

Soft computing



K.N. Toosi
University of
Technology

محاسبات نرم



Hasan Ghasemzadeh
<http://wp.kntu.ac.ir/ghasemzadeh>

Support Vector Machines




یادگیری بردار پشتیبان

رگرسیون

در رگرسیون سعی بر این بود تا بهترین خطی که به داده ها برازش می شود پیدا کنیم

$$h_{\theta}(x) = \theta_0 x_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n \quad h_{\theta} = \theta^T X = \sum_0^n \theta_n x_n$$



در رگرسیون لجستیک سعی بر این بود تا داده های را دسته بندی کنیم

آیا این دسته بندی را می توان به نحوی دیگر توسعه داد؟

If $y = 1$, we want $h_{\theta}(x) \approx 1, \theta^T x \gg 0$
 If $y = 0$, we want $h_{\theta}(x) \approx 0, \theta^T x \ll 0$

این توسعه به نام بردار پشتیبان در سال ۱۹۶۴ توسط آقای Vladimir Vapnik برای طبقه بندی پیشنهاد شد


ابر صفحه Hyperplane

در فضا n بعدی یک ابر صفحه دارای $n-1$ بعد است و فضا را به دو نیم فضا تقسیم می کند


$$f(x) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n = 0 \quad f(x) = \beta_0 + \vec{\beta}x = 0$$



فضای یک بعدی



فضای سه بعدی



فضای دو بعدی

ابر صفحه Hyperplane

علامت تابع $f(x)$ برای نقاط در دو طرف ابر صفحه (دو نیم فضا) متفاوت است

$$f(x) = \beta_0 + \vec{\beta}x = 0$$

اگر بالای ابر صفحه علامت تابع مثبت نباشد کافیت تابع را با ضرب در یک منفی بازنویسی کنیم.

$$f(x) = |\beta_0 + \vec{\beta}x| > 1$$

نقاط کلاسها:

Soft Computing 5

ماشین بردار پشتیبان SVM

در یادگیری بردار پشتیبان به دنبال یافتن یک ابر صفحه جداکننده هستیم که فاصله بین نزدیکترین داده کلاسها را تا ابر صفحه حداکثر کند

$$f(x) = \beta_0 + \vec{\beta}x = 0$$

بردارهای پشتیبان

حاشیه Margin

بردارهای پشتیبان

بردارهای پشتیبان، نقاط داده‌ای هستند که نزدیک‌ترین به ابر صفحه جداکننده قرار دارند. الگوریتم SVM از بردارهای پشتیبان برای ساختن ابر صفحه استفاده می‌کند.

Soft Computing 6

فاصله تا ابر صفحه

اگر دو کلاس قابل تفکیک باشند بینهایت ابر صفحه برای تفکیک وجود دارد.

مقادیر برجسب $y^{(i)} \in \{-1, 1\}$

$$f(x) = \beta_0 + \vec{\beta}x = 0$$

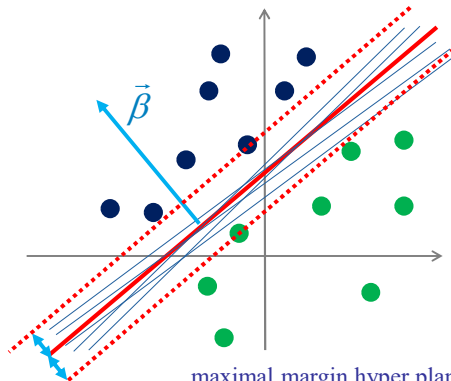
با ضرب در مقدار برجسب کلاسها جدا می شوند و داریم

$$y^{(i)} (\beta^T x^{(i)} + \beta_0) > 0$$

حاشیه حداقل فاصله داده های کلاسها تا ابر صفحه است

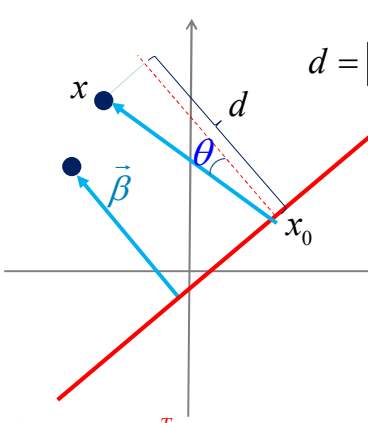
بدنبال ابر صفحه با حداکثر حاشیه هستیم

ابر صفحه با حداکثر حاشیه دارای یک داده از هر کلاس روی حاشیه خود است



Soft Computing 7

علامت تابع $f(x)$ برای نقاط در دو طرف ابر صفحه (دو نیم فضا) متفاوت است



$$d = \|x - x_0\| |\cos\theta| = \|x - x_0\| \frac{|\beta^T (x - x_0)|}{\|\beta\| \|x - x_0\|}$$

$$f(x_0) = \beta_0 + \beta^T x_0 = 0 \Rightarrow \beta_0 = -\beta^T x_0$$

$$\Rightarrow d = \frac{|\beta^T x + \beta_0|}{\|\beta\|} = \frac{|f(x)|}{\|\beta\|}$$

Soft Computing 8

بهینه نمودن فاصله تا ابر صفحه

در بردار پشتیبان به دنبال اکسترمم کردن تابع زیر هستیم

$$\max_{\beta, \beta_0} \left\{ \min_i \left\{ \frac{|\beta^T x^{(i)} + \beta_0|}{\|\beta\|} \right\} \right\} \rightarrow M \text{ حاشیه } M = \min_i \left\{ \frac{|\beta^T x^{(i)} + \beta_0|}{\|\beta\|} \right\}$$

subject to $y^{(i)}(\beta^T x^{(i)} + \beta_0) > 0$ $\xrightarrow{\frac{y^{(i)}(\beta^T x^{(i)} + \beta_0)}{\|\beta\|} > \min \frac{y^{(i)}(\beta^T x^{(i)} + \beta_0)}{\|\beta\|}}$ $\frac{y^{(i)}(\beta^T x^{(i)} + \beta_0)}{\|\beta\|} > M$

$\max_{\beta, \beta_0} M$ s.t. $\frac{y^{(i)}(\beta^T x^{(i)} + \beta_0)}{\|\beta\|} > M$: مساله بهینه سازی بردار پشتیبان :


- $x^{(i)}$: The feature vector for the i -th training sample.
- $y^{(i)}$: The label for the i -th training sample (+1 or -1).
- β : The normal vector to the hyperplane.
- β_0 : The bias term (intercept) of the hyperplane.
- $\|\beta\|$: The norm of the vector β , ensuring normalization.

Soft Computing

9

حاشیه سخت

حاشیه سخت: درون حاشیه نقاط داده هیچ کلاسی وجود ندارد



$\min_{\beta, \beta_0} \frac{1}{2} \beta^T \beta$ s.t. $y^{(i)}(\beta^T x^{(i)} + \beta_0) \geq 1$: مساله بردار پشتیبان:

Soft Computing

10

مساله دوگان

در بهینه سازی ریاضی به جای مساله اصلی می توان مساله دوگان را بهینه نمود که در بهینه سازی مسائل محدب و مقید کاربرد زیادی دارد:

$$\min_x f(x) \quad s.t. \quad g(x) = 0 \quad \text{مساله اصلی (Primal problem)}$$


$$L(x, \alpha) = f(x) + \alpha g(x) \quad \alpha \geq 0$$

تشکیل تابع لاگرانژ و ضرایب لاگرانژ $\alpha \geq 0$

$$\frac{\partial L(x, \alpha)}{\partial x} = 0 \quad \frac{\partial L(x, \alpha)}{\partial \alpha} = 0$$

مساله دوگان معادل (Dual problem):

$$\max_{x, \alpha} L(x, \alpha) \quad s.t. \quad \alpha \geq 0$$



Soft Computing

11

مساله دوگان حاشیه سخت

در بهینه سازی ریاضی به جای مساله اصلی می توان مساله دوگان را حل نمود که در بهینه سازی مسائل محدب و مقید کاربرد زیادی دارد:

مساله اصلی (Primal problem):

$$\min_{\beta, \beta_0} \frac{1}{2} \beta^T \beta \quad s.t. \quad y^{(i)} (\beta^T x^{(i)} + \beta_0) - 1 \geq 0$$

$$L(\beta, \beta_0, \alpha) = \frac{1}{2} \beta^T \beta - \sum_{i=1}^N \alpha_i [y^{(i)} (\beta^T x^{(i)} + \beta_0) - 1]$$

تشکیل تابع لاگرانژ
و مشتق گیری و ساده سازی

$$\max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y^{(i)} y^{(j)} (x^{(i)} x^{(j)}) \quad \text{مساله دوگان (Dual problem)}$$

$$\sum_{i=1}^N \alpha_i y^{(i)} = 0 \quad \text{and} \quad \alpha_i \geq 0$$

حل مساله دوگان به دلیل وجود صرفاً ضرب داخلی ویژگیها و وابستگی به تعداد ویژگیها نه ابعاد آنها راحتتر است و در مسایل غیر خطی و ابعاد بالا قابل استفاده است

Soft Computing

12

مثال حاشیه سخت

فایل: 11 SVM Hard.py

```
from sklearn.svm import SVC
from sklearn.datasets import make_blobs
from sklearn.model_selection import train_test_split
from sklearn.metrics import classification_report

# Generate a synthetic dataset
X, y = make_blobs(n_samples=50, centers=2, random_state=42)
y = 2 * y - 1 # Convert labels to {-1, 1}

# Train-test split
X_train, X_test, y_train, y_test = train_test_split(X, y,
                                                    test_size=0.3, random_state=42)


# Create and train the hard-margin SVM
hard_margin_svm = SVC(C=1e6, kernel='linear')
hard_margin_svm.fit(X_train, y_train)

# Evaluate the model
y_pred = hard_margin_svm.predict(X_test)
print(classification_report(y_test, y_pred))
```

	precision	recall	f1-score	support
-1	1.00	1.00	1.00	6
1	1.00	1.00	1.00	9
accuracy			1.00	15
macro avg	1.00	1.00	1.00	15
weighted avg	1.00	1.00	1.00	15

Soft Computing

13



Formula of the decision boundary: $0.81 * x_1 + -0.86 * x_2 + 0.11 = 0$

Soft Computing

14

حاشیه نرم

حاشیه نرم: اگر با کنترل اجازه داده شود بعضی نقاط داده از حاشیه عبور کنند بردار پشتیبان بصورت پایدارتری برای داده های نوفه دار و غیرخطی قابل حل است

مساله اصلی (Primal problem):

$$\min_{\beta, \beta_0, \xi} \frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^N \xi_i$$

s.t. $y^{(i)} (\beta^T x^{(i)} + \beta_0) \geq 1 - \xi_i \quad \xi_i \geq 0$

$C > 0$ پارامتر جریمه برای حداکثر کردن حاشیه و حداقل کردن خطای کلاس بندی

مساله دوگان (Dual problem):

$$\max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y^{(i)} y^{(j)} (x^{(i)} x^{(j)})$$

$$\sum_{i=1}^N \alpha_i y^{(i)} = 0 \quad \text{and} \quad 0 \leq \alpha_i \leq C$$

Soft Computing 15

حاشیه نرم

تأثیر پارامتر تنظیم C

مقادیر کوچک - تنظیم زیاد:

- بزرگتر کردن حاشیه بین کلاس ها.
- تعداد بیشتری از داده ها به اشتباه طبقه بندی شوند.
- منجر به مدلی ساده تر می شود که ممکن است داده ها را کم برآزش کند.

مقادیر بزرگ - تنظیم کم:

- طبقه بندی اشتباه را بیشتر جریمه می کند. و عبور از حاشیه کمتری ایجاد می شود.
- ممکن است مدل بسیار پیچیده شود و به بیش برآزش دچار شود.

تعیین پارامتر تنظیم C

• پارامتر پیش فرض: از پیش فرض $C=1$ شروع کنید

• مقیاس لگاریتمی: مقادیر C را روی مقیاس لگاریتمی بررسی کنید. $C \in \{10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 100, 1000\}$.

• بررسی نتایج: دقت مدل را روی مجموعه آموزش و اعتبارسنجی بررسی کنید (کنترل صحت و دقت یا F1).

اعتبارسنجی ضروری: برای تعیین C بهینه می توان با تقسیم مجموعه داده های آموزش به K دسته (مثلا 5) و آموزش K-1 دسته و اعتبارسنجی با دسته آخر برای مقادیر مختلف C انجام داد. برای هر C میانگین دقت K-1 دسته تعیین شده و بر اساس بهترین دقت C تعیین می شود.

```
from sklearn.model_selection import cross_val_score
scores = cross_val_score(estimator, X, y, cv=5, scoring='accuracy')
```


Soft Computing 16

بردار پشتیبان برای مسایل غیرخطی

اگر با خط امکان جدا کردن داده‌ها نباشد از ابعاد بالاتر می‌توان استفاده کرد

$$f(x) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

$$f(x) = \beta_0 + \vec{\beta}x$$



Soft Computing

17

کرنل ماشین بردار پشتیبان

اگر با خط امکان جدا کردن داده‌ها نباشد از ابعاد بالاتر می‌توان استفاده کرد

$$\min_{\beta, \beta_0, \xi} \frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^N \xi_i$$

مساله اصلی (Primal problem):

$$s.t. \quad y^{(i)} (\phi(x^{(i)})^T \beta + \beta_0) \geq 1 - \xi_i \quad \xi_i \geq 0$$

$\phi(x^{(i)})$ تابع نگاشت ویژگی به ابعاد بالاتر

مساله دوگان (Dual problem):

$$\max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y^{(i)} y^{(j)} K(x^{(i)}, x^{(j)})$$

بجای ضرب ویژگیها کرنل قرار می‌گیرد

$$\sum_{i=1}^N \alpha_i y^{(i)} = 0 \quad \text{and} \quad 0 \leq \alpha_i \leq C$$

$$K(x^{(i)}, x^{(j)}) = \phi(x^{(i)})^T \phi(x^{(j)})$$

تابع کرنل

Soft Computing

18

کرنل ماشین بردار پشتیبان

انواع کرنل


Kernel	Equation	Use Case	Pros	Cons
Linear	$K = x \cdot x'$	Linearly separable data	Simple, fast, interpretable	Limited to linear relationships
RBF: Radial Basis Function	$K = e^{-\gamma \ x - x'\ ^2}$	Non-linearly separable data	Highly flexible	Can overfit with large γ
Polynomial	$K = (\gamma x \cdot x' + r)^d$	Polynomial feature relationships	Flexible, interpretable	High-degree polynomials may overfit
Sigmoid	$K = \tanh(\gamma(x \cdot x') + r)$	Neural network-like transformations	Flexible	Less robust than RBF

Soft Computing

19

بردار پشتیبان چند کلاسه

در حالتیکه بیش از یک کلاس داشته باشیم:



$$y \in \{1, 2, 3, \dots, K\}$$

Many SVM packages already have built-in multi-class classification functionality.

Soft Computing

20

بردار پشتیبان چند کلاسه

در حالتیکه بیش از یک کلاس داشته باشیم:

One-vs-Rest (OvR): For K classes, train K binary classifiers.

Advantages: Simple to implement and Efficient when K is small.

Disadvantages: Overlaps in decision boundaries can occur and less effective for imbalanced classes.

One-vs-One (OvO): For K classes, train $K(K-1)/2$ binary classifiers.

Advantages: Often performs better than OvR and More granular decision boundaries.

Disadvantages: Computationally expensive for large K, due to many classifiers.

Direct Multi-Class SVM (All-vs-All):

- A single optimization problem is formulated to classify multiple classes.
- This approach solves a large optimization problem for all classes simultaneously.
- Less commonly used due to computational complexity.

Soft Computing

21

مثال حاشیه نرم

فایل: 11 SVM Soft.py

مساله بهینه‌سازی بردار پشتیبان :

```
# Function to train, evaluate, and plot SVM for different kernels
def train_evaluate_plot(kernel, C=1.0, degree=3):
    # Train the SVM model with a specific kernel
    svm = SVC(C=C, kernel=kernel, gamma='scale', degree=degree)
    svm.fit(X_train, y_train)

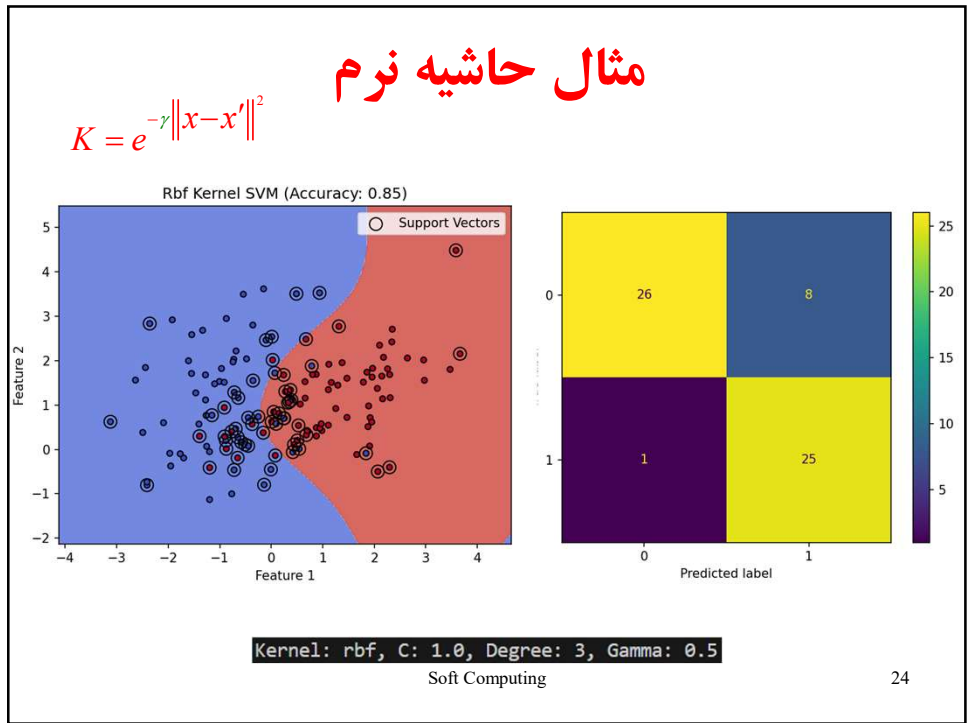
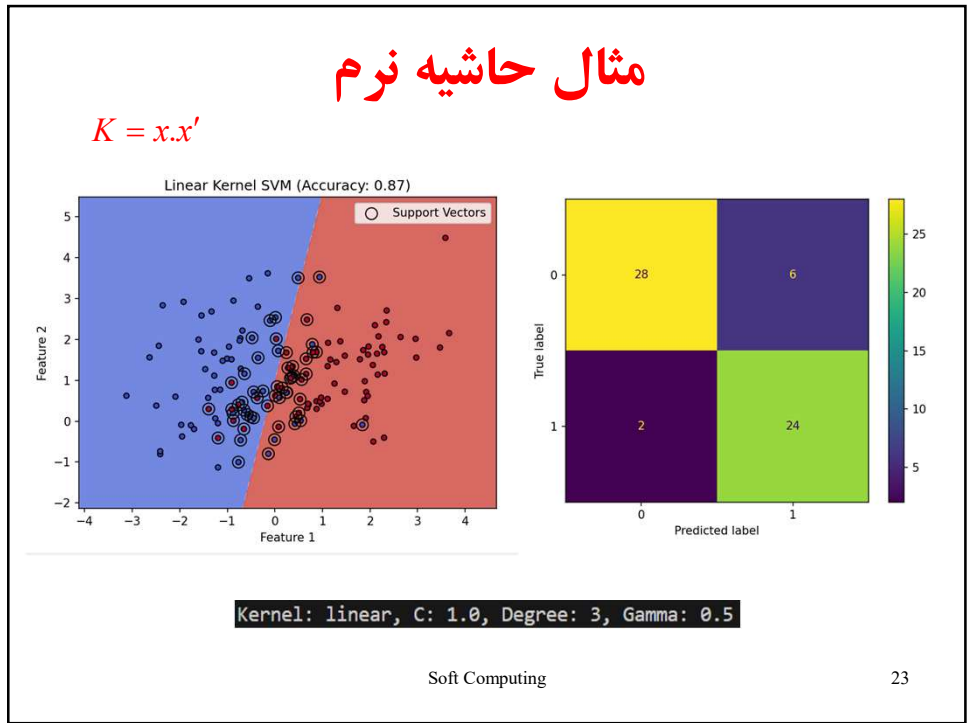
    # Predict and calculate accuracy
    y_pred = svm.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)

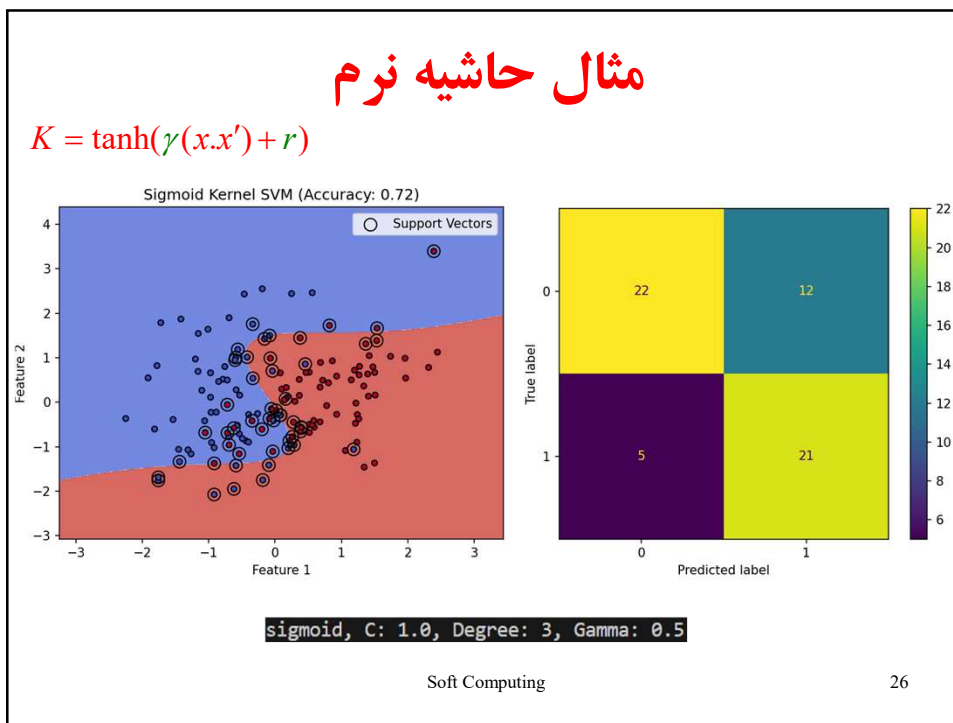
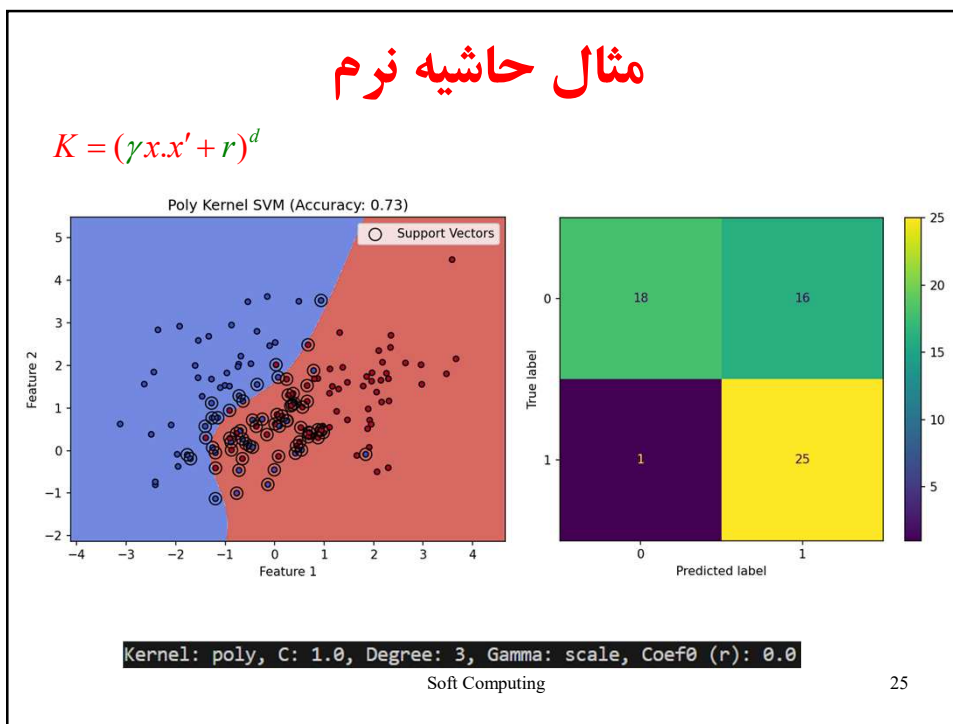
    # Plot decision boundary
    plot_svm_with_margin(X_train, y_train, svm, kernel.capitalize(),
accuracy)

# Test the function with different kernels
for kernel in ['linear', 'rbf', 'poly']:
    train_evaluate_plot(kernel, C=1.0, degree=3)
```

Soft Computing

22





مقایسه روشها



Soft Computing

27

تمرین برنامه نویسی

تمرین ششم: یک برنامه به زبان پایتون بنویسید که یک فایل داده را خوانده و به روش بردار پشتیبان با حاشیه نرم و کرنل تابع پایه شعاعی و چند جمله‌ای کلاس بندی انجام دهد.

۱- خواندن فایل داده

۲- طبقه بندی با بردار پشتیبان با حاشیه نرم

۳- بررسی هایپر پارامترهای کرنل تابع پایه شعاعی و چند جمله ای

۴- تاثیر هایپر پارامترهای مدل با ترسیم آنها

۵- پیشنهاد بهترین دسته بندی با هایپر پارامترهای مربوطه

Soft Computing

28