INF 1771 – Inteligência Artificial

Aula 21 – Support Vector Machine (SVM)

Edirlei Soares de Lima
<elima@inf.puc-rio.br>

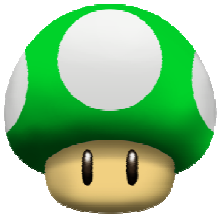

Formas de Aprendizado

- **Aprendizado Supervisionado**
  - Árvores de decisão.
  - K-Nearest Neighbor (KNN).
  - **Support Vector Machines (SVM).**
- Aprendizado Não Supervisionado
- Aprendizado Por Reforço

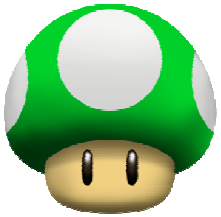

Aprendizado Supervisionado

- Observa-se alguns pares de **exemplos de entrada e saída**, de forma a aprender uma **função que mapeia a entrada para a saída**.

- Damos ao sistema a **resposta correta** durante o processo de treinamento.

- É eficiente pois o sistema pode trabalhar diretamente com informações corretas.

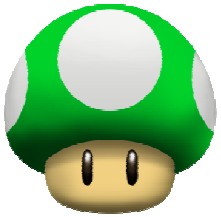

Support Vector Machine

- Poderosa metodologia para resolver problemas de **aprendizagem de máquina**.
- Proposto em 1995 pelo russo **Vladimir Vapnik**.
- **Muito utilizado** atualmente em diversos tipos de aplicações.

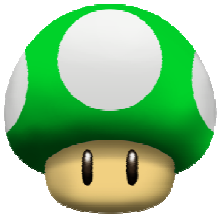

Support Vector Machine

- Consiste em um método de aprendizado que tenta encontrar a **maior margem** para separar diferentes classes de dados.

- Pertence à classe de algoritmos de **aprendizado supervisionado**.

- A essência do SVM é a construção de um **hiperplano ótimo**, de modo que ele possa separar diferentes classes de dados com a maior margem possível.

Support Vector Machine

- Como separar essas duas classes?

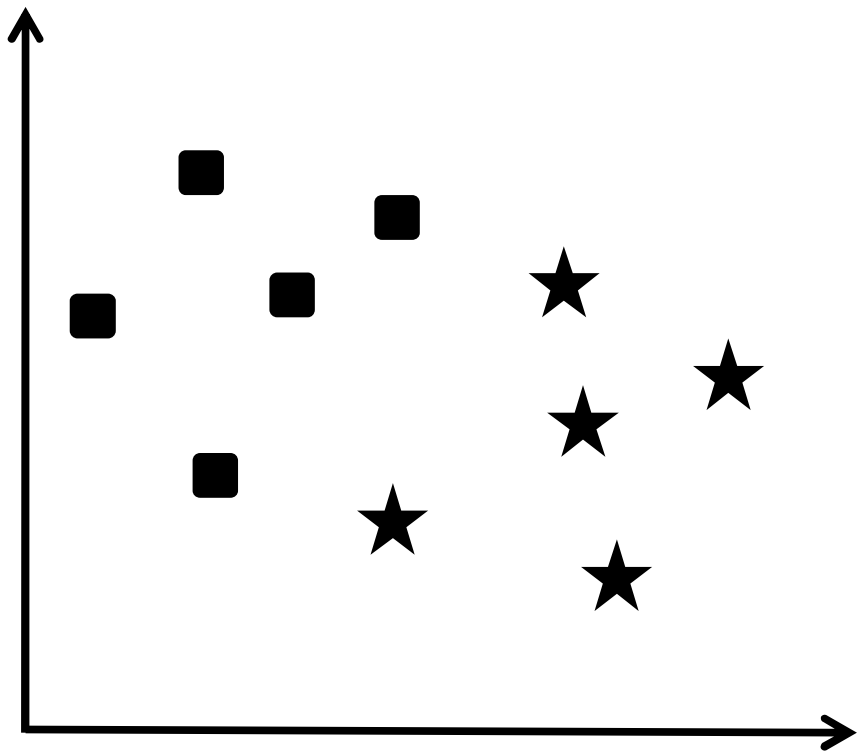

Support Vector Machine

- Como separar essas duas classes?
  - Existem diversas retas que podem ser traçadas para separar os dados.
- Qual delas é a melhor opção?

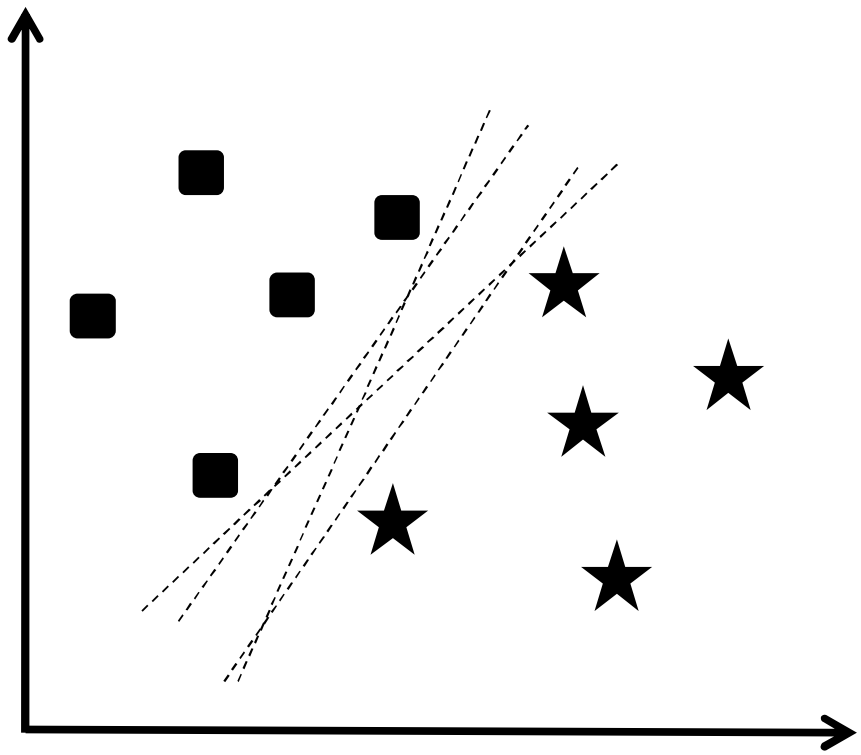

Support Vector Machine

- Como separar essas duas classes?
  - Existem diversas retas que podem ser traçadas para separar os dados.
- Qual delas é a melhor opção?
  - **Hiperplano ótimo!**

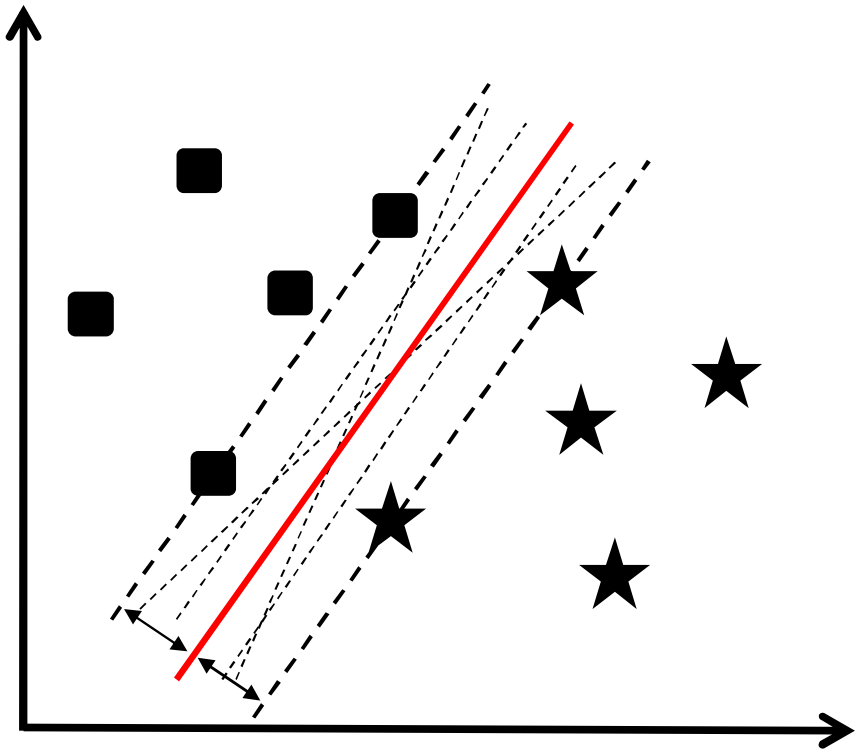

Vetores de Suporte

- Servem para definir qual será o hiperplano.
- São encontrados durante a fase de treinamento.
- Os vetores de suporte são os exemplos de treinamento realmente importantes. Os outros exemplos podem ser ignorados.

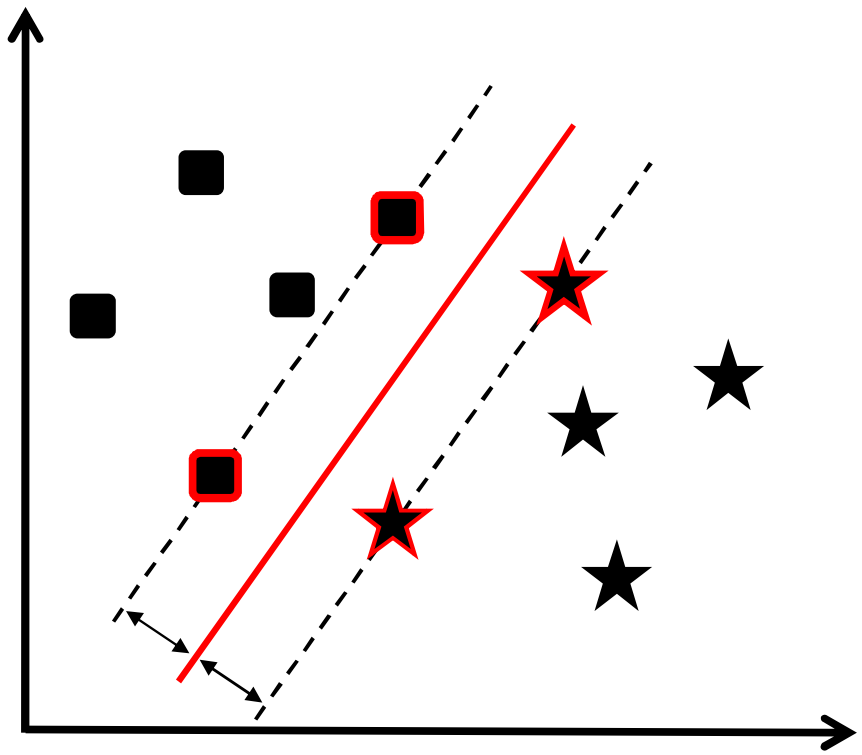

Support Vector Machine

- Hiperplano:
  - Espaço 1D = Ponto

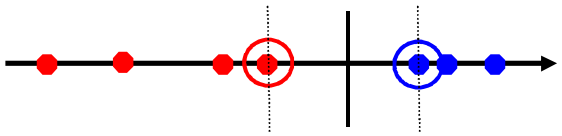

  - Espaço 3D = Plano

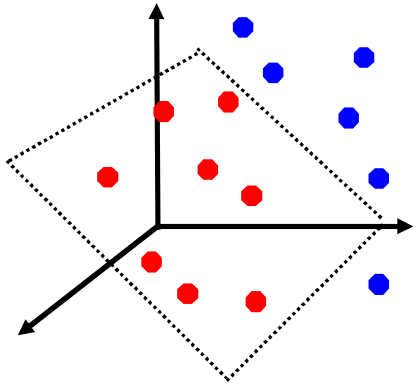

Espaço 2D = Reta

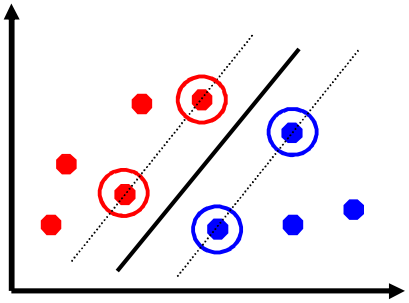

Support Vector Machine

- A aplicação de um método puramente linear para classificar um conjunto de dados pode sofrer com **dois problemas** bastante comuns:
  - Outliers
  - Exemplos rotulados erroneamente
- Mesmo assim o SVM ainda assim pode ser aplicado através do uso do parâmetro C (**soft margin** - variáveis de folga)

Soft Margin

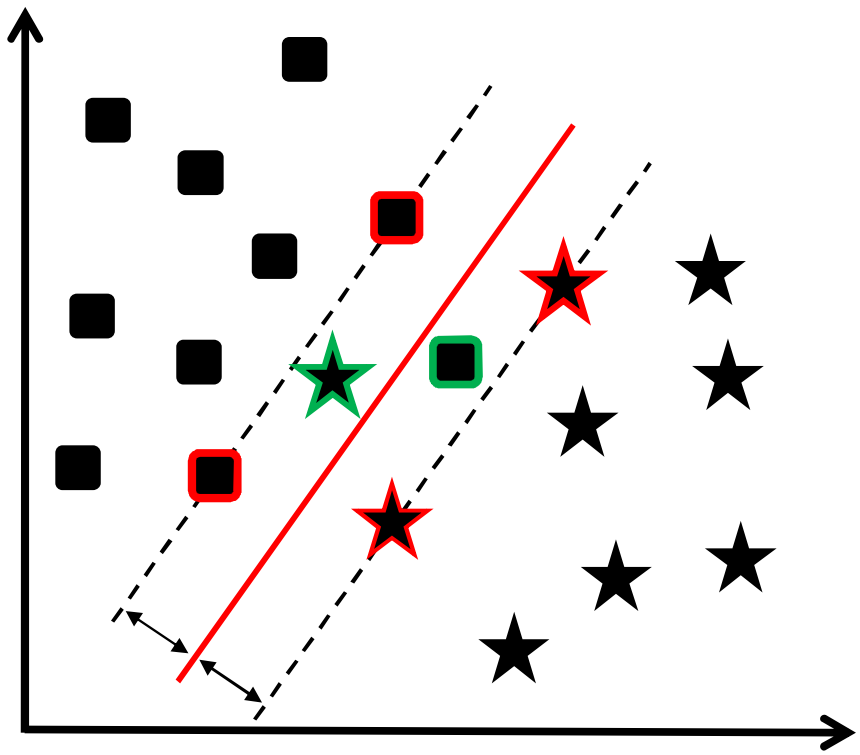

Support Vector Machine

- Em alguns problemas não é possível separar as classes linearmente mesmo utilizando a margem de folga.
- Na realidade, a grande maioria dos problemas reais não são separáveis linearmente.
- O que fazer?

SVM Não-Linear

- O que fazer quando os dados não são linearmente separáveis?

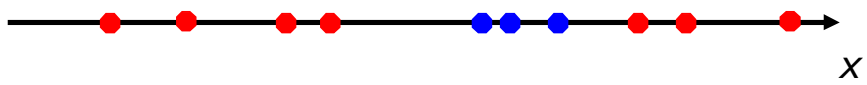

- A abordagem utilizada pelo SVM para resolver esse tipo de problema consistem em mapear os dados para um espaço de dimensão maior:

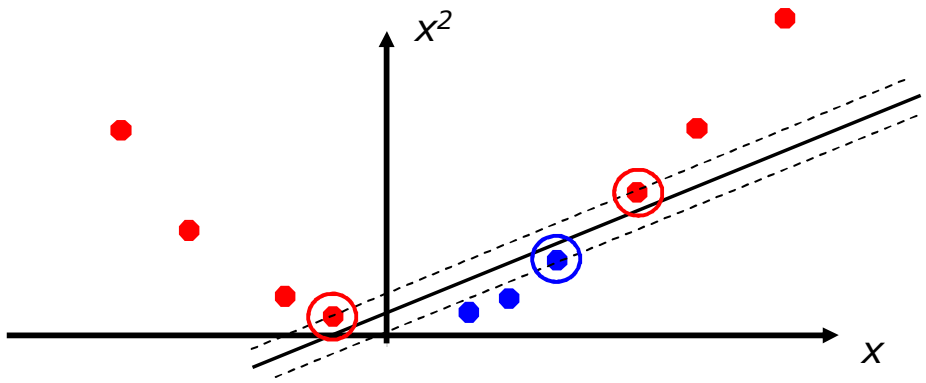

SVM Não-Linear

- O espaço de atributos original pode ser mapeado em um espaço de atributos de dimensão maior onde o conjunto de treinamento é linearmente separável:

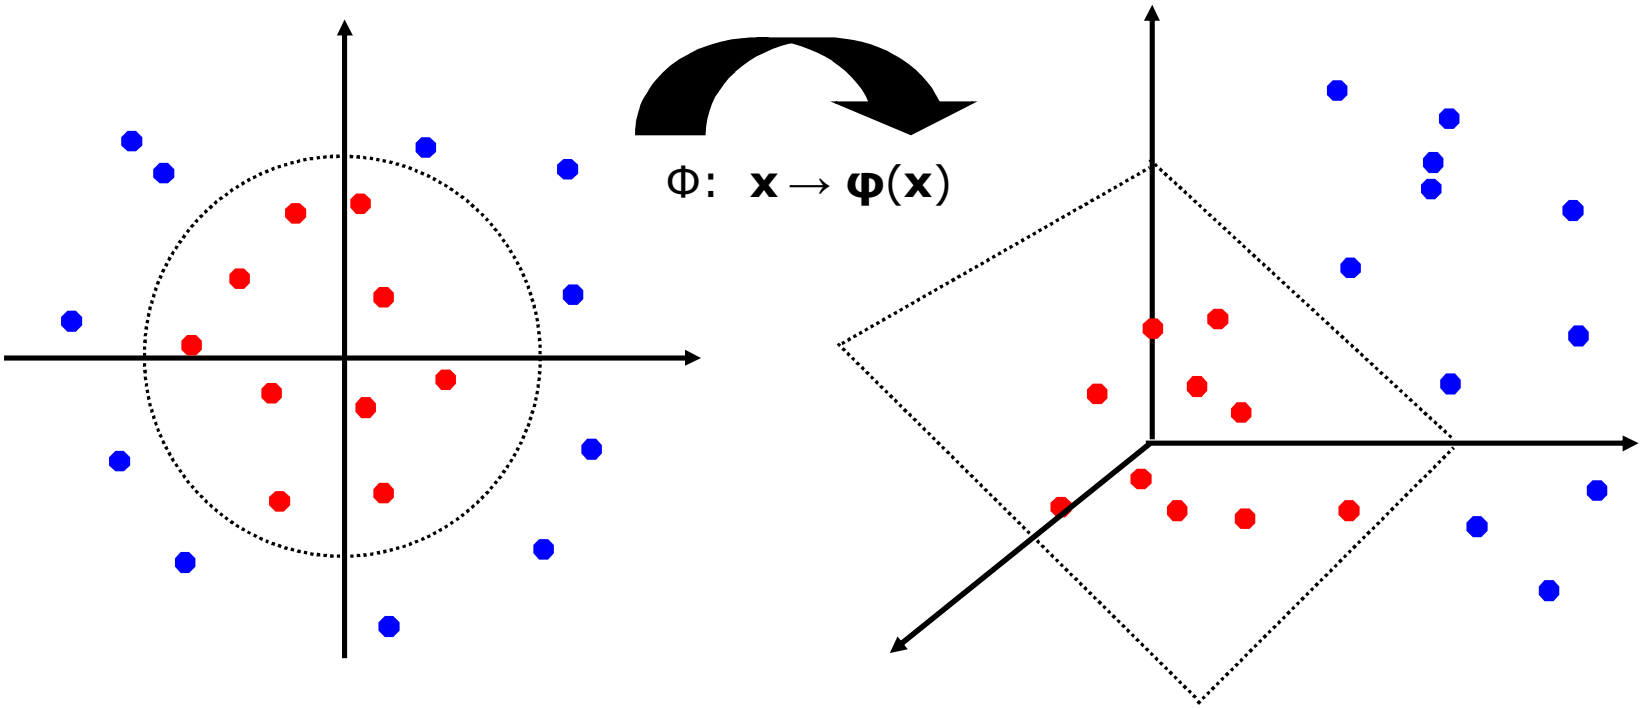

SVM Não-Linear Exemplo

- Considerando o seguinte conjunto de exemplos de treinamento que não são linearmente separáveis:

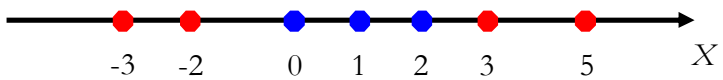

- Elevando para uma dimensão linearmente separável ($R^1 \rightarrow R^2$):

- **Kernel:** $\varphi(x) = (x, x^2)$

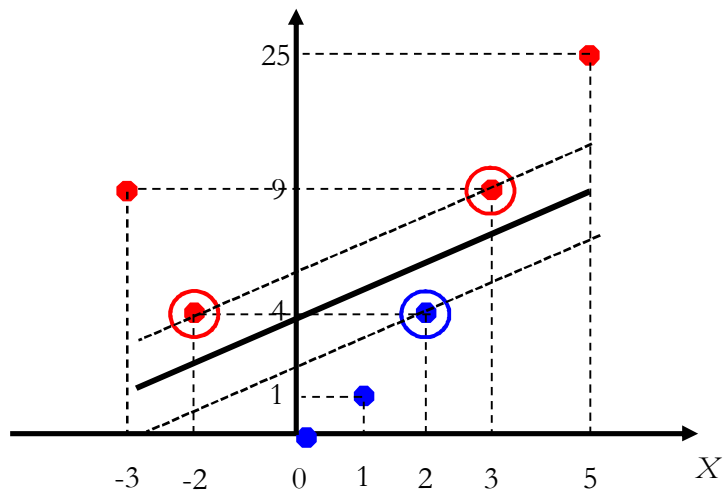

SVM Não-Linear Exemplo

- A mesma metodologia pode ser aplicada em um espaço 2D de características ($R^2 \rightarrow R^3$).

- A única diferença é a necessidade de uma nova função de kernel. Um exemplo de função de kernel aplicável nesse caso seria:

$$\phi(x_1, x_2) \rightarrow (z_1, z_2, z_3) = (x_1^2, \sqrt{2x_1x_2}, x_2^2)$$

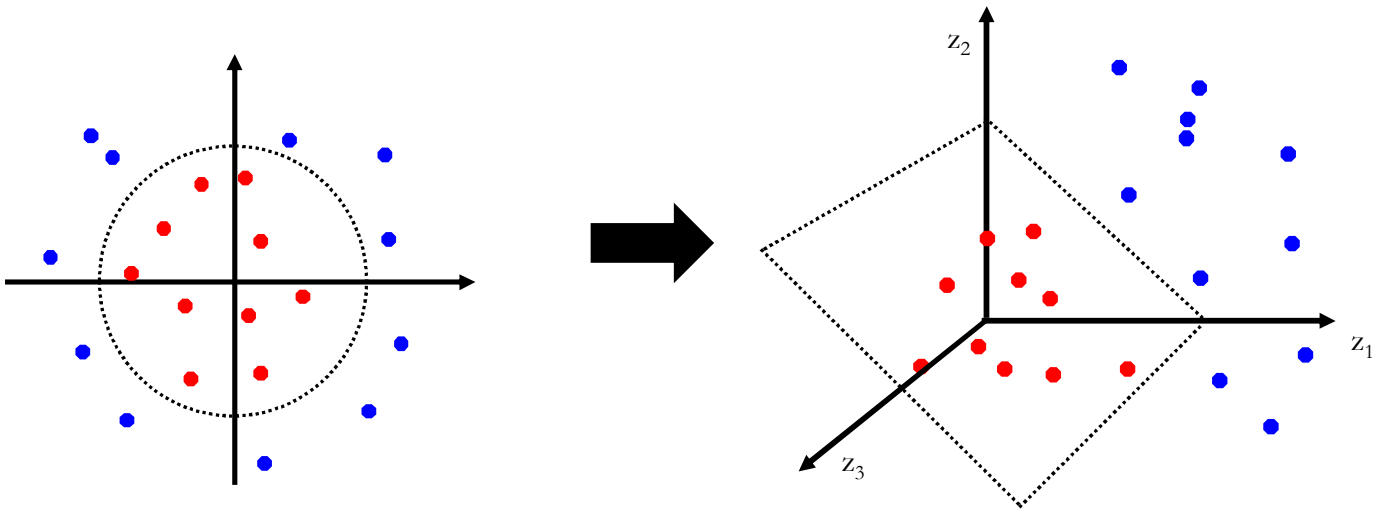

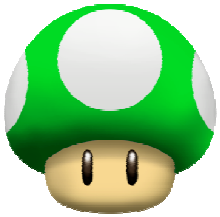

Funções de Kernel

Kernel	**Função** $\phi(x_i, x_j)$
Polinomial	$(\delta(x_i \cdot x_j) + k)^d$
Gaussiano	$\exp(-\sigma \lVert x_i - x_j \rVert^2)$
Sigmoidal	$\tanh(\delta(x_i \cdot x_j) + k)$

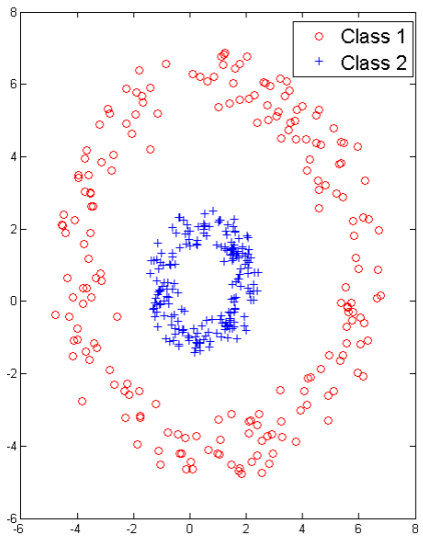

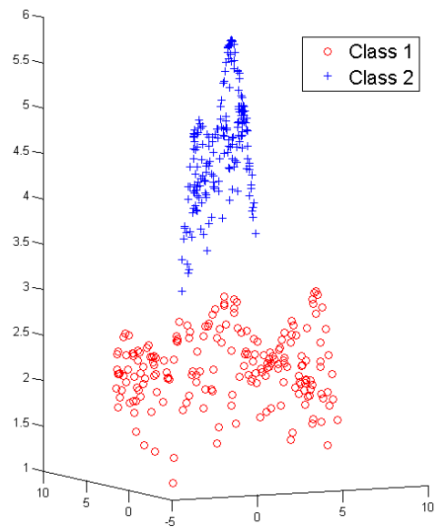

Polynomial Kernel

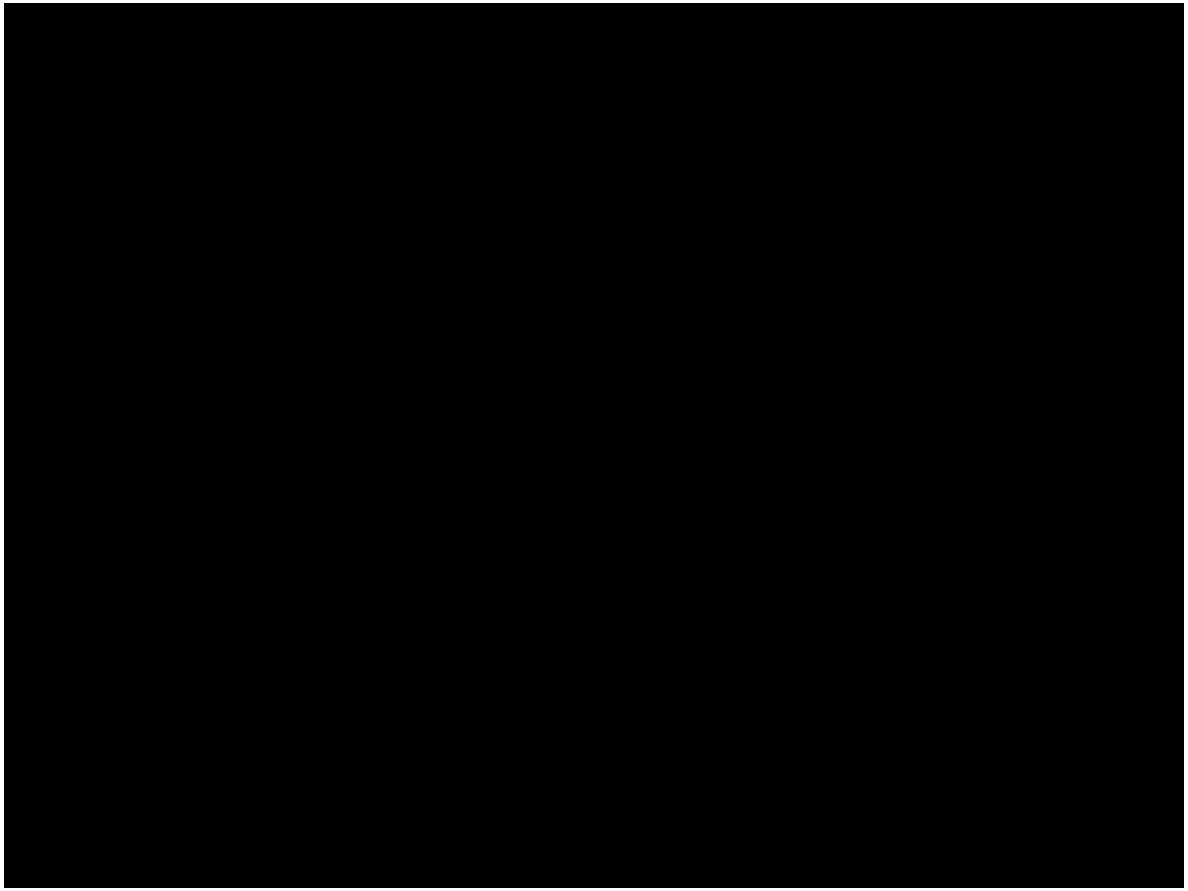

Support Vector Machine

- O SVM foi originalmente concebido para lidar com **classificações binárias**.
- Entretanto, a maior parte dos problemas reais requerem **múltiplas classes**.
- Para se utilizar uma SVM para classificar múltiplas classes é necessário transformar o problema multi-classe em vários problemas da classes binárias
  - Um contra o resto.
  - Pairwise.

Aplicação

- Antes de aplicar uma SVM para classificar um conjunto de dados é necessário responder algumas questões:
  - Quais funções de kernel utilizar?
  - Qual o valor do parâmetro C (Soft Margin)?
- É possível optar por opções comuns, mas uma abordagem mais confiável é a utilização de validações cruzadas (**cross-validations**).

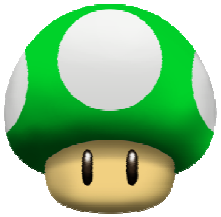

Vantagens de Desvantagens

- **Vantagens:**
  - Consegue lidar bem com grandes conjuntos de exemplos.
  - Trata bem dados de alta dimensão.
  - O processo de classificação é rápido.

- **Desvantagens:**
  - É necessário definir um bom Kernel.
  - O tempo de treinamento pode ser bem longo dependendo do numero de exemplos e dimensionalidade dos dados.

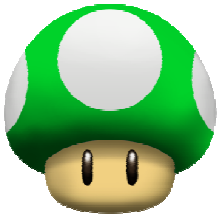

LIBSVM

- http://www.csie.ntu.edu.tw/~cjlin/libsvm/
  - http://www.python.org/download/
  - http://www.gnuplot.info/download.html
- Bases de Exemplos: http://www.csie.ntu.edu.tw/~cjlin/libsvmtools/datasets/
- http://archive.ics.uci.edu/ml/datasets.html