

## Aprendizado de Máquina

Máquinas de vetores de suporte

André C. P. L. F. de Carvalho  
 Pós-doutorando: Isvani Frias-Blanco  
 ICMC-USP

MACHINE LEARNING

## Principais tópicos

- Introdução
- Risco empírico e risco estrutural
- Margens
- Margens suaves
- SVMs
- Kernels
- Multiclasses

© André de Carvalho - ICMC/USP

2

## Teoria de Aprendizado Estatístico

- Algoritmos de AM
  - Estimam um função (modelo) a partir de um conjunto finito de exemplos
  - Função (classificador ou regressor)
- TAE estabelece princípios para induzir função com boa generalização
  - Vapnik e Chervonenkis em 1968
  - Base das máquinas de vetores de suporte

© André de Carvalho - ICMC/USP

3

## TAE

- Sejam
  - $h$ : classificador (hipótese, modelo, função)
  - $H$ : conjunto de todos os classificadores que um algoritmo de AM pode induzir
- Algoritmo de AM utiliza conjunto de dados de treinamento para:
  - Induzir um classificador  $\hat{h} \in H$
- Assume que dados são gerados de forma i.i.d. de acordo com  $P(x, y)$

© André de Carvalho - ICMC/USP

4

## TAE

- TAE define condições matemáticas para auxiliar na escolha de uma boa  $\hat{h}$ 
  - A partir de um conjunto de dados de treinamento
  - Permite escolher  $\hat{h}$  com menor risco esperado
    - Para manter bom desempenho com novos dados, valia:
      - Desempenho preditivo de  $h$  para dados do conjunto de treinamento
      - Complexidade de  $\hat{h}$

© André de Carvalho - ICMC/USP

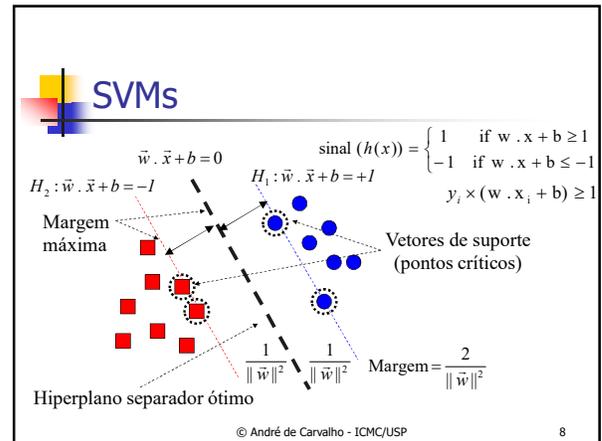
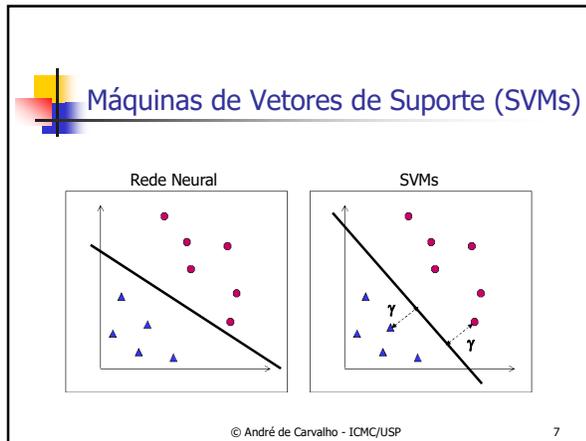
5

## Limites no risco esperado

- Isso é feito pelas máquinas de vetores de suporte (SVMs)
- Estratégia básica
  - Encontrar um hiperplano que maximize margem de separação (margem larga)
    - Distância da fronteira de decisão a um conjunto de "vetores de suporte"
    - Com erro marginal baixo
      - O mínimo de objetos entre as margens

© André de Carvalho - ICMC/USP

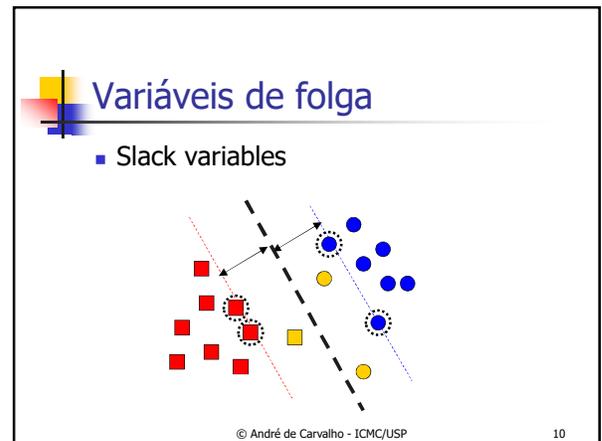
6



## Margens suaves

- Não permitir exemplos entre as margens reduz tamanho da margem
  - Reduz generalização
- SVMs podem ser estendidas para tolerar exemplos dentro das margens
  - Relaxamento de restrições impostas ao problema de otimização
    - Introdução de variáveis de folga

© André de Carvalho - ICMC/USP 9



## Linearmente separáveis

- SVMs apresentam bons desempenhos para problemas linearmente separáveis
- Não conseguem lidar com problemas não linearmente separáveis
- Alguns conjuntos de dados exigem fronteiras mais complexas que lineares
  - Para isso foram propostas alterações baseadas no teorema de Cover

© André de Carvalho - ICMC/USP 11

## Teorema de Cover

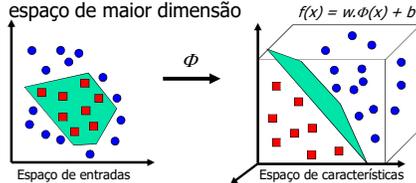
*Conjunto de dados não linearmente separáveis em um espaço podem ser transformados para outro espaço em que, com alta probabilidade, se tornam linearmente separáveis*

- Condições:
  - Transformação seja não linear
  - Dimensão do novo espaço seja suficientemente alta

© André de Carvalho - ICMC/USP 12

## Problemas não lineares

- Generalização de SVMs para problemas não lineares
  - Mapeamento de dados de entrada para um espaço de maior dimensão



© André de Carvalho - ICMC/USP

13

## Exemplo

- Supor conjunto de dados com dois atributos preditivos
- Definir 3 pontos de localização no conjunto original
- Usar esses pontos para transformar 2 atributos originais em 3 novos atributos
  - Ex. distância entre cada exemplo  $x$  e cada um dos 3 pontos de localização

© André de Carvalho - ICMC/USP

14

## Fronteiras mais complexas

- Computação da função  $\Phi$  pode ter custo computacional elevado
  - Informação necessária: cálculo do produto escalar entre objetos
  - Pode ser feito por funções *kernel* ( $K$ )
    - Função *kernel* recebe dois pontos no espaço de entradas e calcula produto escalar deles no espaço de características
    - $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$

© André de Carvalho - ICMC/USP

15

## Funções *Kernel*

- Variações
  - Gaussiana
  - Polinomial
    - Linear
  - Sigmoidal
  - Para aplicações específicas
- Segue condições estabelecidas pelo teorema de Mercer
- Parâmetros ajustáveis

© André de Carvalho - ICMC/USP

16

## Funções *Kernel*

- Em geral,  $K$  é menos complexa que  $\Phi$ 
  - É comum definir-se a função  $K$  sem conhecer-se explicitamente  $\Phi$

Tipos de Kernel	Função $K(x_i, x_j)$ correspondente
Polinomial	$(x_i^T \cdot x_j + 1)^p$ ( $p = 1$ , linear)
Gaussiano	$\exp(-1/(2\sigma^2) \ x_i - x_j\ ^2)$
Sigmoidal	$\tanh(\beta_0 x_i \cdot x_j + \beta_1)$

© André de Carvalho - ICMC/USP

17

## Funções *Kernel*

- Mede similaridade entre objetos
- Kernel linear:
  - Indicado quando #atributos > #objetos
  - Processamento mais rápido
- Kernel Gaussiano
  - Indicado quando #objetos > #atributos
- Kernels específicos são propostos para algumas aplicações

© André de Carvalho - ICMC/USP

18

## Funções Kernel

© André de Carvalho - ICMC/USP 19

## Classificação multiclases

- SVMs podem induzir apenas classificadores binários
  - Outros algoritmos de AM têm a mesma limitação
- Existe um grande número de problemas reais com mais que 2 classes
  - Necessidade de estratégias multiclases

© André de Carvalho - ICMC/USP 20

## Estratégias multiclases

- Duas abordagens têm sido utilizadas:
  - Algoritmo de classificação é internamente adaptado
    - Modificação de parte de suas operações internas
  - Decomposição do problema multiclases em vários problemas binários
    - Estratégias decompositivas

© André de Carvalho - ICMC/USP 21

## Estratégias decompositivas

- Etapas
  - Decomposição da tarefa
  - Reconstrução
- Decomposição
  - Geralmente reduz a complexidade da tarefa
  - Permite processamento paralelo
  - Alternativas:
    - Matrizes de códigos (MC)
    - Hierarquias de classificadores

© André de Carvalho - ICMC/USP 22

## Estratégias Baseadas em MC

- Um-contra-todos (OAA)
  - Um classificador para cada classe
    - k classificadores para k classes
- Todos contra todos (AAA)
  - Um classificador para cada par de classes
    - $k(k-1)/2$  classificadores para k classes
- Error Correcting Output Codes (ECOC)
  - Um código de correção de erro representando cada classe

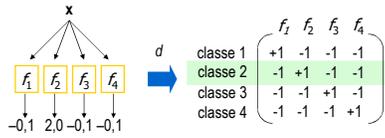
© André de Carvalho - ICMC/USP 23

## Matrizes de códigos

© André de Carvalho - ICMC/USP 24

## Matrizes de códigos

- Reconstrução = decodificação



- Função de decodificação  $d$

- Hamming
- Baseada em margens

© André de Carvalho - ICMC/USP

25

## Conclusão

- Teoria de Aprendizado Estatístico
- SVMs
- Problemas não linearmente separáveis
- Classificação binária e multiclass
- Regressão
- Redes profundas

© André de Carvalho - ICMC/USP

26

## Perguntas



© André de Carvalho - ICMC/USP

27

## Exercício

- Utilizando do repositório UCI as bases de dados IRIS e GLASS
  - Investigar SVMs
    - Três kernels diferentes
  - Particionar os dados como no exercício de métodos probabilísticos
  - Ajustar parâmetros por tentativa e erro
  - Comparar com resultados do kNN, com os dos métodos probabilísticos e das redes neurais

© André de Carvalho - ICMC/USP

28