

2. Redes Neurais Artificiais

Prof. Renato Tinós

Depto. de Computação e Matemática (FFCLRP/USP)

2.5. Support Vector Machines

2.5. Support Vector Machines (SVM)

2.5.1. Hiperplano Ótimo



2.5.2. Kernels

2.5.1. Support Vector Machines

- **Support Vector Machines (SVM) ou Máquinas de Vetor de Suporte**
 - São redes feedforward
 - » Propostas por Vapnik (1992 -1995)
 - » Bastante popular, especialmente na primeira década nos anos 2000
 - Como outros modelos vistos aqui, são aproximadores universais
 - » Podem portanto ser usadas em classificação e regressão

2.5.1. Hiperplano Ótimo


- Como definir hiperplanos para o problema de classificação?
 - Diversos modelos vistos aqui: os hiperplanos são otimizados de acordo com o erro médio quadrático sobre o conjunto de treinamento
 - » Exemplo: espaço de classificação gerado pelo MLP



2.5.1. Hiperplano Ótimo

- **Problema de classificação linearmente separável**
 - Qual é o melhor hiperplano?

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



2.5.1. Hiperplano Ótimo

- **Ideia principal nas SVMs**

Construir um hiperplano de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima


» É baseada no **método de minimização estrutural de riscos**

- ☐ Fundamentada na teoria de aprendizagem estatística

- ☐ Este princípio indutivo é baseado no fato de que a taxa de erro de uma máquina de aprendizagem sobre dados de teste (generalização) é limitada pela soma da taxa de erro de treinamento e por um termo que depende da dimensão de **Vapnik-Chervonendis (V-C)**

2.5.1. Hiperplano Ótimo

- **Margem de separação (ρ)**
 - Separação entre o hiperplano e o dado mais próximo
 - » A equação é dada na figura (ver desenvolvimento em [Haykin, 2001])



Fonte: Graphic showing the maximum separating hyperplane and the margin.
https://commons.wikimedia.org/wiki/File:Svm_max_sep_hyperplane_with_margin.png

2.5.1. Hiperplano Ótimo

- **Como encontrar o hiperplano ótimo?**
 - Em SVM, a ideia é encontrar o vetor de pesos w que fornece a máxima separação possível entre exemplos positivos e negativos
 - » Maximizar ρ significa minimizar a norma Euclidiana de w
 - Fixando $\rho=1$, temos o seguinte problema de otimização para um conjunto de treinamento (x_i, y_i) para $i=1, \dots, n$

Minimizar

$\| w \|$

Sujeito às restrições:

$y_i (w^T x_i + b) \geq 1,$
para $i=1, \dots, n$

2.5.1. Hiperplano Ótimo

- **Este é um problema de otimização restrito**
 - com função de custo convexa
 - com restrições lineares em relação à w
- **Portanto, podemos utilizar o método dos multiplicadores de Lagrange para encontrar os pontos ótimos**
 - Este é um grande atrativo de SVMs

2.5.1. Hiperplano Ótimo

- **Método de otimização**

- Função Lagrangiana a ser otimizada

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) - 1)$$

sendo que α_i são os multiplicadores de Lagrange

- Soluções ótimas: pontos de sela da função Lagrangiana

$$\frac{\partial L}{\partial b} = 0$$

$$\frac{\partial L}{\partial \mathbf{w}} = 0$$

2.5.1. Hiperplano Ótimo

- **Método de otimização**

- Resolvendo as equações (ver [Haykin, 2001]), obtemos o seguinte problemas

$$\text{Maximizar: } \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j$$

$$\text{Sujeito a: } \begin{cases} \alpha_i \geq 0, i = 1, \dots, n \\ \sum_{i=1}^n \alpha_i y_i = 0 \end{cases}$$

- Sendo que o hiperplano ótimo é definido por

$$\begin{aligned} \mathbf{w} &= \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i \\ b^* &= -\frac{1}{2} \left[\max_{\{i|y_i=-1\}} (\mathbf{w}^* \cdot \mathbf{x}_i) + \min_{\{i|y_i=+1\}} (\mathbf{w}^* \cdot \mathbf{x}_i) \right] \\ &= -\frac{1}{2} \left[\max_{\{i|y_i=-1\}} \left(\sum_{j=1}^n y_j \alpha_j^* \mathbf{x}_i \cdot \mathbf{x}_j \right) + \min_{\{i|y_i=+1\}} \left(\sum_{j=1}^n y_j \alpha_j^* \mathbf{x}_i \cdot \mathbf{x}_j \right) \right] \end{aligned}$$

2.5.1. Hiperplano Ótimo

Algoritmo 3.1 Determinação do hiperplano ótimo para conjuntos linearmente separáveis (Vert, 2001).

- 1: Para cada conjunto de treinamento linearmente separável $S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$
 - 2: Seja $\alpha^* = (\alpha_1^*, \dots, \alpha_n^*)$ a solução do seguinte problema de otimização com restrições:
 - 3: Maximizar: $\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j \mathbf{x}_i \cdot \mathbf{x}_j$
 - 4: Sob as restrições:
$$\begin{cases} \sum_{i=1}^n y_i \alpha_i = 0 \\ \alpha_i \geq 0, i = 1, \dots, n \end{cases}$$
 - 5: O par $(\mathbf{w}^*, b^*)$ apresentado a seguir define o hiperplano ótimo.
 - 6: $\mathbf{w}^* = \sum_{i=1}^n \alpha_i^* y_i \mathbf{x}_i$
 - 7: $b^* = -1/2 \left[\max_{\{i|y_i=-1\}} (\mathbf{w}^* \cdot \mathbf{x}_i) + \min_{\{i|y_i=+1\}} (\mathbf{w}^* \cdot \mathbf{x}_i) \right]$
-

2.5.1. Hiperplano Ótimo

- E quando os padrões não são linearmente separáveis?

1. Construir margens de separação **suaves**


$$\begin{aligned} \text{Minimizar: } & \| \mathbf{w} \|^2 + C \sum_{i=1}^n \varepsilon_i \\ \text{Sob as restrições: } & \begin{cases} \varepsilon_i \geq 0 \\ y_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \varepsilon_i \end{cases} \end{aligned}$$

2.5.1. Hiperplano Ótimo

- E quando os padrões não são linearmente separáveis?

2. Mapear não-linearmente o vetor de entrada para um espaço de característica de mais alta dimensionalidade

» Oculto dos espaços de entrada e saída



2.5.2. Kernels

- **Teorema de Cover sobre a separabilidade de padrões**

“Um problema complexo de classificação de padrões disposto não-linearmente em um espaço de alta dimensão tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade”

(ver Seção 5.2 de [Haykin, 2001])

2.5.2. Kernels

- Utilizando o vetor de características, ao invés do vetor de entradas, teríamos

- Hiperplano

$$\mathbf{w}^T \cdot \phi(\mathbf{x}) = 0$$


- Vetor para o hiperplano ótimo

$$\mathbf{w} = \sum_{i=1}^N \alpha_i y_i \phi(\mathbf{x}_i)$$

» Substituindo na primeira equação

$$\sum_{i=1}^N \alpha_i y_i \phi(\mathbf{x}_i)^T \phi(\mathbf{x}) = 0$$

2.5.2. Kernels



2.5.2. Kernels

- Novo hiperplano

$$\sum_{i=1}^N \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) = 0$$

- Kernels usuais

TABELA 6.1 Resumo dos Núcleos de Produto Interno

Tipo de máquina de vetor de suporte	Núcleo de produto interno $K(\mathbf{x}, \mathbf{x}_i), i = 1, 2, \dots, N$	Comentários
Máquina de aprendizagem polinomial	$(\mathbf{x}^T \mathbf{x}_i + 1)^p$	A potência p é especificada <i>a priori</i> pelo usuário
Rede de função de base radial	$\exp\left(-\frac{1}{2\sigma^2} \ \mathbf{x} - \mathbf{x}_i\ ^2\right)$	A largura σ^2 , comum a todos os núcleos, é especificada <i>a priori</i> pelo usuário
Perceptron de duas camadas	$\tanh(\beta_0 \mathbf{x}^T \mathbf{x}_i + \beta_1)$	O teorema de Mercer é satisfeito apenas para alguns valores de β_0 e β_1

2.5.2. *Kernels*

- **E quando existem várias classes?**
 - Solução usual:
 - » Decomposição um-contra-todos
 - Gera um classificador para cada classe

- **Referências**

- **Haykin, S. S.. *Redes neurais: princípios e prática*. 2ª ed., Bookman, 2001.**
 - » Capítulo 6