



Máquinas de Vetores

Suporte

Visão Computacional

Programa de Pós-Graduação em Ciência da Computação – UFMA

Prof. Geraldo Braz Junior

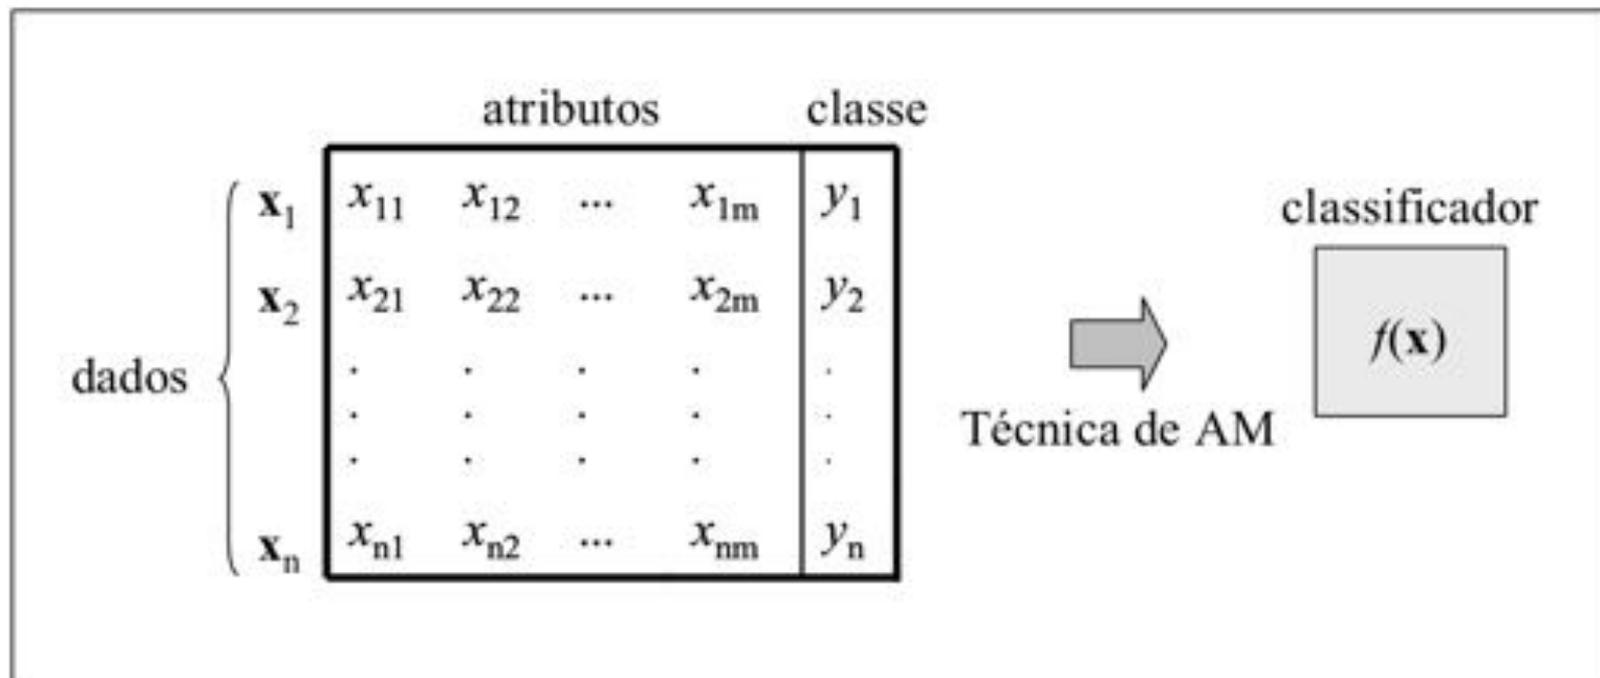
Introdução

- Máquinas de Vetores de Suporte (MVS)
 - Criada por (VAPNIK, 1998) é um método de aprendizagem **supervisionado** usado para estimar uma função que classifique dados de entrada em duas classes (normalmente, mas é multiclass)
 - O objetivo do treinamento através de MVS é a obtenção de hiperplanos que dividam as amostras de tal maneira que sejam otimizados os limites de generalização.

Introdução

- Os algoritmos de treinamento das MVS possuem forte influência da teoria de otimização e de **aprendizagem estatística**
- Resultados normalmente melhores comparado a redes neurais
 - Bons exemplos de aplicações em processamento de imagens, bioinformática, categorização de textos, análise se solo

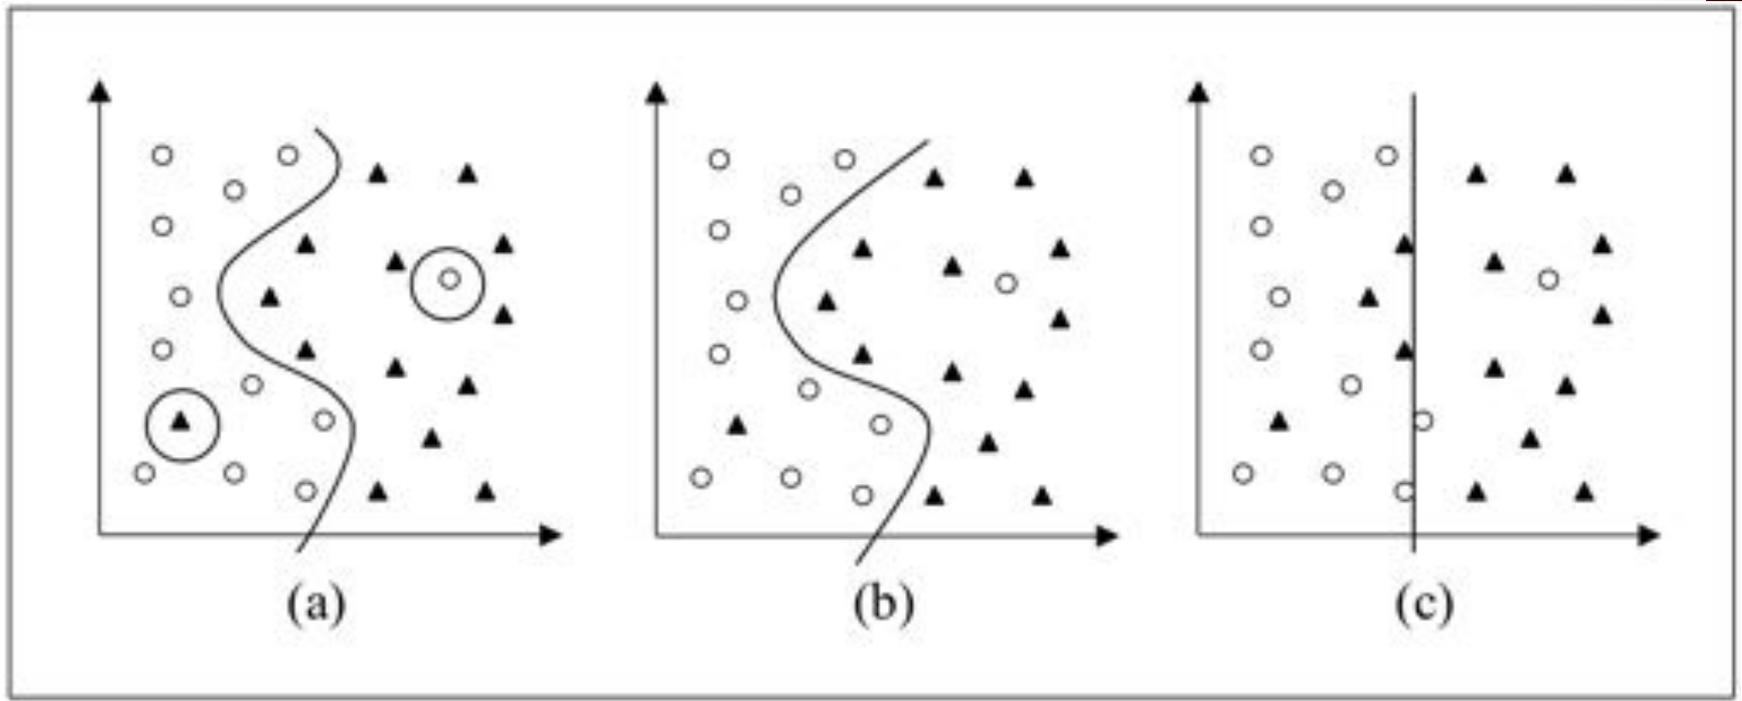
Representação AM



Teoria de Aprendizado Estatístico

- Seja f um classificador e F o conjunto de todos os classificadores que um determinado algoritmo de **AM** pode gerar.
- Esse algoritmo, durante o processo de aprendizado, utiliza um conjunto de treinamento T , composto de n pares (\mathbf{x}_i, y_i) , para gerar um classificador particular $f' \in F$.

Teoria de Aprendizado Estatístico



Funções representadas pelas curvas de decisão
Conjunto de treinamento binário

Qual classificador f escolher?

- Sendo todos dados do domínio gerados de forma independente e identicamente distribuídos (i.i.d)
 - O risco empírico de um classificador f pode ser calculado como:

$$R_{emp}(f) = \frac{1}{n} \sum_{i=1}^n c(f(\mathbf{x}_i), y_i)$$

- Princípio de Minimização de Risco Empírico
- Nem sempre leva a um bom classificador

Limite do Risco Esperado

- Relaciona o Risco Empírico com o Risco Esperado
 - Garantido com probabilidade $1 - \theta$ onde $\theta \in [0, 1]$

$$R(f) \leq R_{emp}(f) + \sqrt{\frac{h \left(\ln \left(\frac{2n}{h} \right) + 1 \right) - \ln \left(\frac{\theta}{4} \right)}{n}}$$

- h denota a dimensão Vapnik-Chervonenkis (VC)
- n qtd exemplos no treinamento

Dimensão VC Vapnik-Chervonenkis

- A dimensão VC h mede a capacidade do conjunto de funções F .
- Quanto maior o seu valor, mais complexas são as funções de classificação que podem ser induzidas a partir de F .
- Dado um problema de classificação binário, essa dimensão é definida como o número máximo de exemplos que podem ser particionados em duas classes pelas funções contidas em F , para todas as possíveis combinações binárias desses dados.

Contribuição Risco Esperado

- Importância de se controlar a capacidade do conjunto de funções F do qual o classificador é extraído
 - Bom classificador minimiza o Risco Empírico e que possua a uma classe de funções F com baixa dimensão VC h
 - **Minimização de Risco Estrutural**

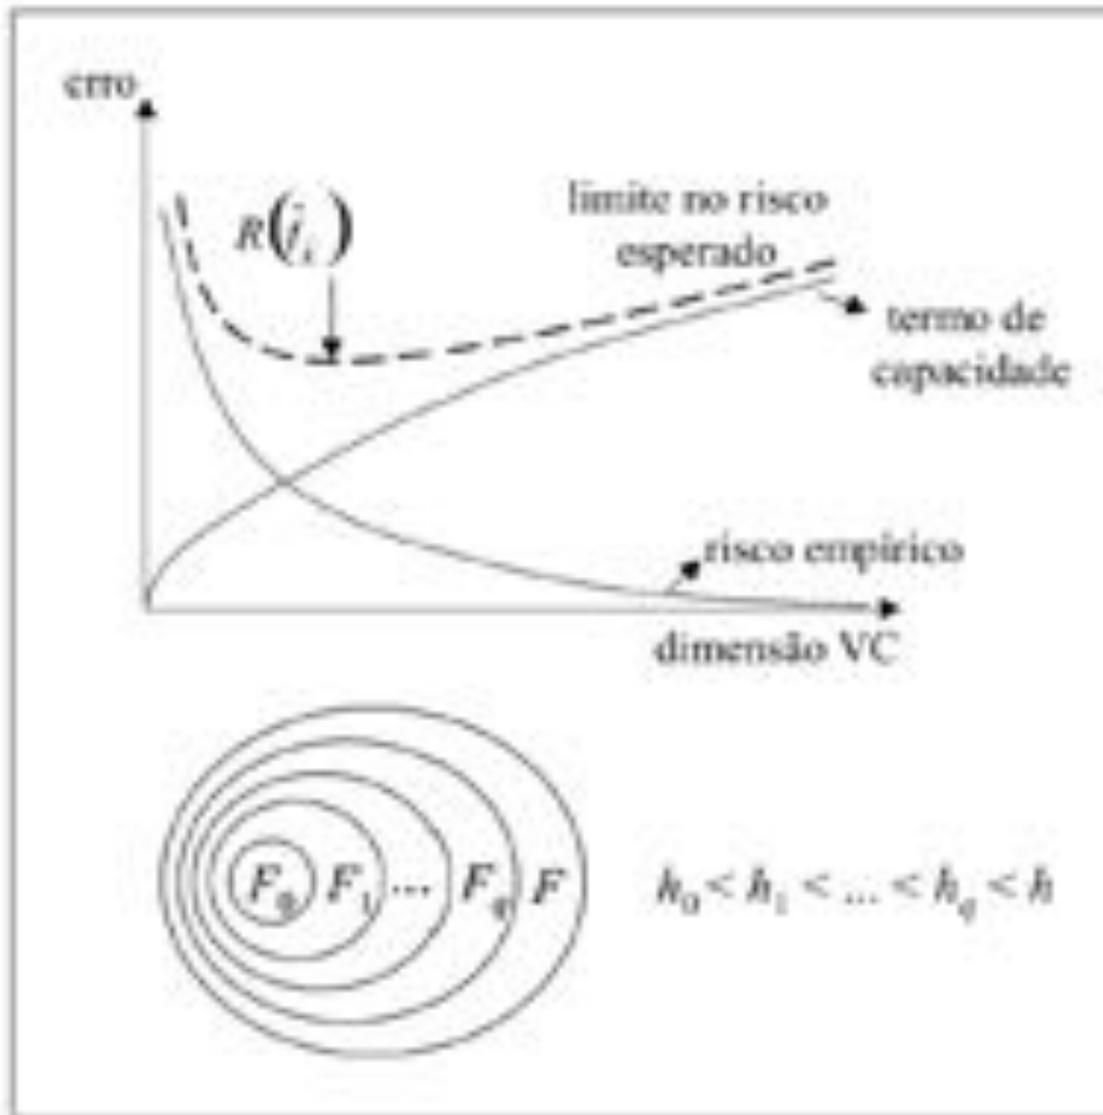
Como escolher

- Divide-se inicialmente F em subconjuntos de funções com dimensão VC crescente

Princípio da Minimização do Risco Estrutural

- **Introduzir** uma estrutura (função de classificação) em F
- Minimiza-se então o limite sobre as estruturas introduzidas.
- Quanto **maior a capacidade** menor o **risco empírico** pela complexidade das funções

Princípio de Minimização de Risco Estrutural



Na prática

- Útil na definição do procedimento de minimização de risco estrutural
- Mas ...
 - Computar a dimensão VC de uma classe de funções geralmente não é uma tarefa trivial.
 - Soma-se a isso o fato de que o valor de h poder ser desconhecido ou infinito

Para funções Lineares

- Relacionamento do risco esperado com a **margem** (distância da fronteira de decisão induzida)

$$\rho(f(\mathbf{x}_i), y_i) = y_i f(\mathbf{x}_i)$$

Erro Marginal

- Assim o erro marginal pode ser calculado por:

$$R_\rho(f) = \frac{1}{n} \sum_{i=1}^n I(y_i f(x_i) < \rho)$$

- Onde $I(q) = 1$ se q é verdadeiro e $I(q) = 0$ se q é falso.
- Um ρ elevado implica um menor termo de capacidade

Hiperplano Ótimo

- Como conclusão tem-se que:
 - deve-se buscar um hiperplano que tenha margem elevada
 - e cometa poucos erros marginais, minimizando assim o erro sobre os dados de teste e de treinamento, respectivamente.
- Esse hiperplano é denominado ótimo

MVS Lineares (Rígidas)

- Definem fronteiras lineares a partir de dados linearmente separáveis
 - Hiperplano linear é definido por

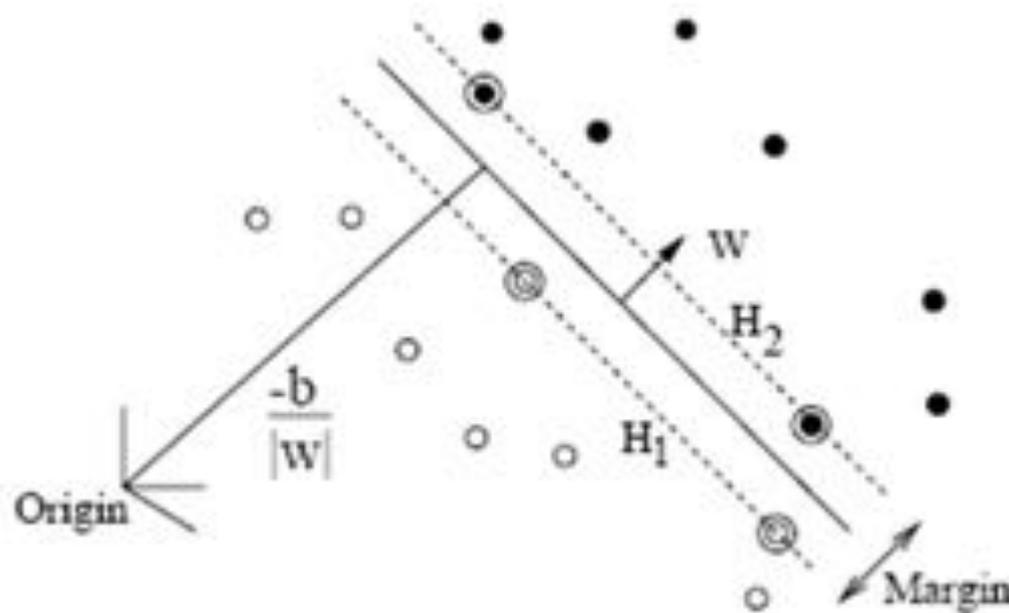
$$f(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b = 0$$

- Onde em que $\mathbf{w} \cdot \mathbf{x}$ é o produto escalar entre os **vetores \mathbf{w} e \mathbf{x}**
- $\mathbf{w} \in X$ é o vetor normal ao hiperplano descrito
- $b / ||\mathbf{w}||$ corresponde à distância do hiperplano em relação à origem

MVS Lineares (Rígidas)

- Função $g(x)$ divide o espaço X em duas regiões

$$g(x) = \text{sgn}(f(x)) = \begin{cases} +1 & \text{se } w \cdot x + b > 0 \\ -1 & \text{se } w \cdot x + b < 0 \end{cases}$$



Função Objetivo

- Logo para se obter maximização da margem, deve-se minimizar a norma de w através de:

$$\text{Minimizar}_{w,b} \frac{1}{2} \|w\|^2$$

$$y_i (w \cdot x_i + b) - 1 \geq 0, \quad \forall i = 1, \dots, n$$

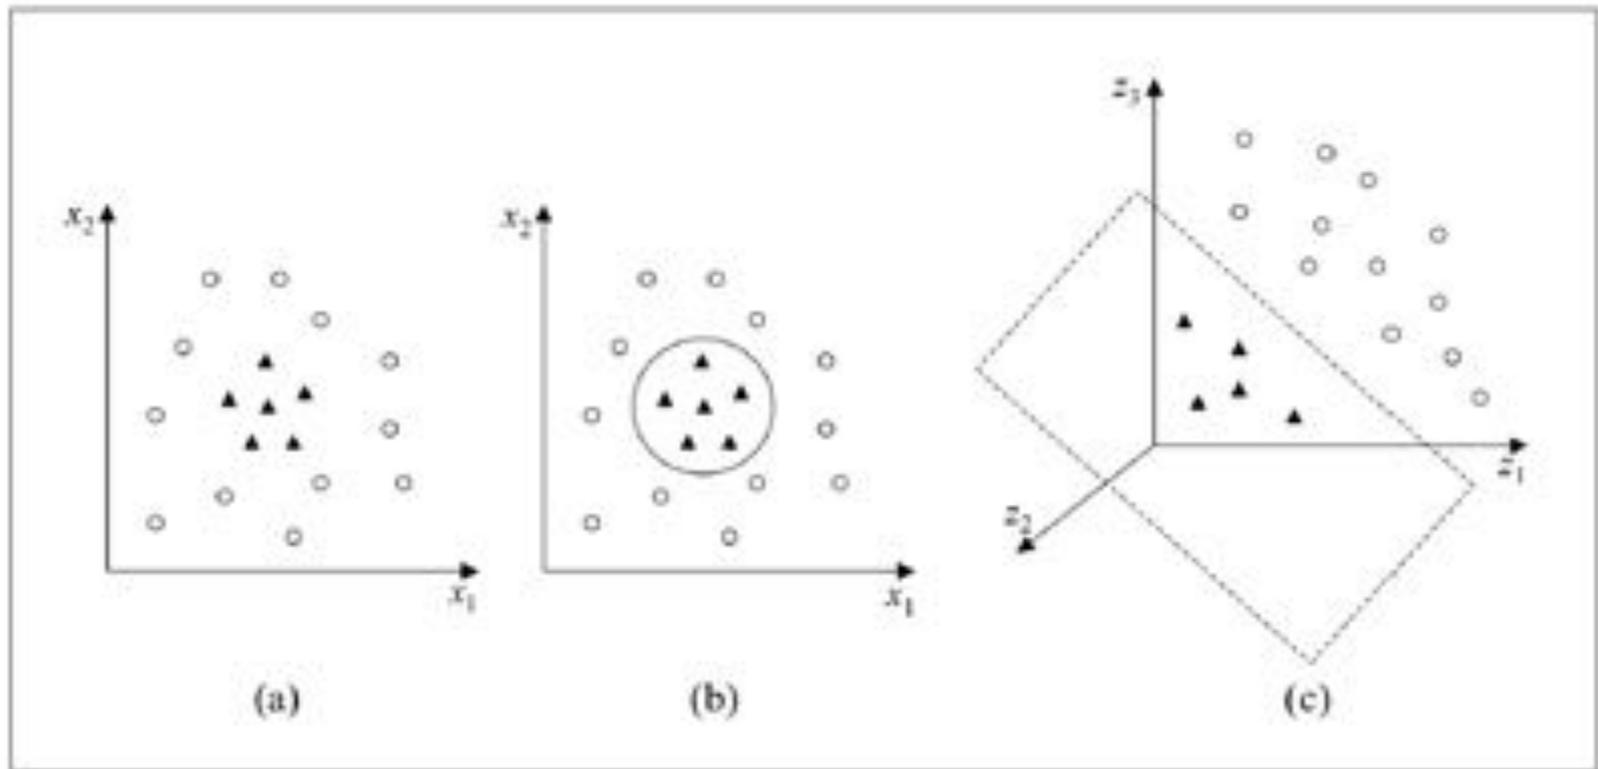
MVS com Margem Suave

- Presença de ruídos e *outliers*
- Sujeito a restrição:
- Nova função objetivo:

$$y_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad \forall i = 1, \dots, n$$

$$\text{Minimizar}_{\mathbf{w}, b, \xi} \quad \frac{1}{2} \|\mathbf{w}\|^2 + C \left(\sum_{i=1}^n \xi_i \right)$$

MVS não Linear



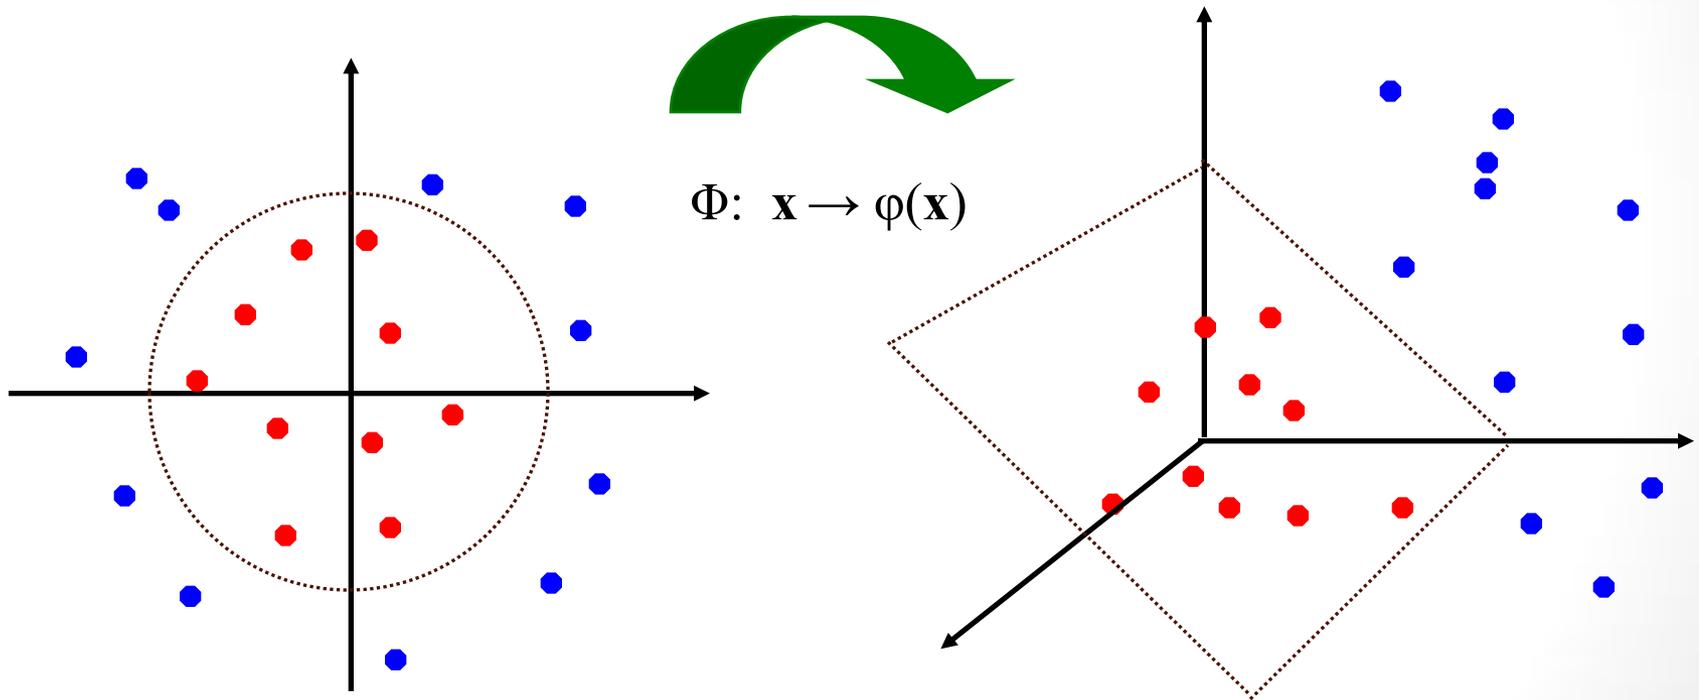
MVS não Linear

- Lidam com este problema mapeando o espaço de treinamento para um novo espaço de maior dimensão denominado *feature space*
 - Através de uma função Φ
 - Mapeamento da figura anterior realizado por:

$$\Phi(\mathbf{x}) = \Phi(x_1, x_2) = \left(x_1^2, \sqrt{2}x_1x_2, x_2^2 \right)$$

$$f(\mathbf{x}) = \mathbf{w} \cdot \Phi(\mathbf{x}) + b = w_1x_1^2 + w_2\sqrt{2}x_1x_2 + w_3x_2^2 + b = 0$$

Função Φ



Funções Kernel Comum

Tipo de Kernel	Função $K(\mathbf{x}_i, \mathbf{x}_j)$	Parâmetros
Polinomial	$(\delta (\mathbf{x}_i \cdot \mathbf{x}_j) + \kappa)^d$	δ, κ e d
Gaussiano	$\exp(-\sigma \ \mathbf{x}_i - \mathbf{x}_j\ ^2)$	σ
Sigmoidal	$\tanh(\delta (\mathbf{x}_i \cdot \mathbf{x}_j) + \kappa)$	δ e κ

Usando SVM no opencv

Pacote SVM em ML

- Funções básicas
 - `train`: treina SVM com parâmetros informados
 - `trainAuto`: descobre parâmetros para SVM e treina
 - `predict`: realiza o teste

Vide exemplos



Usando SVM

com libsvm

LIBSVM

- Biblioteca básica com implementação do SVM (<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>)
 - Java
 - C/C++
 - Depende de python para rodar alguns scripts
- Implementações
 - Classificação (C-SVC, nu-SVC)
 - Regressão (episolon-SVR, nu-SVR)
 - Estimação de distribuição (one-class SVM)
 - Utilitários para facilitar o processo de classificação

Como usar? Classificação

- Para estratégia dividindo **treinamento** e teste (ou validação)
- Colocar a base no formato .libsvm

```
1 1:0.1 2:2.3 3:1.0
-1 1:0.2 2:1.3 3:0.5
1 1:0.3 2:3.3 3:1.2
...
```

- Utilitários básicos (são aplicados na ordem abaixo)
 1. svm-scale
 2. subset.py
 3. grid.py
 4. svm-train
 5. svm-predict

1) svm-scale

- Serve para normalizar as variáveis. Melhora a convergência do método
- Faixas definidas pelos parâmetros $-l$ (lower) e $-u$ (upper)
 - vide outras opções de salvar...

USO:

```
svm-scale heart_scale > heart_scale.scale
```

Normaliza entre a faixa -1 a 1, por padrão.

*<https://www.csie.ntu.edu.tw/~cjlin/libsvmtools/datasets/binary/heart>

2) subset.py

- Fica na pasta tools do aplicativo
- Utilizado para gerar bases de treinamento e bases de teste
 - deve utilizar o parâmetro `-s 1` para garantir aleatoriedade

USO

```
tools/subset.py -s 1 heart_scale.scale 135 train test
```

Gera os arquivos train e test.

Train é usado para treinamento (grid e svm-train)

Test é usado para avaliar a metodologia (svm-predict)

3) grid.py

- Fica na pasta tools
- Serve para estimar os parâmetros do SVM (C e gama) quando for utilizado o núcleo radial

USO

`tools/grid.py train`

```
[local] 13 -5 75.5556 (best c=8.0, g=0.0078125, rate=85.9259)
[local] 13 -15 85.9259 (best c=8.0, g=0.0078125, rate=85.9259)
[local] 13 3 60.7407 (best c=8.0, g=0.0078125, rate=85.9259)
[local] 13 -9 79.2593 (best c=8.0, g=0.0078125, rate=85.9259)
[local] 13 -3 77.037 (best c=8.0, g=0.0078125, rate=85.9259)
8.0 0.0078125 85.9259
```



C



Gama



Acc

4) svm-train

- Realiza o treinamento SVM criando um modelo
- Por padrão usa:
 - -s svm-type = C-SVC (para classificação)
 - -t kernel-type = radial
- Deve ser informado o C e gama obtidos na etapa anterior
 - -c XXX
 - -g YYY
- Pode aplicar -v para validação cruzada informando o número de folds

4) svm-train

USO

`svm-train -c 8 -g 0.0078125 train modelo`

```
* UFMA
optimization finished, #iter = 88
nu = 0.436144
obj = -407.886185, rho = 0.191294
nSV = 64, nBSV = 54
Total nSV = 64
```

Representa quantos vetores foram utilizados para o modelo de treinamento.

Quanto menor, melhor (menor dimensão VC)

O arquivo modelo gerado representa o treinamento do SVM

5) svm-predict

- A partir do arquivo de modelo, usa o arquivo de test para avaliar o método

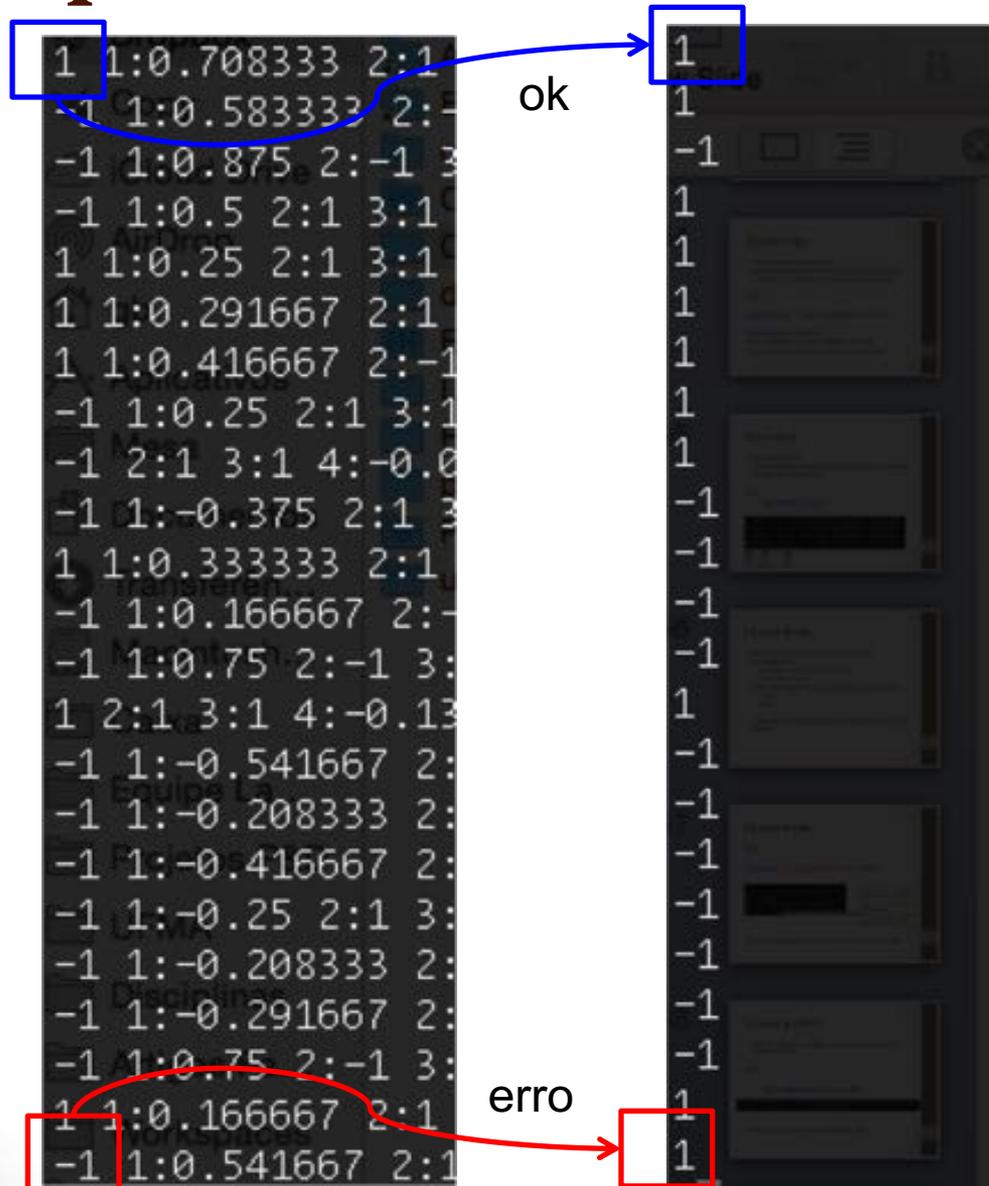
USO

svm-predict test modelo rtest

```
MacBook-Pro-de-Geraldo:libsvm-3.20 gb$ svm-predict test modelo rtest  
Accuracy = 82.963% (112/135) (classification)
```

Em **rtest** é gravado o resultado da classificação

Arquivo rtest



- Usado para avaliar os resultados
- Compara cada resposta esperada, com a resposta gerada

Quando se deseja obter Probabilidades

- Use o parâmetro `-b 1` no `svm-train` para obter as probabilidades por classe

USO

```
svm-train -b 1 -c 8 -g 0.0078125 train modelo
```

Para o `heart_scale`

Perceba que foram usados os mesmos parâmetros do grid

Quando se deseja obter Probabilidades

- e incluir o mesmo parâmetro no svm-predict

USO

```
svm-predict -b 1 test modelo rtest
```

Saída com probabilidades

1	1:0.708333	2:1	1	0.959263	0.0407366	
-1	1:0.583333	2:-1	1	0.933212	0.0667885	
-1	1:0.875	2:-1	1	0.80885	0.19115	
-1	1:0.5	2:1	3:1	-1	0.122729	0.877271
1	1:0.25	2:1	3:1	-1	0.302207	0.697793
1	1:0.291667	2:1	1	0.955871	0.0441294	
1	1:0.416667	2:-1	1	0.846384	0.153616	
-1	1:0.25	2:1	3:1	-1	0.131076	0.868924
-1	2:1	3:1	4:-0.0	-1	0.0842905	0.91571
-1	1:-0.375	2:1	3	-1	0.14609	0.85391
1	1:0.333333	2:1	-1	0.209301	0.790699	
-1	1:0.166667	2:-1	1	0.723051	0.276949	
-1	1:0.75	2:-1	3:	-1	0.22567	0.77433
1	2:1	3:1	4:-0.13	1	0.727965	0.272035
-1	1:-0.541667	2:	1	0.950781	0.049219	
-1	1:-0.208333	2:	1	0.920036	0.0799635	
-1	1:-0.416667	2:	-1	0.0849741	0.915026	
-1	1:-0.25	2:1	3:	-1	0.0881266	0.911873
-1	1:-0.208333	2:	-1	0.330041	0.669959	
-1	1:-0.291667	2:	-1	0.076559	0.923441	
-1	1:0.75	2:-1	3:	-1	0.122144	0.877856
1	1:0.166667	2:1	1	0.573081	0.426919	
-1	1:0.541667	2:1	1	0.930212	0.0697881	
			-1	0.0371023	0.962898	

ok

- Usado para avaliar os resultados
- Aqui cada linha também contém o grau de pertinência entre classes

Conjuntos desbalanceados?

- Desbalanceamento: existem mais representantes da classe 1 do que da classe 0
- SVM não necessita de ajustes para conjuntos levemente desbalanceados
- Para conjuntos fortemente desbalanceados é necessário ajustar a quantidade de erro que pode ser suportada
 - Ou para conjuntos onde existe uma necessidade maior de acerto de um conjunto em relação ao outro
- **Pense: Porque?**

Weighted SVM

- Uma das maneiras é usando o parâmetro `-wi VALOR`
 - onde **i** é o número da classe e **VALOR** a quantidade de peso
- **Na prática diz ao classificador quanto irá custar a mais errar (VALOR) um indivíduo da classe I**
- O que muda?
 - `tools/grid.py -w1 5 train`
 - `svm-train -c 8 -g 0.5 -w1 5 train modelo`

```
MacBook-Pro-de-Geraldo:datasets gb$ svm-predict test modelo rtest  
Accuracy = 73.3333% (99/135) (classification)
```

Como usar? Regressão

- Para estratégia dividindo **treinamento** e teste (ou validação)
- Colocar a base no formato `.libsvm`

```
1 1:0.1 2:2.3 3:1.0
-1 1:0.2 2:1.3 3:0.5
1 1:0.3 2:3.3 3:1.2
...
```

- Utilitários básicos (são aplicados na ordem abaixo)
 1. `svm-scale`
 2. `subset.py`
 3. **`gridregression.py`**
 4. `svm-train`
 5. `svm-predict`

1) svm-scale

- Serve para normalizar as variáveis. Melhora a convergência do método
- Faixas definidas pelos parâmetros `-l` (lower) e `-u` (upper)
 - vide outras opções de salvar...

USO:

```
svm-scale body_fat > body_fat.scale
```

Normaliza entre a faixa -1 a 1, por padrão.

*<https://www.csie.ntu.edu.tw/~cjlin/libsvmtools/datasets/regression/bodyfat>

2) subset.py

- Fica na pasta tools do aplicativo
- Utilizado para gerar bases de treinamento e bases de teste
 - deve utilizar o parâmetro `-s 1` para garantir aleatoriedade

USO

```
tools/subset.py -s 1 body_fat.scale 125 train test
```

Gera os arquivos train e test.

Train é usado para treinamento (**gridregression** e svm-train)

Test é usado para avaliar a metodologia (svm-predict)

3) gridregression.py

- Deve ser baixado como add-on do libsvm
- Serve para estimar os parâmetros do SVM (C e gama) quando for utilizado o núcleo radial e do epsilon para regressão

USO

`tools/gridregression.py train`

```
[local] -1 -5 -2 0.000373225 (best c=4.0, g=0.00390625, p=0.00390625, mse=2.25268e-05)
[local] -1 -5 -7 4.28891e-05 (best c=4.0, g=0.00390625, p=0.00390625, mse=2.25268e-05)
[local] -1 -5 -3 0.000373225 (best c=4.0, g=0.00390625, p=0.00390625, mse=2.25268e-05)
[local] -1 -5 -5 0.000245227 (best c=4.0, g=0.00390625, p=0.00390625, mse=2.25268e-05)
[local] -1 -5 -1 0.000373225 (best c=4.0, g=0.00390625, p=0.00390625, mse=2.25268e-05)
[local] -1 -5 -8 2.49217e-05 (best c=4.0, g=0.00390625, p=0.00390625, mse=2.25268e-05)
4.0 0.00390625 0.00390625 2.25268e-05
```



C



Gama



p



mean square error

4) svm-train

- Realiza o treinamento SVM criando um modelo
- Por padrão usa:
 - -s svm-type = **epsilon-SVR (para regressão)**
 - -t kernel-type = radial
- Deve ser informado o C e gama obtidos na etapa anterior
 - -c XXX
 - -g YYY
 - -p YYY
- Pode aplicar -v para validação cruzada informando o número de folds

4) svm-train

USO

```
svm-train -s 3 -c 4.0 -g 0.00390625 -p 0.00390625  
train modelo
```

```
*  
optimization finished, #iter = 77  
nu = 0.057647  
obj = -0.330552, rho = -1.078779  
nSV = 17, nBSV = 3
```

Representa quantos vetores foram utilizados para o modelo de treinamento.

Quanto menor, melhor (menor dimensão VC)

O arquivo modelo gerado representa o treinamento do SVM

5) svm-predict

- A partir do arquivo de modelo, usa o arquivo de test para avaliar o método

USO

svm-predict test modelo rtest

```
Mean squared error = 6.48333e-06 (regression)  
Squared correlation coefficient = 0.984702 (regression)
```

Em **rtest** é gravado o resultado da classificação

Arquivo rtest

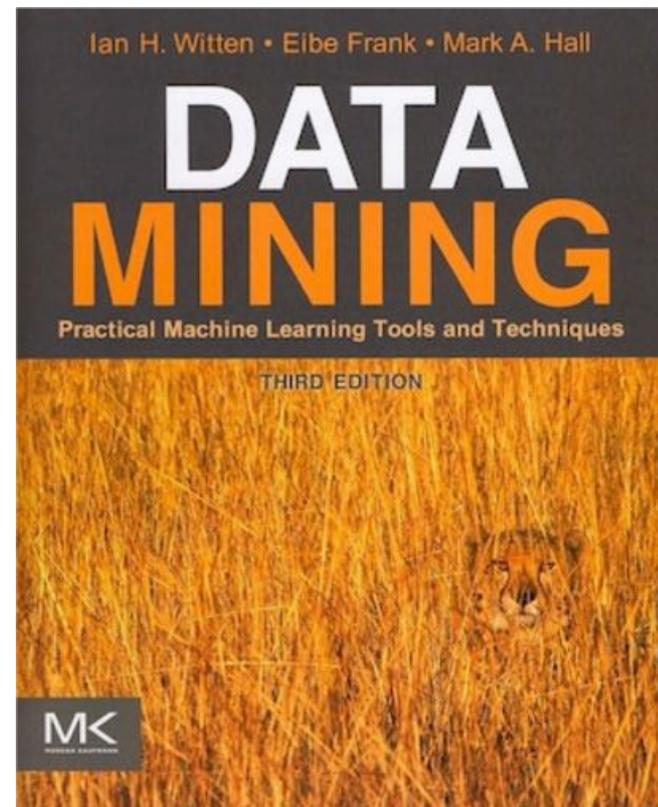
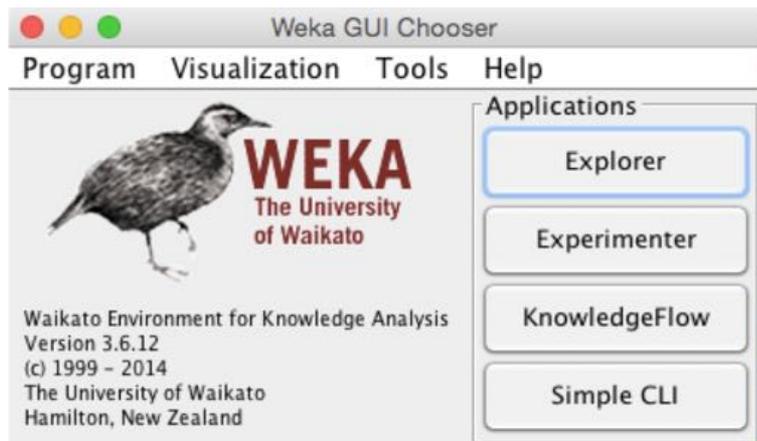
```
1.06973
1.08408
1.07494
1.05311
1.08593
1.0723
1.0816
1.05338
1.05111
1.03437
1.04874
1.05638
1.0651
1.06643
1.06183
1.06987
1.05091
1.08933
1.07797
1.06803
1.07623
1.04836
1.02707
1.03838
1.02585
1.02112
1.02991
1.06979
1.07664
1.0667
```

- Usado para avaliar os resultados
- Compara cada resposta esperada, com a respost gerada

Usando o Weka a nosso favor

O que é

- Software livre, voltado para a mineração dados
- Mantenedora principal: University of Waikato (<http://www.cs.waikato.ac.nz/ml/weka/>)



Weka Explorer – Usando SVM

- Inicialmente deve ser linkar o libsvm com o weka
- Maneira #1: incluir no classpath

```
java -classpath $CLASSPATH:weka.jar:libsvm.jar  
weka.gui.GUIChooser
```

- Maneira #2: maior parte das vezes já está incluída no pacote completo do weka

Weka Explorer

The screenshot shows the Weka Explorer application window. The 'Preprocess' tab is active. The 'Open file...' button is circled in red. Below the buttons, there is a 'Filter' section with a 'Choose' button and a text field containing 'Normalize -S 1.0 -T 0.0'. The 'Current relation' section shows 'Relation: iris-weka.filters.unsupervised.attribute.Nor...' and 'Instances: 150 Attributes: 5'. The 'Attributes' section has buttons for 'All', 'None', 'Invert', and 'Pattern', and a list of attributes: '1 sepalength', '2 sepalwidth', '3 petalength', '4 petalwidth', and '5 class'. The 'Selected attribute' section shows 'Name: sepalength', 'Type: Numeric', 'Missing: 0 (0%)', 'Distinct: 35', and 'Unique: 9 (6%)'. A table of statistics is displayed:

Statistic	Value
Minimum	0
Maximum	1
Mean	0.429
StdDev	0.23

Below the statistics, there is a 'Class: class (Nom)' dropdown and a 'Visualize All' button. A histogram is shown at the bottom right, with a yellow tooltip that says 'The chosen attribute will als'. The histogram has bars of different colors (blue, red, cyan) and values (16, 30, 34, 28, 25, 10, 7) above them. The x-axis ranges from 0 to 1. The status bar at the bottom left shows 'Status OK' and a 'Log' button.

Filter

- Filter -> unsupervised -> attribute -> Normalize

Weka Explorer

Preprocess | Classify | Cluster | Associate | Select attributes | Visualize

Open file... Open URL... Open DB... Generate... Undo Edit... Save...

Filter

Choose **Normalize -S 1.0 -T 0.0** Apply

Current relation
Relation: iris-weka.filters.unsupervised.attribute.Nor...
Instances: 150 Attributes: 5

Selected attribute
Name: sepalength Type: Numeric
Missing: 0 (0%) Distinct: 35 Unique: 9 (6%)

Statistic	Value
Minimum	0
Maximum	1
Mean	0.429
StdDev	0.23

Attributes

All None Invert Pattern

No.	Name
1	<input checked="" type="checkbox"/> sepalength
2	<input type="checkbox"/> sepalwidth
3	<input type="checkbox"/> petallength
4	<input type="checkbox"/> petalwidth
5	<input type="checkbox"/> class

Remove

Class: class (Nom) Visualize All

The chosen attribute will als

16 30 34 28 25 10 7

0 0.5 1

Status OK Log x 0

Classify

Weka Explorer

Preprocess **Classify** Cluster Associate Select attributes Visualize

Classifier: Choose **LibSVM -S 0 -K 2 -D 3 -G 0.0 -R 0.0 -N 0.5 -M 40.0 -C 1.0 -E 0.001 -P 0.1 -seed 1**

Test options:
 Use training set
 Supplied test set (Set...)
 Cross-validation Folds:
 Percentage split %:
More options...

(Nom) class:

Start Stop

Result list (right-click for options):
15:20:10 - functions.LibSVM

Classifier output

```
=== STRATIFIED cross-validation ===  
=== Summary ===  
Correctly Classified Instances      144      96 %  
Incorrectly Classified Instances     6        4 %  
Mean absolute error                  0.0267  
Root mean squared error              0.1633  
Relative absolute error              6 %  
Root relative squared error          34.641 %  
Total Number of Instances           150
```

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC AUC
1	0.96	0	0.923	1	0.941	0.96
2	0.92	0.02	0.958	0.92	0.939	0.96
Weighted Avg.	0.96	0.02	0.96	0.96	0.96	0.96

=== Confusion Matrix ===

a	b	c	←← classified as
50	0	0	a = Iris-setosa
0	48	2	b = Iris-versicolor
0	4	46	c = Iris-virginica

Status: OK

Log x 0

Ajuste de Parâmetros

- Meta -> GridSearch



Ajuste de Parâmetros

- Meta -> GridSearch
 - classifier: escolha libsvm
 - evaluation: accuracy (veja se é o melhor para você)
 - filer: escolha Allfilter (não vamos fazer nenhuma filtragem)
- Em:
 - Xexpression = pow(BASE,I)
 - Xmax = 15
 - Xmin = -5
 - Xproperty = classifier.cost
 - Xstep = 1
 - Xbase = 2
 -

Ajuste de Parâmetros

- Em:
 - $Y_{\text{expression}} = \text{pow}(\text{BASE}, I)$
 - $Y_{\text{max}} = 3.0$
 - $Y_{\text{min}} = -15$
 - $Y_{\text{property}} = \text{classifier. gamma}$
 - $Y_{\text{step}} = 1$
 - $Y_{\text{base}} = 2$
- E SALVE!

Ajuste de Parâmetros

Ajuste o percentual!



Weka Explorer

Preprocess **Classify** Cluster Associate Select attributes Visualize

Classifier
Choose **GridSearch** -E ACC -y-property classifier.gamma -y-min -15.0 -y-max 3.0 -y-step 1.0 -y-base 10.0 -

Determine relevance of attributes

Test options

- Use training set
- Supplied test set
- Cross-validation Folds
- Percentage split %

(Nom) class

Result list (right-click for options)

- 13:42:47 - meta.GridSearch

Classifier output

=== Run information ===

Scheme:weka.classifiers.meta.GridSearch -E ACC -y-property classifier.gamma -y-min -15.0 -y-max 3.0 -y-step 1.0 -y-base 10.0
Relation: iris-weka.filters.unsupervised.instance.Normalize-N1.0
Instances: 150
Attributes: 5
sepalwidth
petalwidth
class
Test mode:split 70.0% train, remainder test

Status
Building model on training data...

x 1

Novo Resultado

The screenshot shows the Orange Data Mining interface with the 'Classify' tab selected. The classifier is 'GridSearch' with the following command: `-E ACC -y-property classifier.gamma -y-min -15.0 -y-max 3.0 -y-step 1.0 -y-base 2.0 -y-expression pow(BASE,I) -filter`. The 'Percentage split' is set to 70%.

Classifier output

==== Evaluation on test split ====
==== Summary ====

Correctly Classified Instances	43	95.5556 %
Incorrectly Classified Instances	2	4.4444 %
Gamma statistic	0.9333	
Mean absolute error	0.0296	
Root mean squared error	0.1721	
Relative absolute error	6.6626 %	
Root relative squared error	36.4876 %	
Total Number of Instances	45	

==== Detailed Accuracy By Class ====

	TP Rate	FP Rate	Precision	Recall	F-Measure	RDC Area	Class
	1	0	1	1	1	1	Iris-setosa
	0.875	0	1	0.875	0.933	0.938	Iris-versicolor
	1	0.067	0.882	1	0.938	0.967	Iris-virginica
weighted Avg.	0.956	0.022	0.961	0.956	0.955	0.967	

==== Confusion Matrix ====

a	b	c	← classified as
14	0	0	a = Iris-setosa
0	14	2	b = Iris-versicolor
0	0	15	c = Iris-virginica

A red arrow points from the 'Result list' area on the left towards the 'Detailed Accuracy By Class' table.

Status: OK

Parâmetros

```
Attributes: 5
            sepallength
            sepalwidth
            petallength
            petalwidth
            class
mode:split 70.0% train, remainder test
Classifier model (full training set) ==
```

```
.classifiers.meta.GridSearch:
  filter: weka.filters.AllFilter
  classifier: weka.classifiers.functions.LibSVM -S 0 -K 2 -D 3 -G 0.125 -R 0.0

  property: classifier.cost
  property: classifier.gamma

  evaluation: Accuracy
  evaluation: [15.0, -3.0]
  evaluation: 15.0 (X coordinate), 0.125 (Y coordinate)
```

Detalhe

- Para fazer sucessivos treinos e testes no Weka, com bases aleatórias:
 - Gere por fora bases aleatórias para ele
 - ou
 - Utilize o filtro [Randomize](#), sempre mudando o **seed!!!**

Referências

- Ana Carolina Lorena e André C. P. L. F. de Carvalho. Uma Introdução às Support Vector Machines
- C.J.C. Burges. A tutorial on support vector machines for pattern recognition. Data Mining and Knowledge Discovery, 2(2):955-974, 1998.
<http://citeseer.nj.nec.com/burges98tutorial.html>
- LIBSVM:
<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>