

Rozpoznávanie obrazcov

šk.r. 2015-16

Lineárny klasifikátor

SVM

Zuzana Berger Haladova

Lineárny klasifikátor

- Jednoduchosť

- Nízka výpočtová náročnosť


$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$$

- Pri učení nastavujeme váhy w a člen b a potom už tréningovú množinu nebudeme potrebovať


Klasifikácia do dvoch tried

- Máme triedy ω_1 a ω_2
- Hodnota $f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$ je nulová pre body, ktoré ležia na oddeľujúcej nadrovine
- $f(\mathbf{x}) \geq 0 \Leftrightarrow \mathbf{x} \in \omega_1$
- $f(\mathbf{x}) < 0 \Leftrightarrow \mathbf{x} \in \omega_2$

Lineárna klasifikácia



Lineárna klasifikácia




Sigmoid

$$\mathbf{x}^T = [1, x_1, x_2]$$

$$h_{\theta}(x) = g(\theta^T x),$$

$$g(z) = \frac{1}{1 + e^{-z}}.$$



Cenová funkcia

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \left[-y^{(i)} \log(h_{\theta}(x^{(i)})) - (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)})) \right],$$


Gradient

$$\frac{\partial J(\theta)}{\partial \theta_j} = \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) x_j^{(i)}$$

SVM

- Hľadáme nadrovinu, reprezentovanú váhovým vektorom, ktorá maximalizuje rozpätie
- Podporné vektory

$$\mathbf{w}^T \mathbf{x} + b = \pm 1$$



SVM

```
data = load('ex2data1.txt');
X = data(:, [1, 2]); y = data(:, 3);
SVMModel = fitcsvm(X,y)
sv = SVMModel.SupportVectors;
figure
gscatter(X(:,1),X(:,2),y)
hold on
plot(sv(:,1),sv(:,2),'ko','MarkerSize',10)
legend('0','1','Support Vector')
hold off

CVSVMModel = crossval(SVMModel);
classLoss = kfoldLoss(CVSVMModel)

P=[45,85];
[label,score] = predict(SVMModel,P)
```

