نامیده می شوند .  
 هر کدام از نقاط آموزشی  $(\mathbf{x}_i)$  متغیر دو گان مربوط به خود را دارند.



# The Dual Problem

مسئله اصلی primal problem نامیده می شود.  
بنابراین dual Problem به صورت زیر است که باید maximum شود!!!

$$\begin{aligned} \max. \quad W(\alpha) &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ \text{subject to } \alpha_i &\geq 0, \quad \sum_{i=1}^n \alpha_i y_i = 0 \end{aligned}$$

که این یک مسئله Quadratic Programming است.

بعد از اینکه  $\alpha_i$  بدست آمد  $w$  نیز از  $\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i$  بدست می آید.  $b$  نیز با جایگذاری در معادله اولیه بدست می آید.



## دسته بندی داده های جدید

پس از آنکه مقادیر  $(a^*, b^*)$  با حل معادلات quadratic بر اساس داده های ورودی بدست آمد، می توان SVM را برای دسته بندی نمونه های جدید بکار برد. اگر  $x$  یک نمونه جدید باشد، دسته بندی آن بصورت زیر مشخص می شود:


→  $\text{sign}[f(x, a^*, b^*)]$ , where

$$f(\mathbf{x}, \alpha^*, b^*) = \mathbf{w}^* \mathbf{x} + b^* = \sum_{i=1}^N \alpha_i^* y_i \mathbf{x}_i \mathbf{x} + b^* = \sum_{i \in SV} \alpha_i^* y_i \mathbf{x}_i \mathbf{x} + b^*$$

Data enters only  
in the form of  
dot products!

## متغیر slack

- اگر داده‌ی آموزشی به صورت خطی قابل جداسازی نبود متغیر کمکی را می‌توان اضافه کرد تا اجازه‌ی جداسازی اشتباه را برای نمونه‌های نویزی بدهد. متغیرهای کمکی اجازه می‌دهند بعضی از نمونه‌ها درون حاشیه قرار بگیرند اما آنها را جریمه می‌کند. این متغیرها انحراف یک نقطه داده از جداکننده ایده‌آل آن را اندازه می‌گیرند.
- این کار با معرفی متغیر  $\xi_i$  انجام می‌شود که متغیر slack نامیده می‌شود که تقریبی از



► فرمول جدید شامل متغیرهای کمکی به صورت زیر درمی آید:

► 
$$\phi(\vec{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i$$

► 
$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i$$

► عبارت  $C \sum_{i=1}^N \xi_i$  حداکثر تعداد خطا را تعیین می کند. هرچه  $C$  بزرگ تر باشد

حساسیت بیشتری نسبت به خطاهایی که اجازه می دهیم اتفاق بیافتد، در نظر گرفته می شود. به  $C$  پارامتر تنظیم کننده گفته می شود و باید توسط کاربر انتخاب شود.


► برای مسئله فوق نیز تکنیک های برنامه نویسی درجه دو استفاده شده مقادیر  $a$  به دست می آید.

## svm های غیر خطی: فضای ویژگی (Feature Space)

مجموعه داده هایی که به طور خطی قابل جداسازی هستند با مقداری نویز خوب


کار می کنند. اما اگر مجموعه داده ما خیلی پیچیده بود چه؟

شکل زیر را در نظر بگیرید:



این مجموعه داده را نمی توان به سادگی با یک خط دسته بندی کرد. در این

موارد از نداشتن به فضایی با ابعاد بالاتر استفاده می شود.



چرا انتقال می دهیم؟

• عملگرهای خطی در فضای ویژگی معادل عملگرهای غیرخطی در فضای ورودی هستند (در نتیجه با نگاشت تغییری در مسئله ایجاد نمی کنیم).

• جداسازی با انتقال مناسب راحت تر است.

➤ برای انتقال ابتدا تابع  $\varphi(x)$  را برای نگاشت به فضای دیگر، پیدا می کنیم. سپس فرمول SVM به صورت زیر تغییر می یابد:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad \text{➤}$$

➤ با توجه به محدودیت زیر:

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \forall x_i, \xi_i \geq 0 \quad \text{➤}$$

➤ فضای نگاشت اصلی همواره می تواند به فضای ویژگی با ابعاد بالاتر دیگری که مجموعه آموزشی قابل جداسازی باشد، نگاشت یابد. انجام محاسبات در فضای ویژگی چون ابعاد بیشتری دارد می تواند پرهزینه باشد. در حالت کلی این فضا بی نهایت است. برای غلبه بر این مشکل از حقه کرنل استفاده می شود.

➤ Kernel trick



## تابع کرنل

44

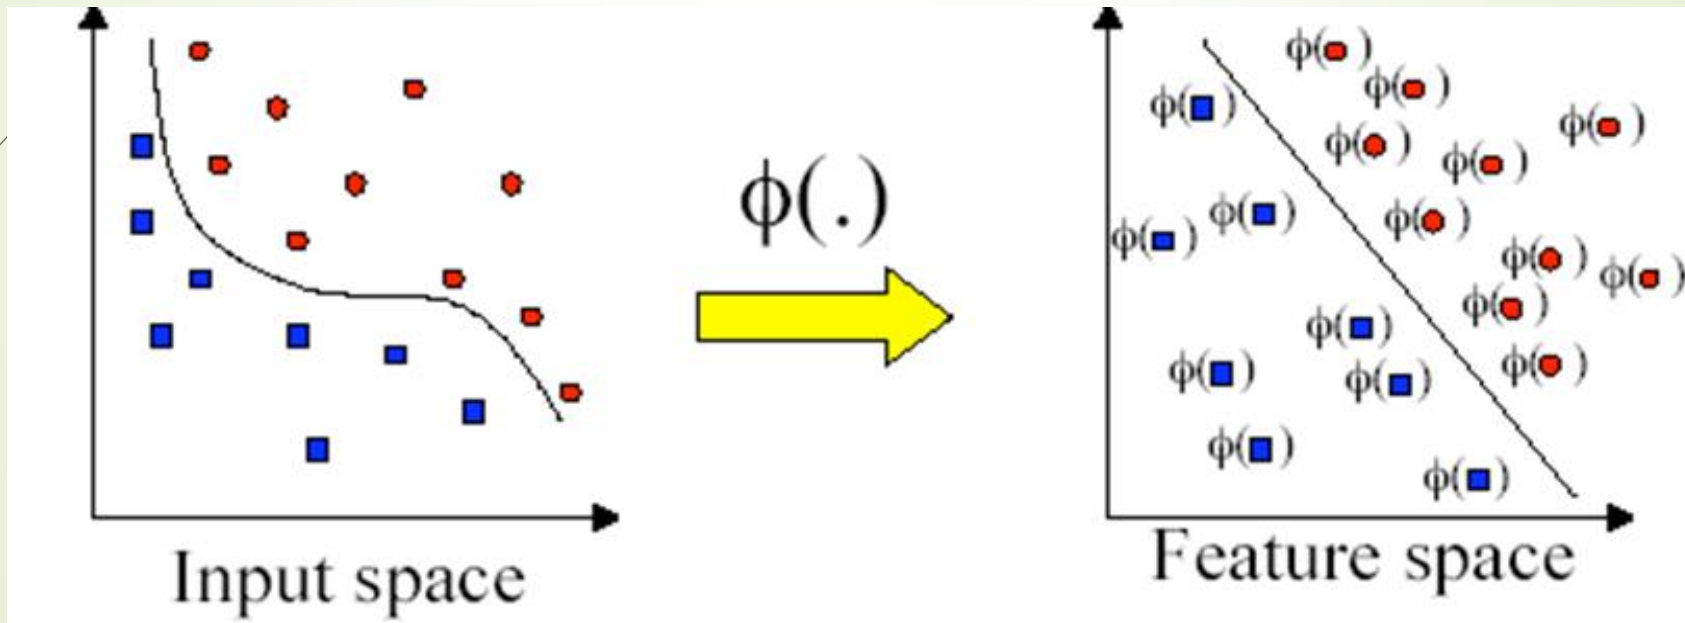
- ▶ تابع کرنل، یک جداکننده خطی متکی بر ضرب داخلی بردارهاست که به صورت
- ▶  $k(x_i, x_j) = x_i^T x_j$  می باشد. اگر نقاط با استفاده از انتقال  $\varphi: x \rightarrow \varphi(x)$  به فضای ویژگی (فضای با ابعاد بالاتر) انتقال یابند، ضرب داخلی آنها به صورت

$$k(x_i, x_j) = \varphi(x_i)^T \cdot \varphi(x_j) \quad \blacktriangleright$$

تبدیل خواهد شد. بنابراین ما از محاسبه ی  $\varphi(x)$  خودداری کرده و به جای آن از تابع کرنل استفاده می کنیم.



انتخاب کرنل های غیرخطی به ما اجازه ی ساخت جداکنندهای خطی در فضای ویژگی را می دهد در صورتی که آنها در فضای اصلی غیرخطی هستند.



# متداول ترین توابع کرنل

□ Linear kernel:



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

□ Polynomial kernel:



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

□ Gaussian (Radial-Basis Function (RBF) ) kernel:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right)$$

□ Sigmoid:



$$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\beta_0 \mathbf{x}_i^T \mathbf{x}_j + \beta_1)$$

با استفاده از توابع کرنل مسئله به فرم زیر تبدیل خواهد شد:

$$\max. Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j k(\vec{x}_i, \vec{x}_j) \quad \blacktriangleright$$

$$s.t: \sum_{i=1}^N \alpha_i y_i = 0 \quad , 0 \leq \alpha_i \leq C \text{ for } i = 1, \dots, N \quad \blacktriangleright$$

# کاربردهای svm

48

➤ در اقتصاد : پیش بینی رکود

➤ تشخیص صورت : دسته بندی و کاهش ویژگی برای تشخیص سریع صورت

➤ انتخاب ژن در دسته بندی سرطان

➤ شناسایی گفتار

➤ شناسایی الگو

➤ ...

## مزایا و معایب svm

49

❖ آموزش نسبتا ساده است

❖ برای داده های با ابعاد بالا تقریبا خوب جواب می دهد.

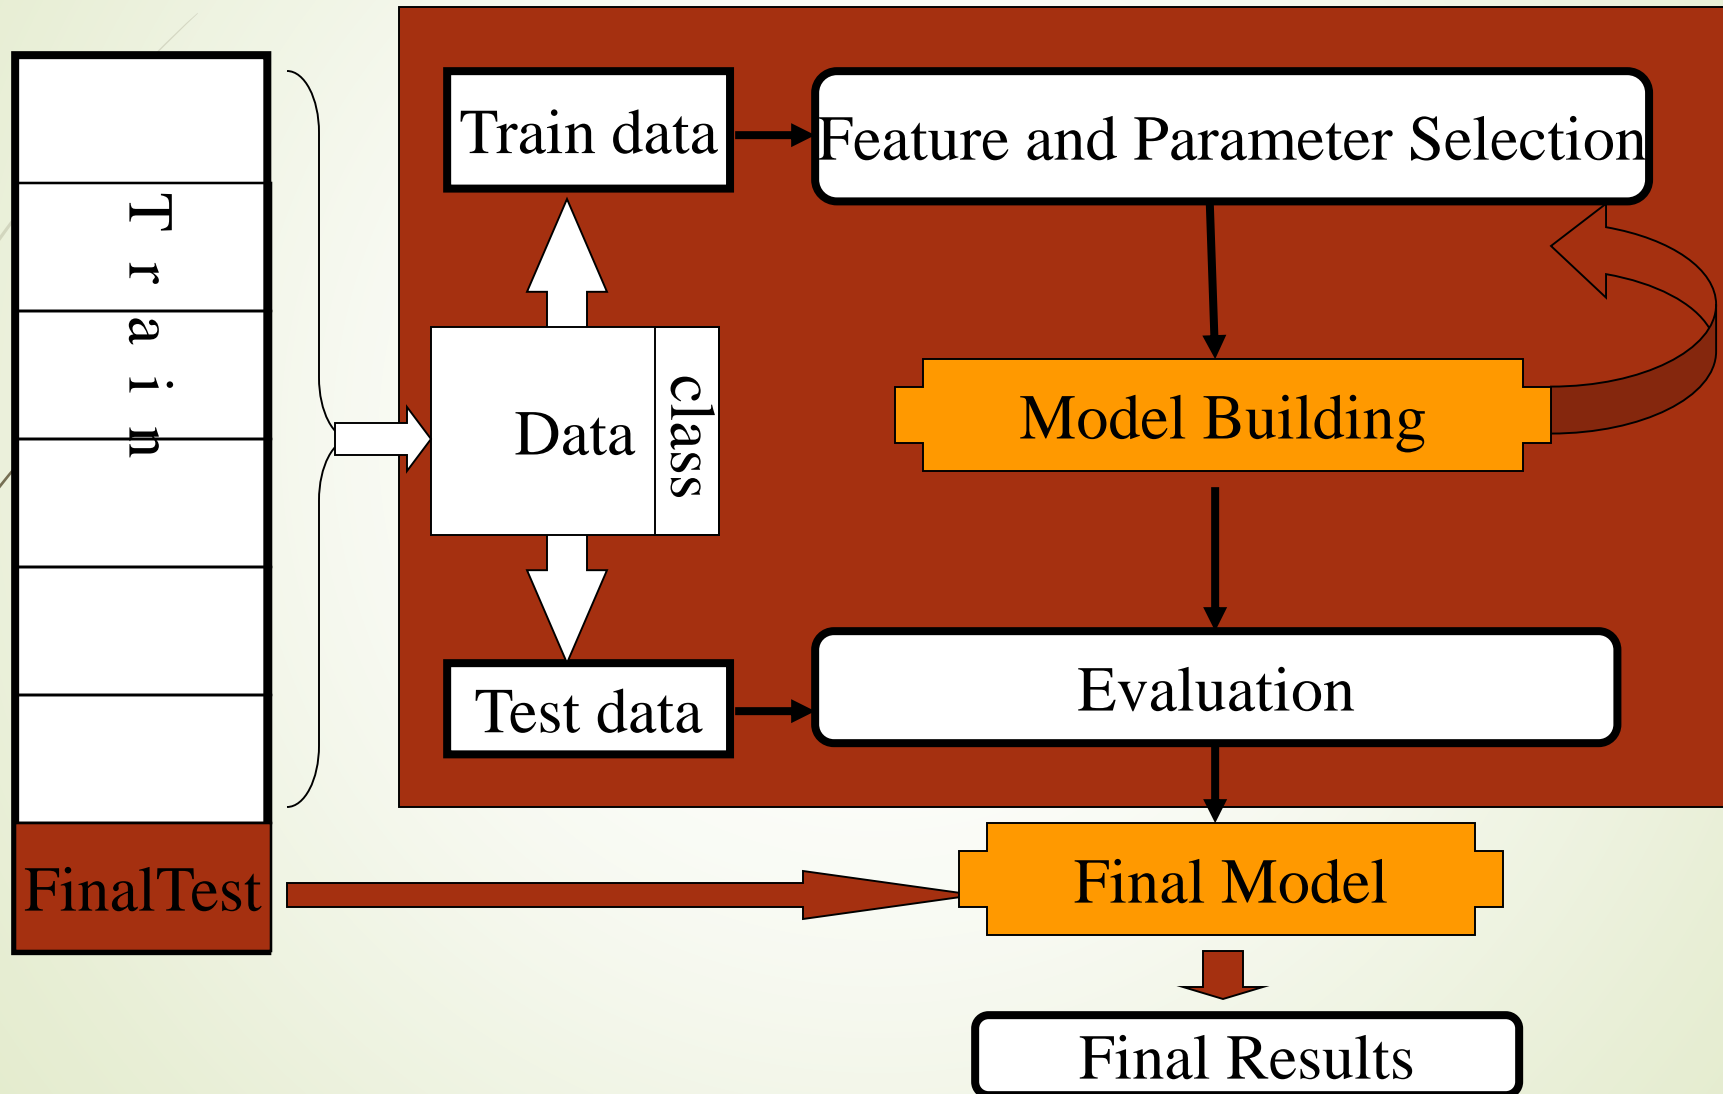
❖ مصالحه بین پیچیدگی دسته بندی کننده و میزان خطا به طور واضح کنترل می شود.

❖ به یک تابع کرنل خوب و انتخاب پارامتر  $C$  نیاز دارد.

## خلاصه روش اجرا

50

- I. ماتریس الگو را آماده می کنیم.
- II. تابع کرنلی را برای استفاده انتخاب می کنیم.
- III. پارامتر تابع کرنل و مقدار  $C$  را انتخاب می کنیم.
- IV. برای محاسبه  $\alpha_i$  مقادیر الگوریتم آموزشی را با استفاده از حل کننده های  $QP$  اجرا می کنیم.
- V. داده های جدید با استفاده از مقادیر  $\alpha_i$  و بردارهای پشتیبان می توانند دسته بندی شوند





The image shows a MATLAB interface with three main panels:

- Current Folder:** Shows the current directory as 'SVM' and a file named 'mydata.mat' under the 'MAT File' section.
- Command Window:** Contains the command `>> load mydata` and the prompt `fx >>`.
- Workspace:** Displays the variables loaded from the file. It shows a table with the following data:

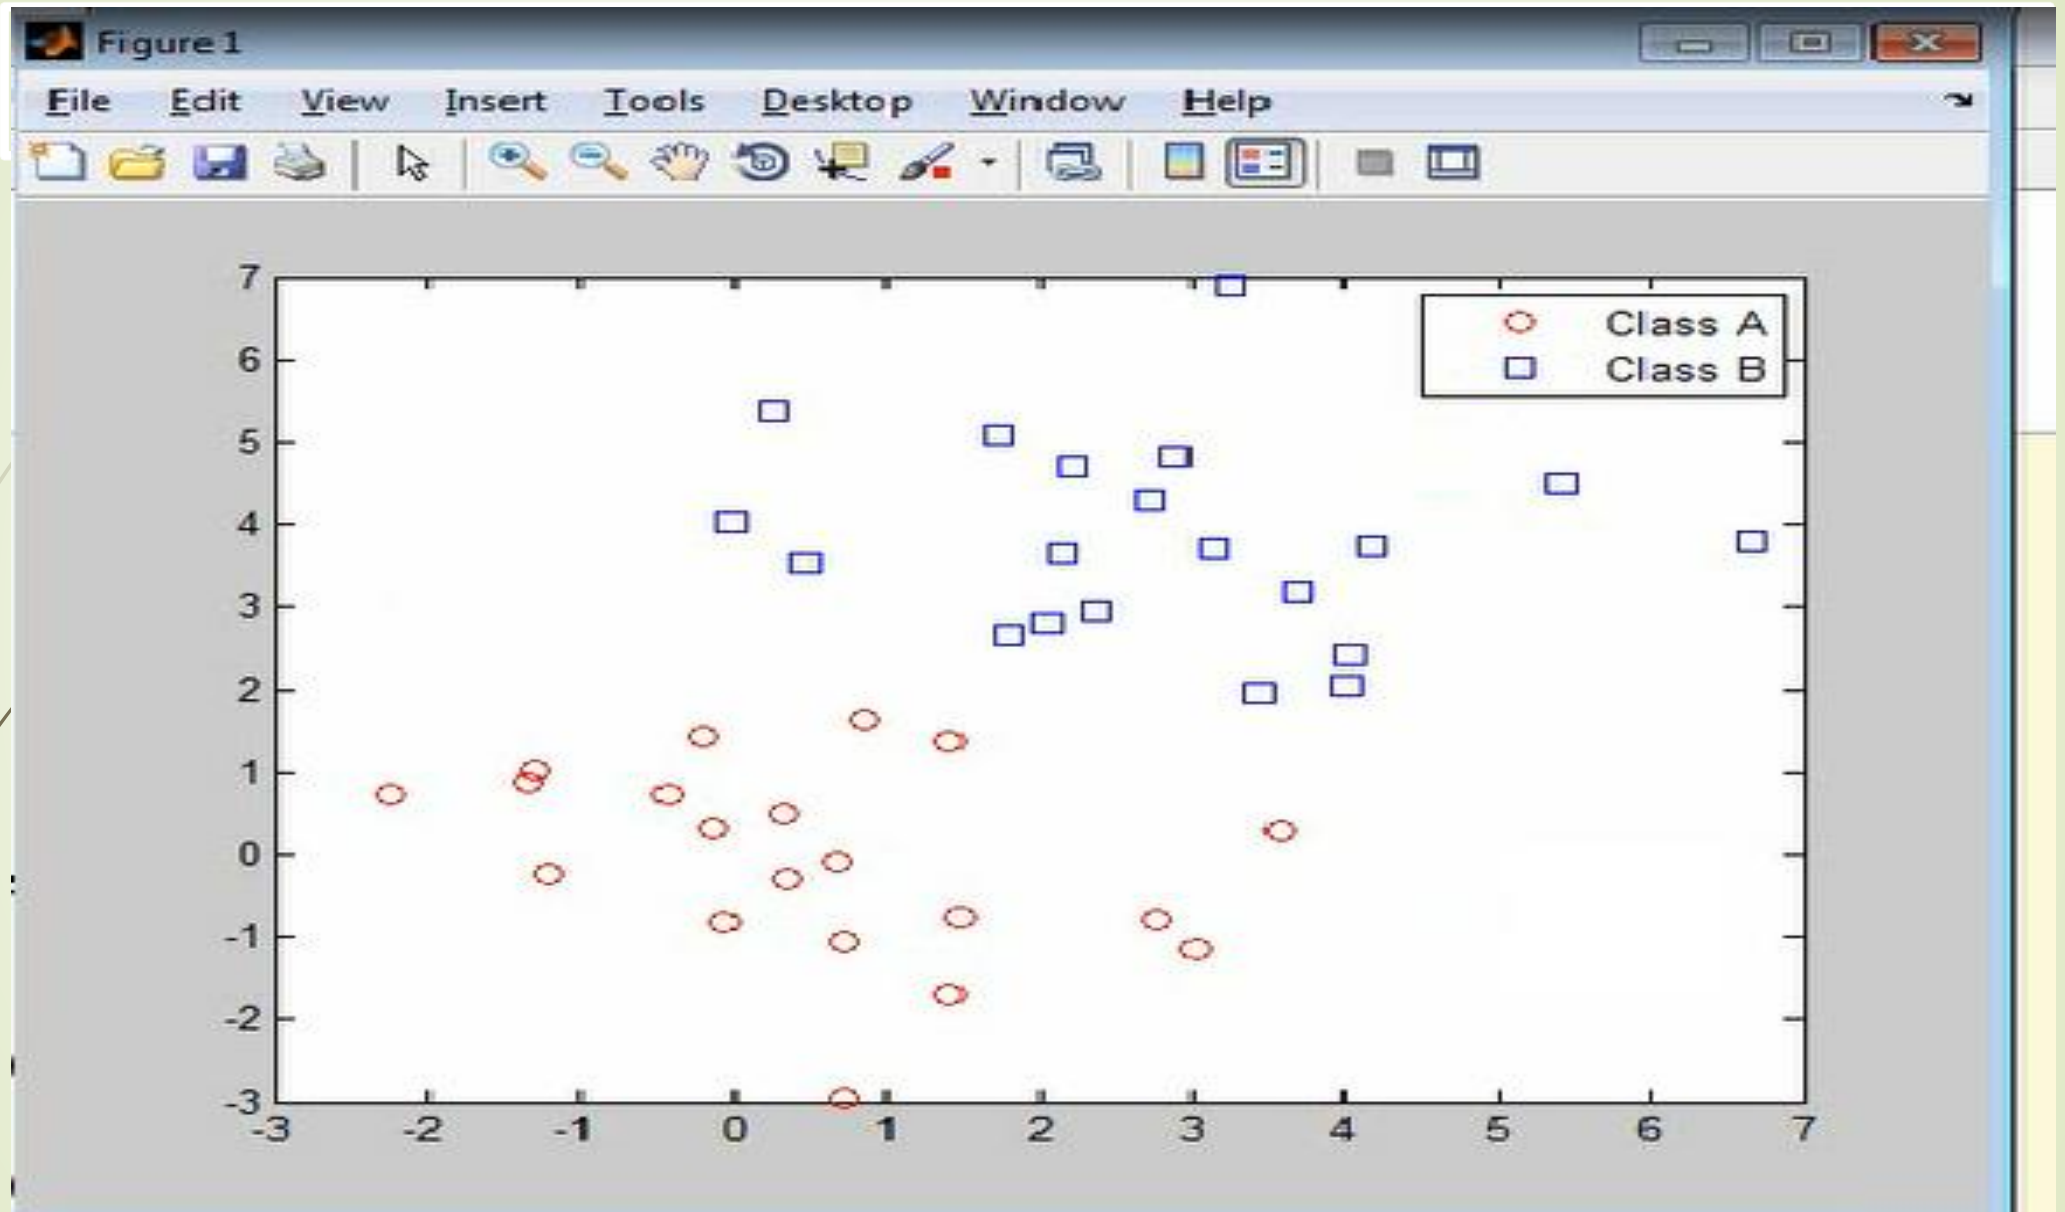
Name	Value
x	<2x40 double>
y	<1x40 double>
- Command History:** Shows the command `load mydata` executed on 5/31/2012 at 5:11.

```
>> [x' y']
```

```
ans =
```

```
-2.2588    0.7172    1.0000  
 0.8622    1.6302    1.0000  
 0.3188    0.4889    1.0000  
-1.3077    1.0347    1.0000  
-0.4336    0.7269    1.0000  
 0.3426   -0.3034    1.0000  
 3.5784    0.2939    1.0000  
 2.7694   -0.7873    1.0000  
-1.3499    0.8884    1.0000  
 3.0349   -1.1471    1.0000  
 0.7254   -1.0689    1.0000  
-0.0631   -0.8095    1.0000  
 0.7147   -2.9443    1.0000  
-0.2050    1.4384    1.0000  
-0.1241    0.3252    1.0000  
 4.0214    2.0391   -1.0000  
 6.6564    3.8023   -1.0000  
 2.0569    2.7922   -1.0000  
 3.2649    6.9080   -1.0000  
 2.8833    4.8252   -1.0000  
 0.2663    5.3790   -1.0000  
 2.3792    2.9418   -1.0000  
 0.4619    3.5314   -1.0000  
 4.1885    3.7275   -1.0000  
 1.7441    5.0984   -1.0000  
 3.1416    3.7221   -1.0000  
 2.2299    4.7015   -1.0000  
 3.4292    1.9482   -1.0000  
 2.1510    3.6462   -1.0000  
 3.6829    3.1764   -1.0000
```

```
1  clc;
2  clear;
3  close all;
4
5  %% Load Data
6
7  load mydata;
8
9  n=numel(y);
10
11  ClassA=find(y==1);
12  ClassB=find(y==-1);
13
14  figure;
15  plot(x(1,ClassA),x(2,ClassA),'ro');
16  hold on;
17  plot(x(1,ClassB),x(2,ClassB),'bs');
18  legend('Class A','Class B');
19  |
20
```





The image shows the MATLAB R2012a interface. The Command Window displays the following text:

```
speed up its evaluation and avoid the need to loop  
over array elements.  
> In specgraph\private\ezplotfeval at 57  
  In ezplot>ezimplicit at 256  
  In ezplot at 154  
  In svm3 at 86  
Warning: Function failed to evaluate on array  
inputs; vector inputs may  
speed up its evaluation and avoid the need to loop  
over array elements.  
> In specgraph  
  In ezplot>e  
  In ezplot a  
  In svm3 at  
Warning: Func  
inputs; vecto  
speed up its  
over array el  
> In specgraph\private\ezplotfeval at 57  
  In ezplot>ezimplicit at 256  
  In ezplot at 154  
  In svm3 at 92
```

A context menu is open over the warning message, listing the following options:

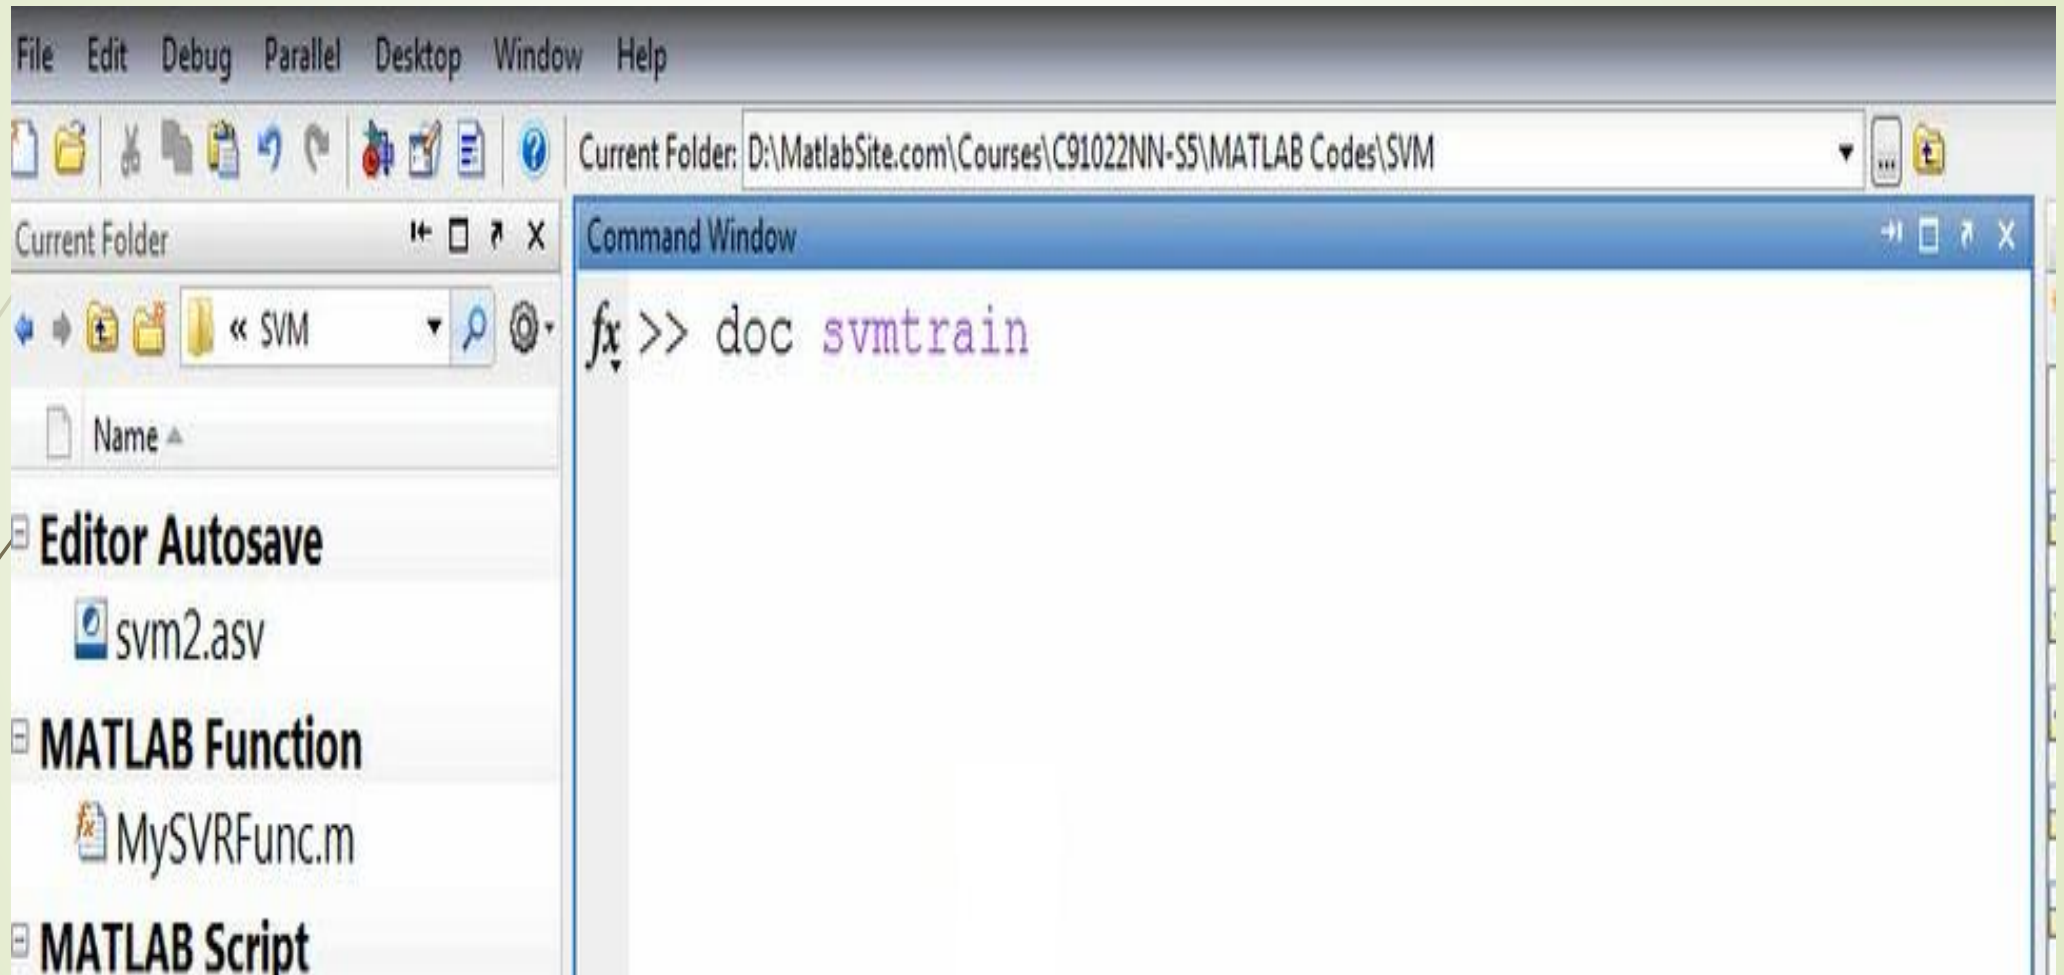
- Evaluate Selection (F9)
- Open Selection (Ctrl+D)
- Help on Selection (F1)
- Function Browser (Shift+F1)
- Show Function Browser Button
- Function Hints (Ctrl+F1)
- Cut (Ctrl+X)
- Copy (Ctrl+C)
- Paste (Ctrl+V)
- Clear Command Window

The left sidebar shows the following file structure:

- Editor Autosave
  - svm2.asv
- MATLAB Function
  - MySVRFunc.m
- MATLAB Script
  - svm1.m
  - svm2.m
  - svm3.m
- MAT File
  - mydata.mat

The status bar at the bottom left shows "svm1.m (MATLAB Script)".

چطور می توان از توابع موجود در تولباکس bio informatic برای پیاده سازی svm استفاده کرد؟





Contents Search Results

- ⊕ GFFAnnotation Methods
- ⊕ GTFAnnotation Methods
- ⊕ HeatMap Methods
- ⊕ Clustergram Methods
- ⊕ ExpressionSet Methods
- ⊕ ExptData Methods
- ⊕ DataMatrix Methods
- ⊕ MetaData Methods
- ⊕ MIAME Methods
- ⊖ Statistical Learning
  - fx classperf - Evaluate performance of
  - fx crossvalind - Generate cross-validat
  - fx knnclassify - Classify data using nec
  - fx knnimpure - Impute missing data us
  - fx optimalleaforder - Determine optim
  - fx randfeatures - Generate randomized
  - fx rankfeatures - Rank key features by
  - fx svmclassify - Classify using support
  - fx **svmtrain** - Train support vector mac

fx Bioinformatics Toolbox Functions Statistical Learning svmtrain

## svmtrain

Train support vector machine classifier

### Syntax

```
SVMStruct = svmtrain(Training, Group)
SVMStruct = svmtrain(Training, Group, Name, Value)
```

### Description

[SVMStruct](#) = svmtrain([Training](#), [Group](#)) returns a structure, SVMStruct, containing information about the trained support vector machine (SVM) classifier.

[SVMStruct](#) = svmtrain([Training](#), [Group](#), [Name](#), [Value](#)) returns a structure with additional options specified by one or more Name, Value pair arguments.

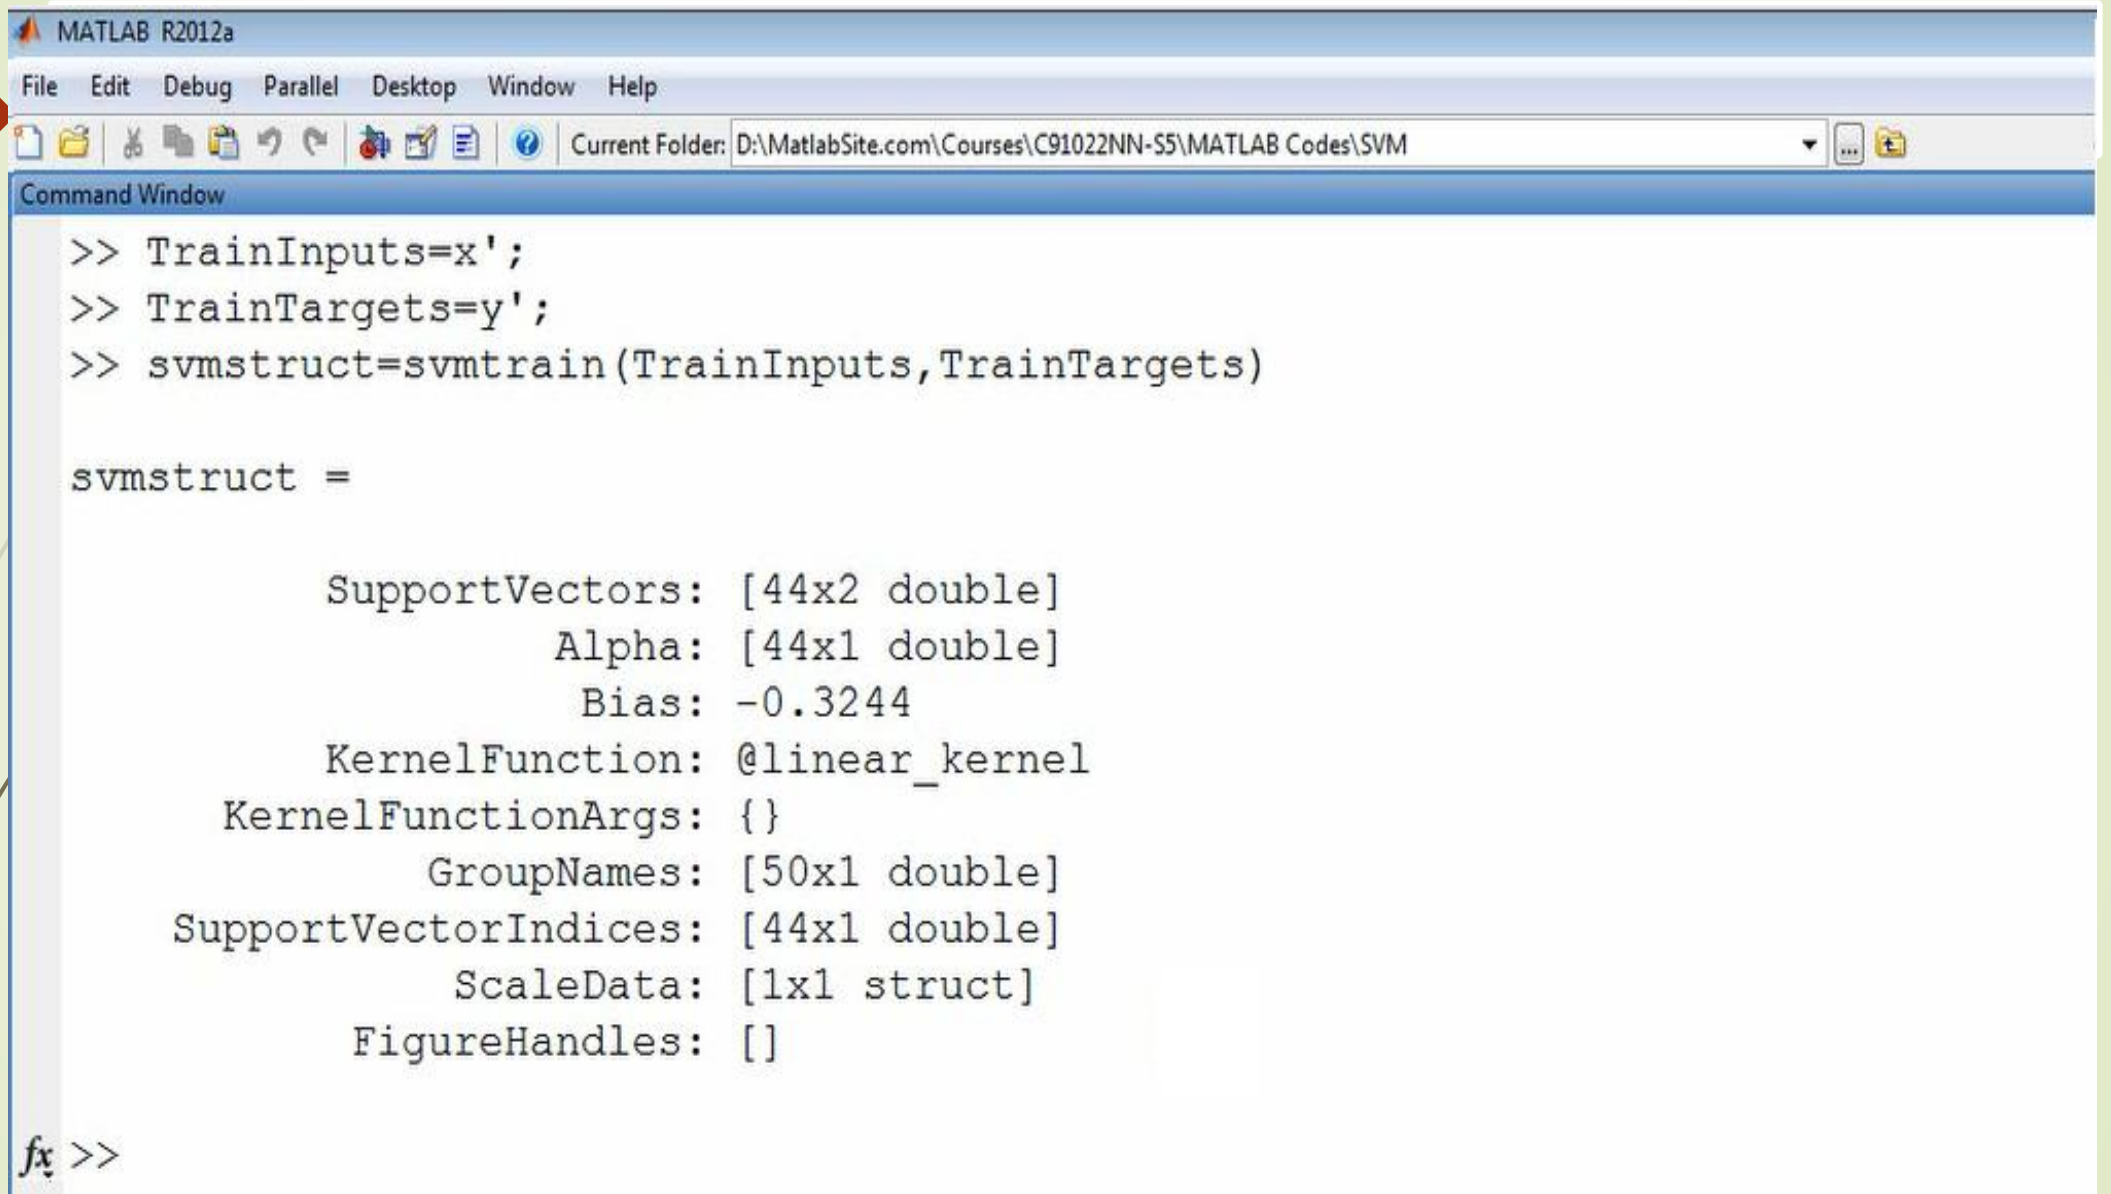
### Tips

- To classify new data, use the result of training, SVMStruct, with the [svmclassify](#) function.

### Input Arguments

**Training** Matrix of training data, where each row corresponds to an observation or replicate, and each column corresponds to a feature or variable. svmtrain treats NaNs or empty strings in Training as missing values and ignores the corresponding rows of Group

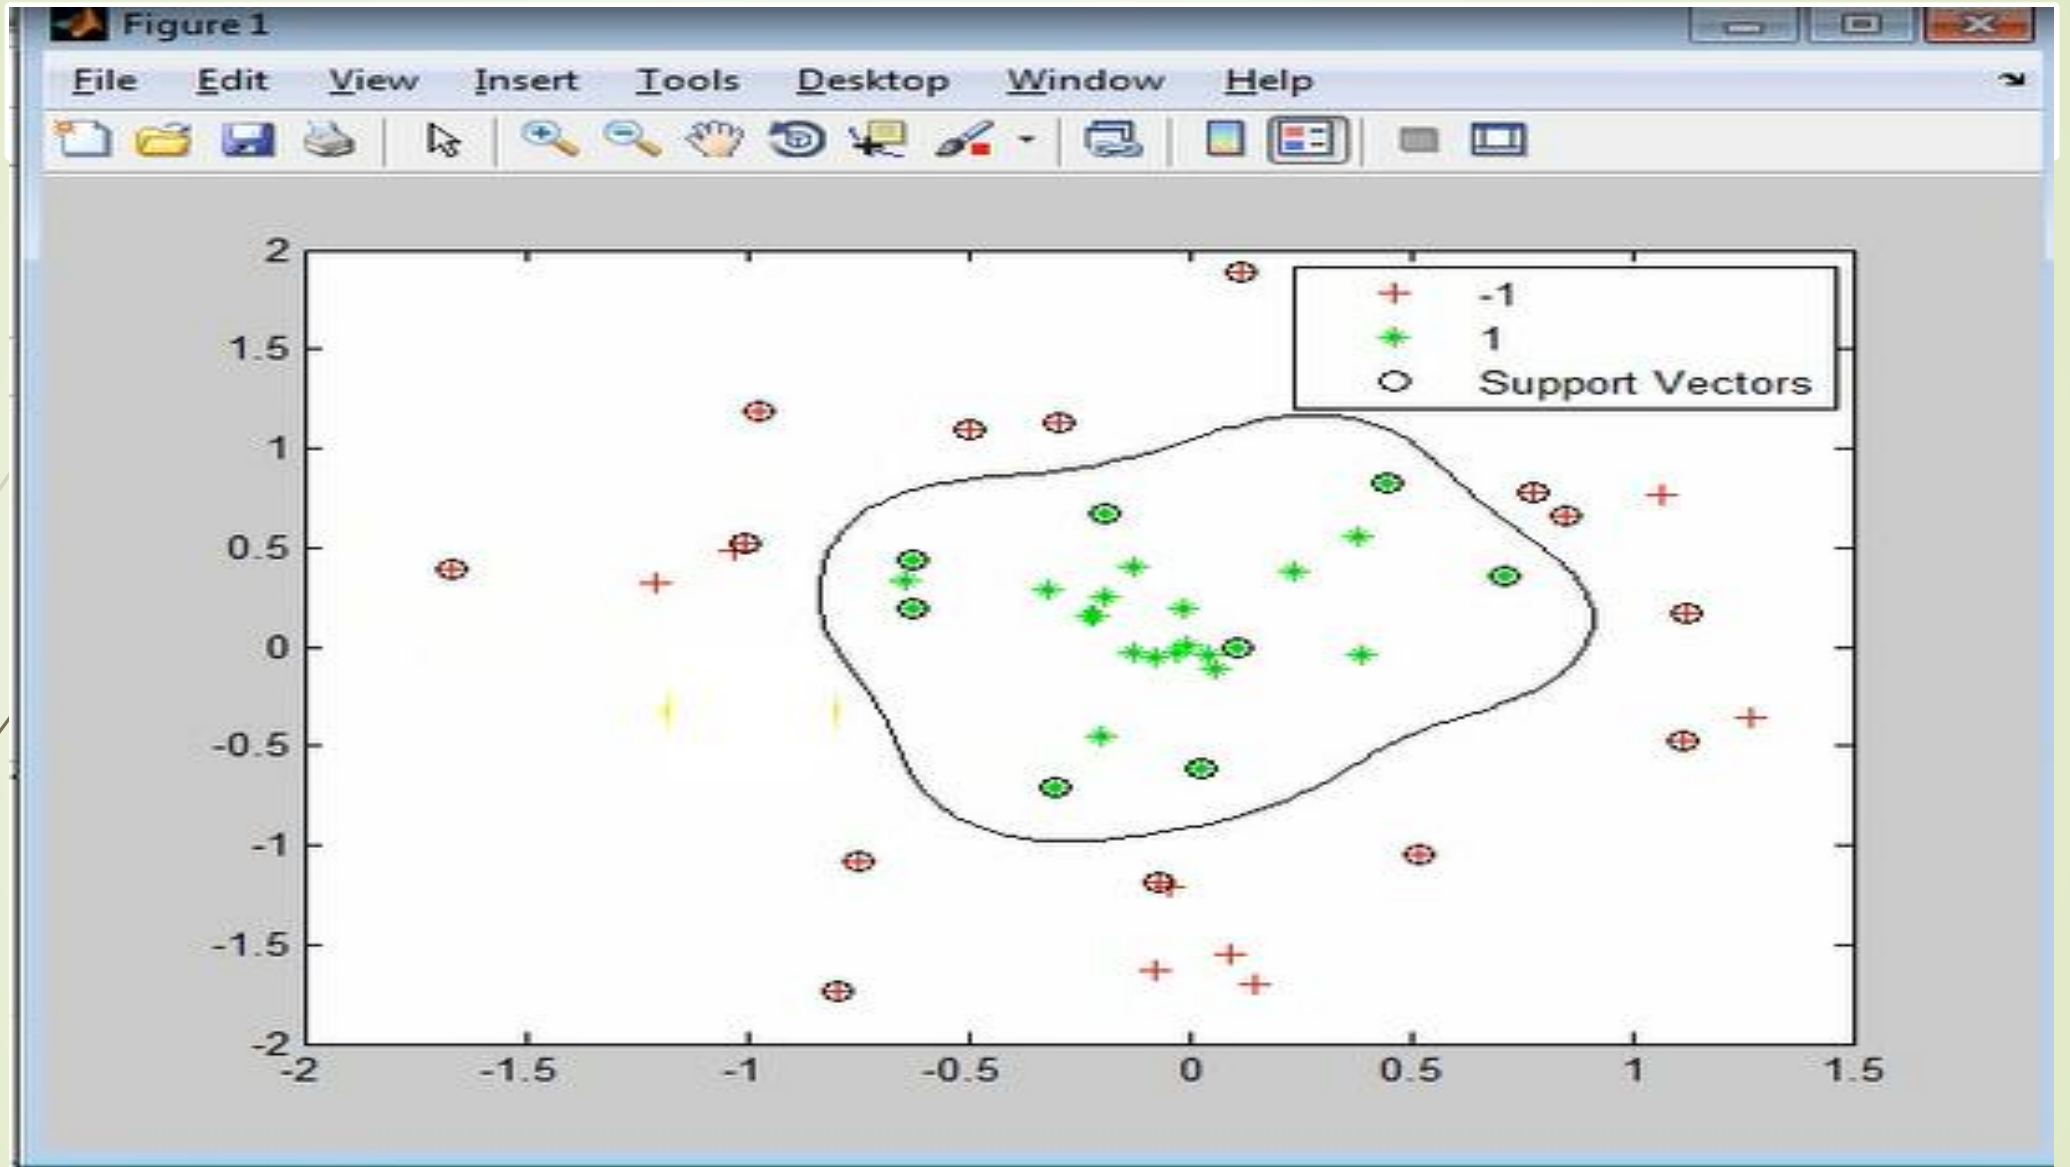


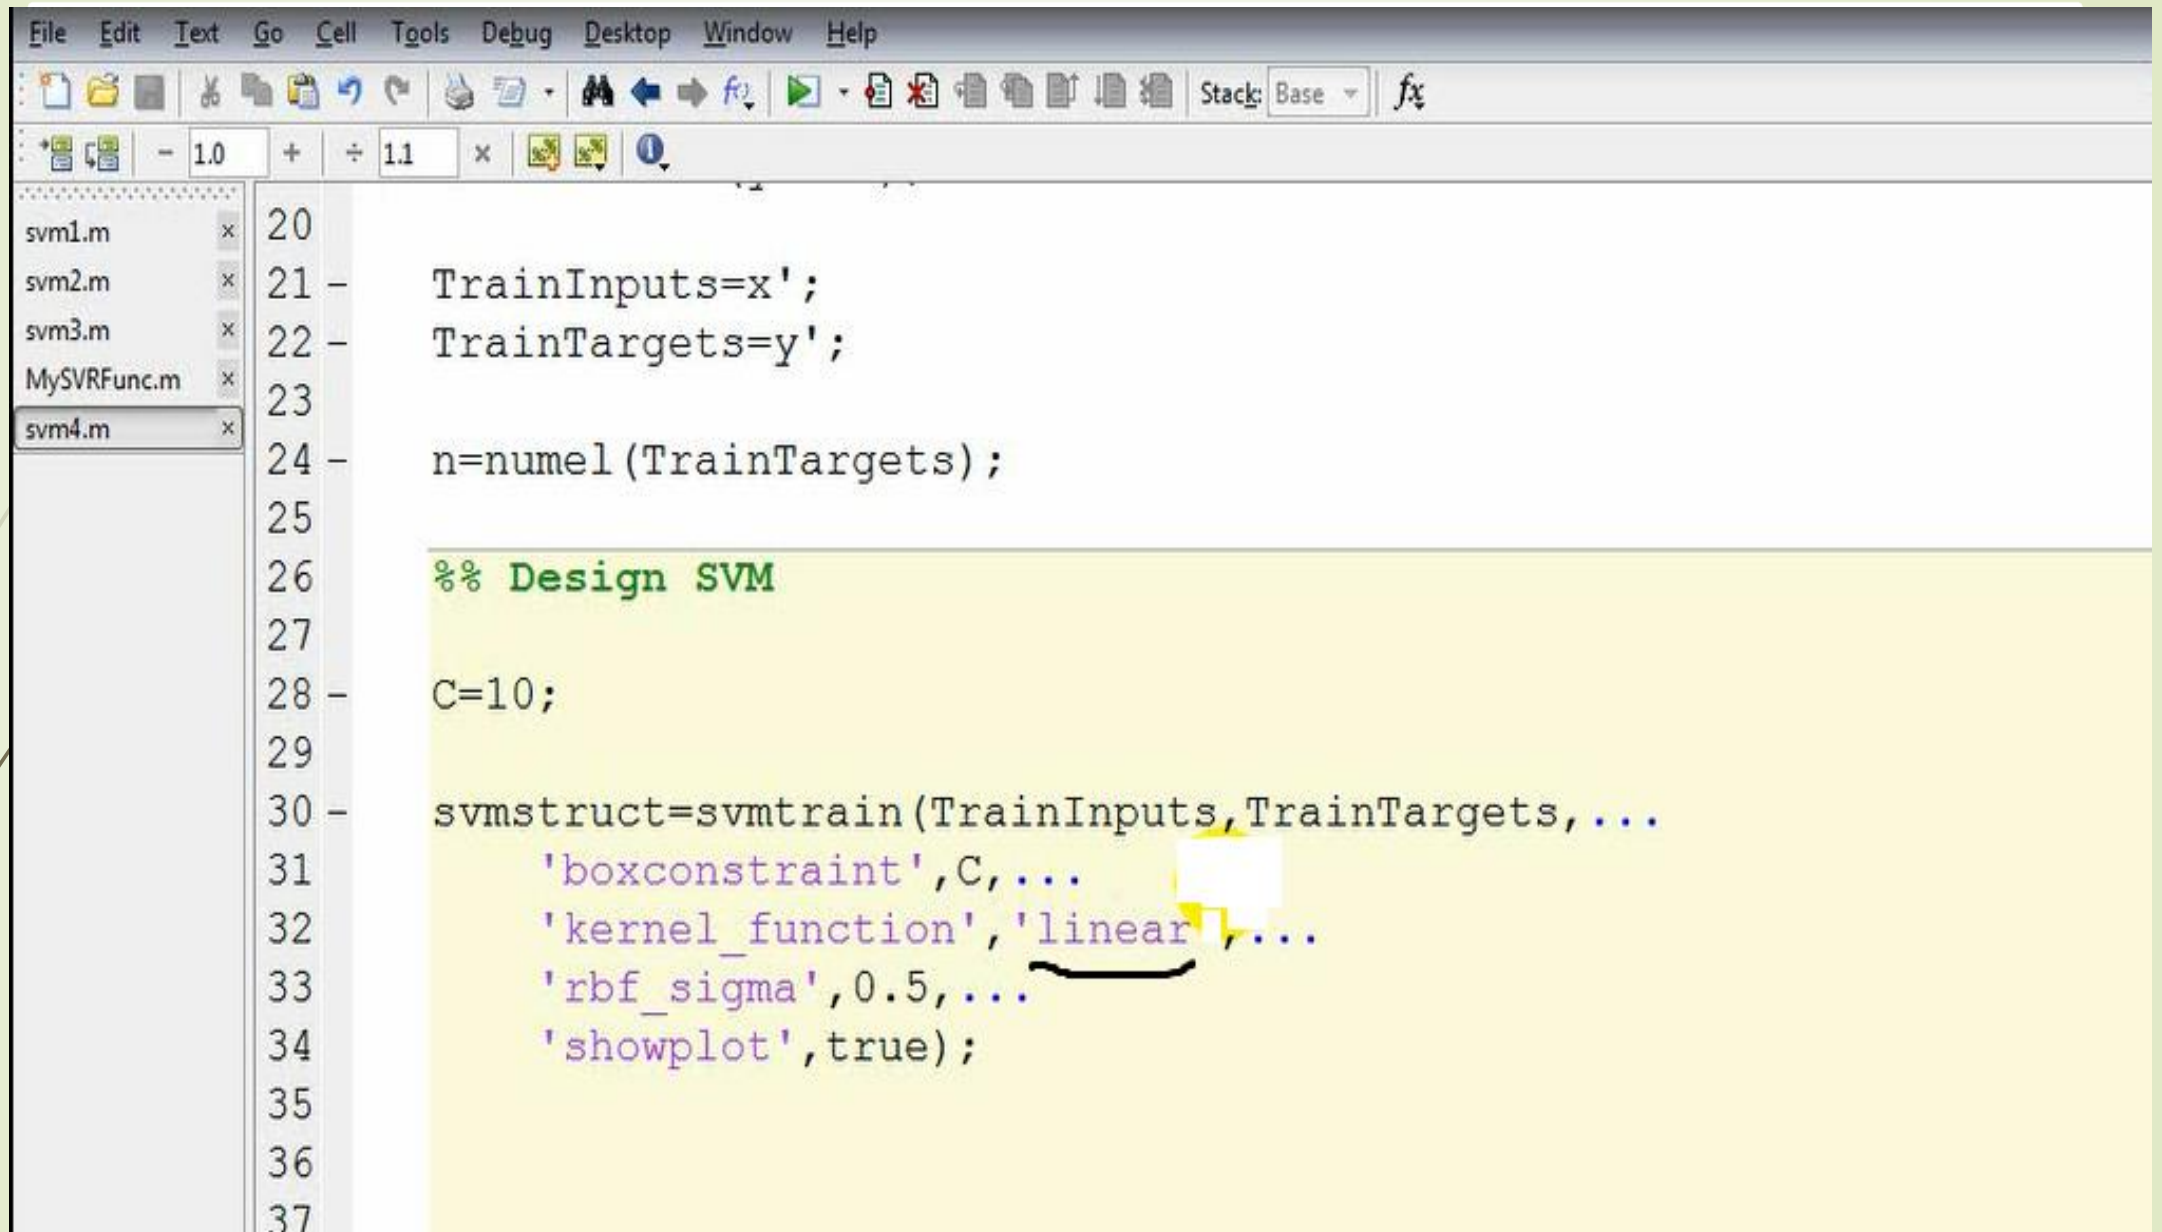


The image shows a MATLAB R2012a Command Window. The title bar reads "MATLAB R2012a". The menu bar includes "File", "Edit", "Debug", "Parallel", "Desktop", "Window", and "Help". The current folder is "D:\MatlabSite.com\Courses\C91022NN-S5\MATLAB Codes\SVM". The Command Window contains the following code and output:

```
>> TrainInputs=x';  
>> TrainTargets=y';  
>> svmstruct=svmtrain(TrainInputs,TrainTargets)  
  
svmstruct =  
  
    SupportVectors: [44x2 double]  
           Alpha: [44x1 double]  
           Bias: -0.3244  
    KernelFunction: @linear_kernel  
    KernelFunctionArgs: {}  
           GroupNames: [50x1 double]  
SupportVectorIndices: [44x1 double]  
           ScaleData: [1x1 struct]  
           FigureHandles: []  
  
fx >>
```

```
svm3.m x 18 - ClassA=find(y==1);  
MySVRFunc.m x 19 - ClassB=find(y==-1);  
svm4.m x 20  
21 - TrainInputs=x';  
22 - TrainTargets=y';  
23  
24 - n=numel(TrainTargets);  
25  
26 %% Design SVM  
27  
28 - C=10;  
29  
30 - svmstruct=svmtrain(TrainInputs,TrainTargets,...  
31     'boxconstraint',C,...  
32     'kernel_function','rbf',...  
33     'rbf_sigma',0.5,...  
34     'showplot',true);  
35  
36  
37
```



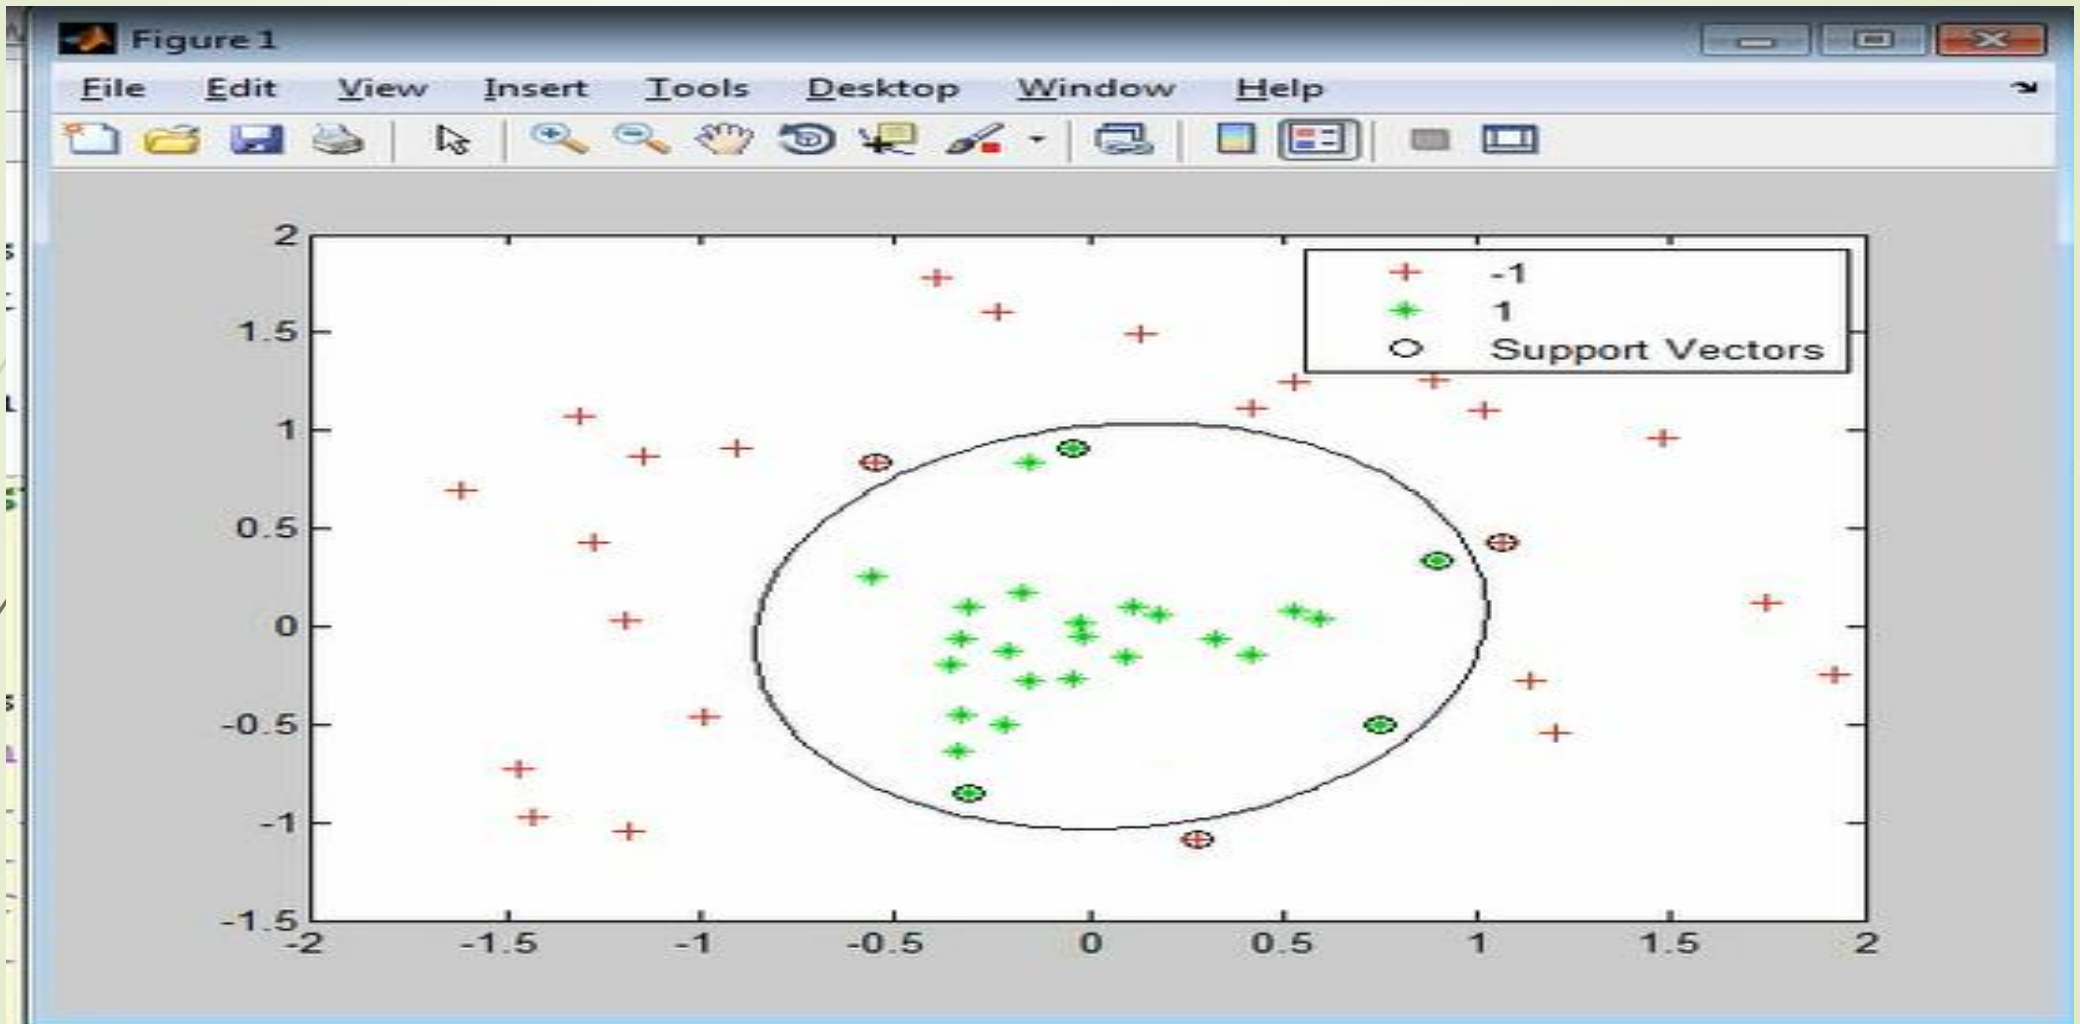


```
File Edit Text Go Cell Tools Debug Desktop Window Help
+ - 1.0 + ÷ 1.1 x
svm1.m x 20
svm2.m x 21 - TrainInputs=x';
svm3.m x 22 - TrainTargets=y';
MySVRFunc.m x 23
svm4.m x 24 - n=numel(TrainTargets);
25
26 %% Design SVM
27
28 - C=10;
29
30 - svmstruct=svmtrain(TrainInputs,TrainTargets,...
31     'boxconstraint',C,...
32     'kernel_function','linear',...
33     'rbf_sigma',0.5,...
34     'showplot',true);
35
36
37
```

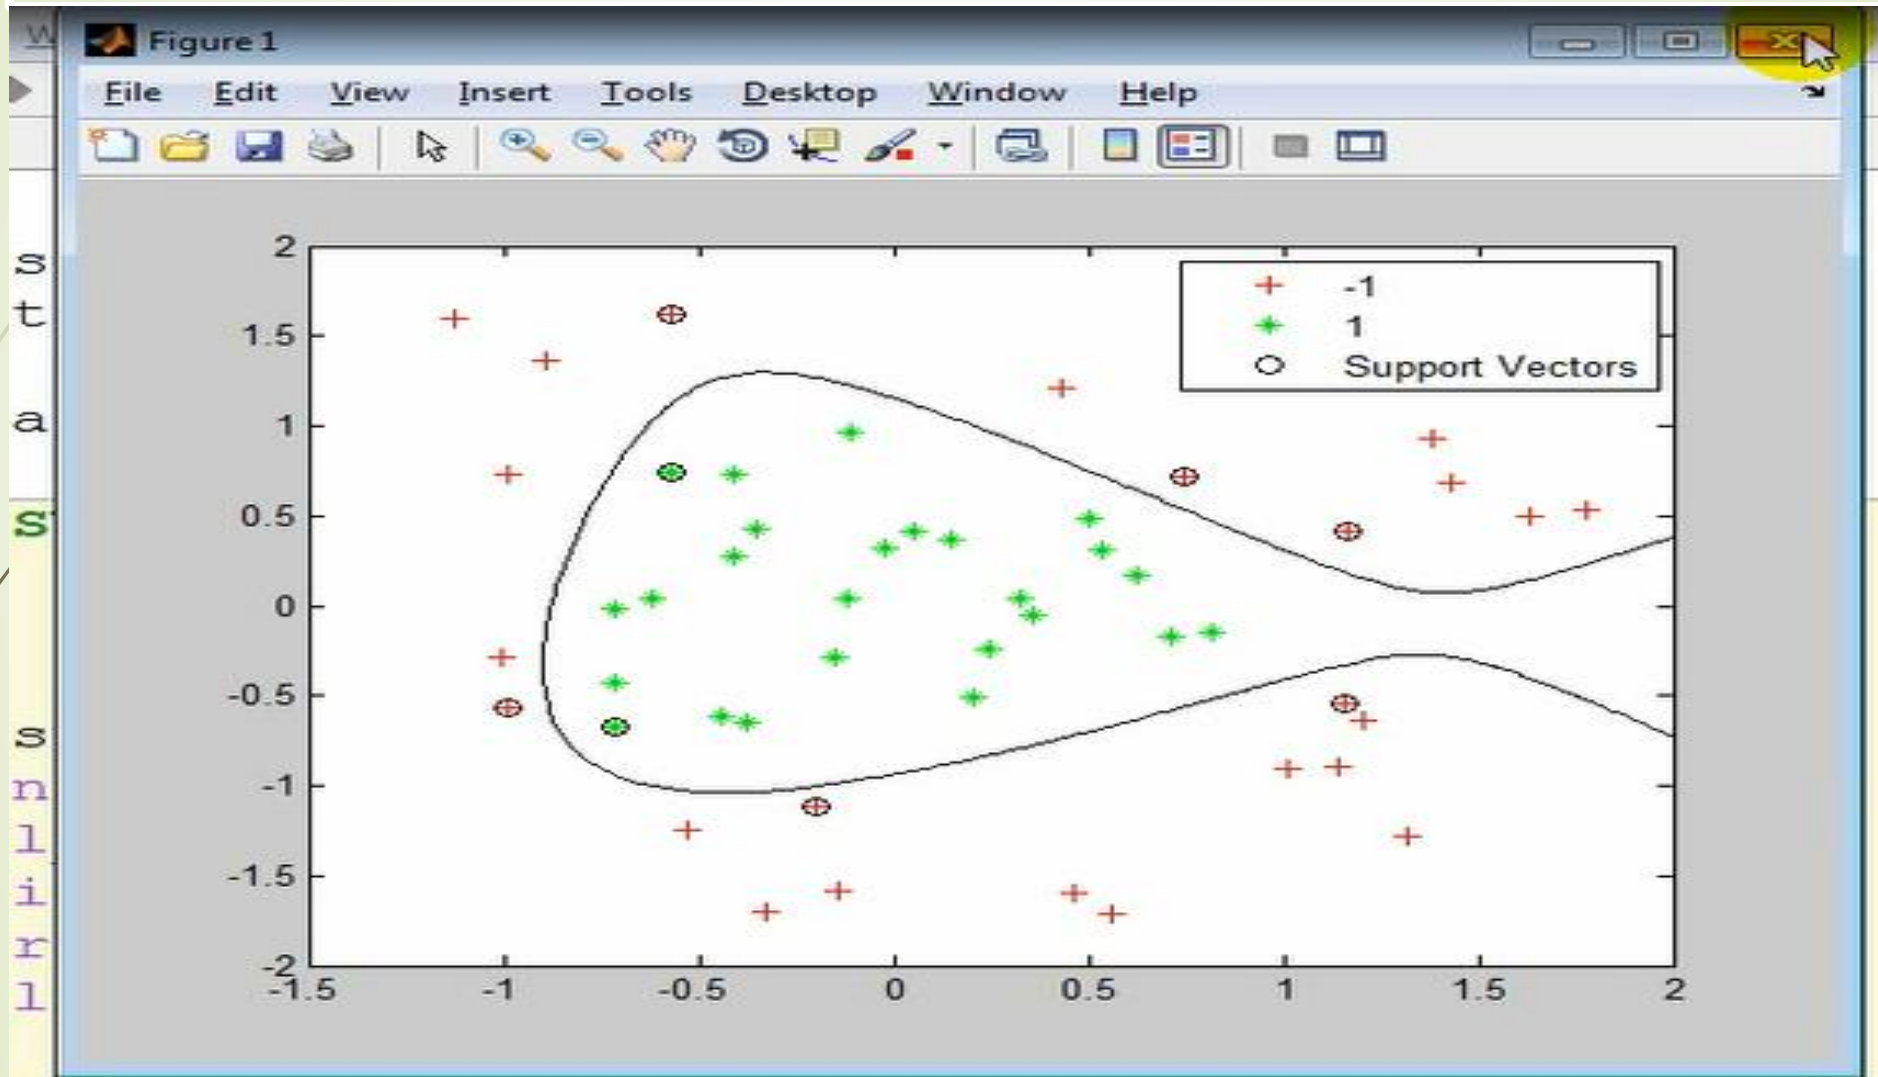




# کرنل: چند جمله ای درجه ۲



## کرنل : چند جمله ای درجه ۲

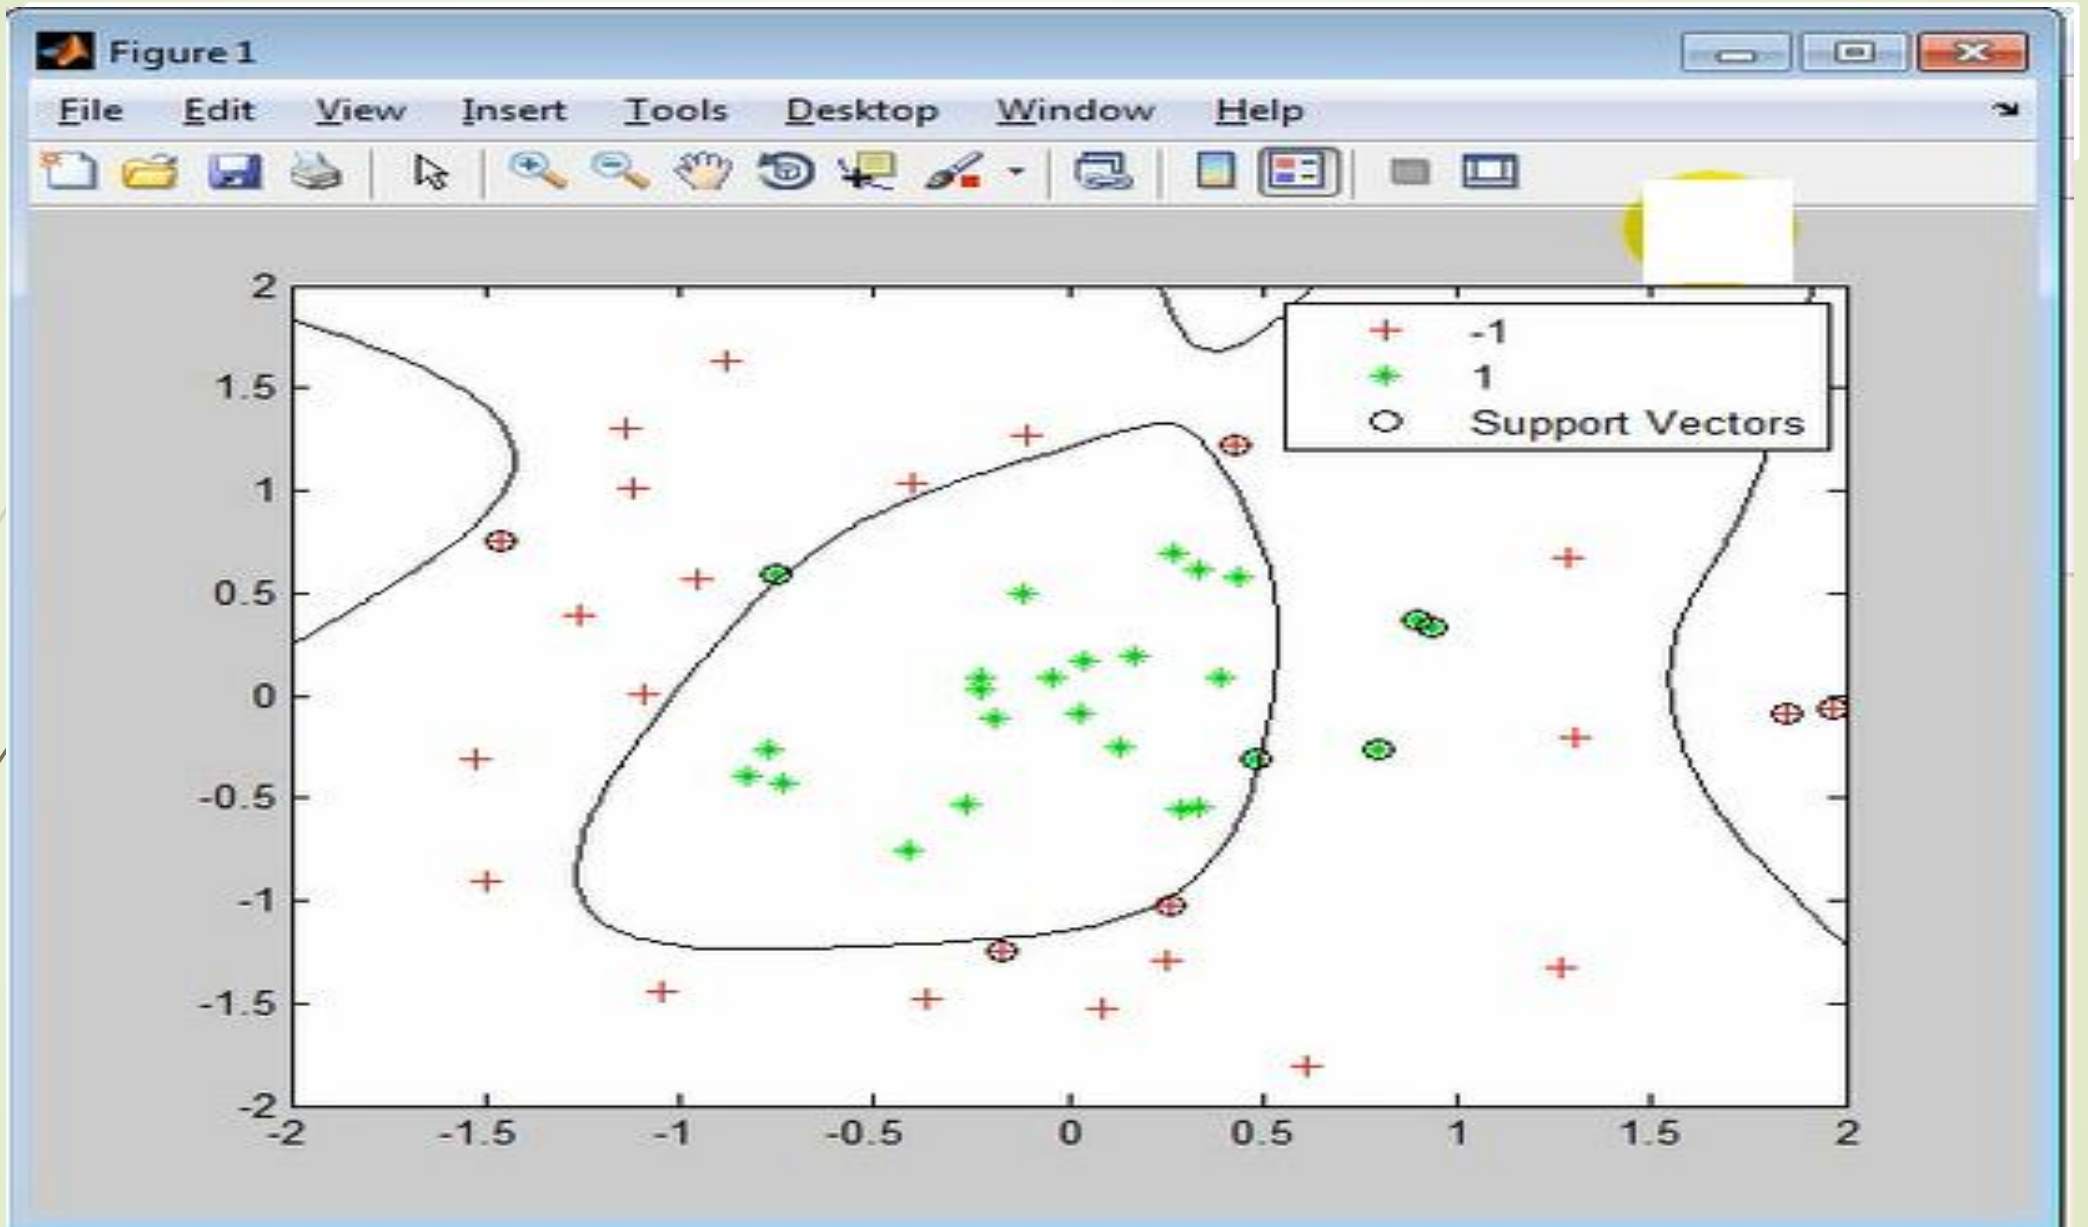




# MLP کرنل

66

```
svm1.m x 20
svm2.m x 21 - TrainInputs=x';
svm3.m x 22 - TrainTargets=y';
MySVRFunc.m x 23
svm4.m x 24 - n=numel(TrainTargets);
25
26 %% Design SVM
27
28 - C=10;
29
30 - svmstruct=svmtrain(TrainInputs,TrainTargets,...
31     'boxconstraint',C,...
32     'kernel_function','mlp',...
33     'rbf_sigma',0.5,...
34     'polyorder',2,...
35     'mlp_params',[1 -2],...
36     'showplot',true);
```



## پیش بینی عود مجدد سرطان سینه به کمک سه تکنیک داده کاوی

68

- ▶ تحقیقی که توسط دکتر عباس طلوعی و همکارانش انجام شده، در خصوص بیماران مبتلا به سرطان سینه که حداقل هرکدام به مدت دو سال تحت پیگیری بوده اند می باشد.
- ▶ اطلاعات این بیماران در مرکز تحقیقات سرطان جهاد دانشگاهی بدست آمده است.
- ▶ به منظور توسعه مدل‌های پیش بینی جهت پیش بینی عود سرطان سینه، از درختان تصمیم گیری (C.5) ، ماشین بردار پشتیبان (SVM: Support Vector Machines) و تکنیک‌های شبکه های عصبی مصنوعی (ANNs: Artificial Neural Networks) با بهره گیری از پایگاه داده مذکور استفاده شده است.

## مواد و روش اجرا

► پایگاه داده قبل از پردازش شامل ۱۱۸۹ نمونه و ۲۶ ویژگی اولیه بود که پس از پردازش اولیه، تمیزکردن داده ها و حذف نمونه های محتوی متغیرها بامقادیرمفقود  
► شده، ۵۴۷ نمونه با اطلاعات و متغیرهای کامل و ۲۲ ویژگی نهایی باقی ماند. که به دو گروه منتهی به عود یا عدم عود ختم گردیدند.

از این تعداد ۱۱۷ بیمار دچار عودبیماری و ۴۳۰ بیمار نیز فاقد عود مجدد بیماری بودند.

► جدول ۱ شامل متغیرهای پیش بینی برای مدل سازی عود مجدد سرطان سینه می باشد



داده ها با نسبت ۷۰ به ۳۰ به ترتیب برای داده های آموزشی و آزمایشی پارتیشن بندی شدند. دقت مدل، درصد تعداد دفعاتی است که نمونه های آزمایشی با موفقیت دسته بندی می شوند. اگر دقت مدل قابل قبول باشد می توان مدل را برای دسته بندی داده هایی که دسته آنها مشخص نیستند، به کار برد. برای انجام آموزش و آزمایش داده ها به صورت تصادفی به ۱۰ قسمت و در ۱۰ آزمایش مختلف تقسیم می شوند. سپس این داده ها به دو کلاس عود مجدد و عدم عود مجدد تقسیم می شوند.



جدول شماره دو، میزان دقت، حساسیت و ویژگی را برای سه روش مختلف دسته بندی نشان می دهد.



## جدول ۲: مقایسه نتایج حاصل از سه مدل داده کاوی

ویژگی	حساسیت	دقت	
۰/۹۰۷	۰/۹۵۸	۰/۹۳۶	درخت تصمیم (C5.0)
۰/۹۲۸	۰/۹۵۶	۰/۹۴۷	شبکه های عصبی مصنوعی (MLP)
۰/۹۴۵	۰/۹۷۱	۰/۹۵۷	ماشین بردار پشتیبان (SVM)

## Resources

- <http://www.kernel-machines.org/>
- <http://www.support-vector.net/>
- <http://www.support-vector.net/icml-tutorial.pdf>
- <http://www.kernel-machines.org/papers/tutorial-nips.ps.gz>
- <http://www.clopinet.com/isabelle/Projects/SVM/appplist.html>

## Resources

- [1] b.E. Boser et al. A training algorithm for optimal margin classifiers. Proceedings of the fifth annual workshop on computational learning theory 5 144-152, Pittsburgh, 1992.
- [2] I. Bottou et al. Comparison of classifier methods: a case study in handwritten digit recognition. Proceedings of the 12th IAPR international conference on pattern recognition, vol. 2, pp. 77-82.
- [3] v. Vapnik. The nature of statistical learning theory. 2nd edition, Springer, 1999.

76

Thank you!

June 2015

www.dj... .com