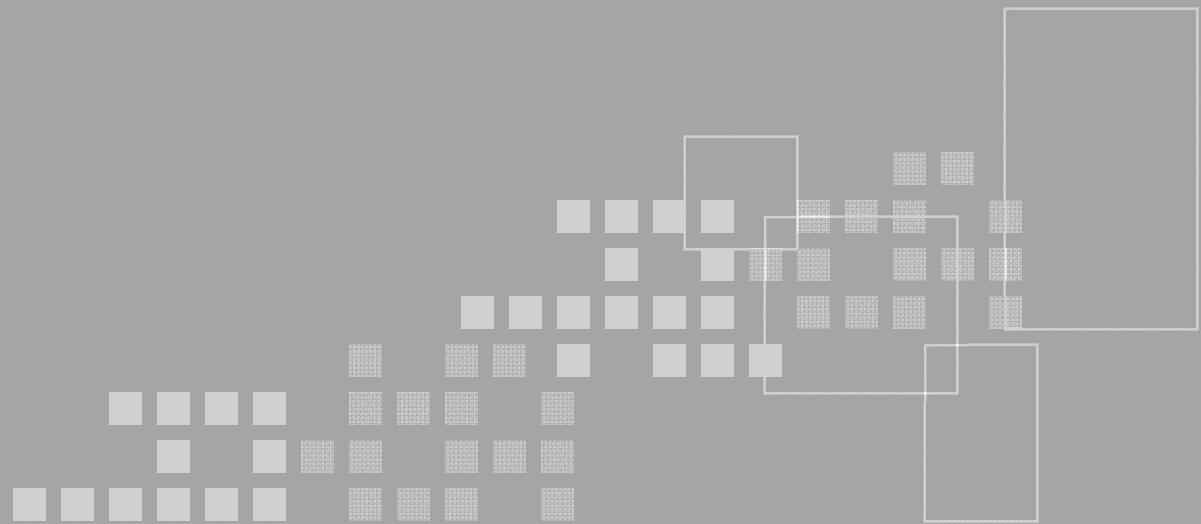
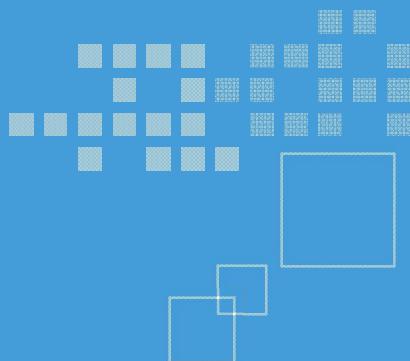


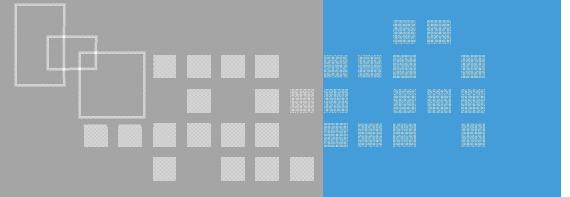
LOGO



教你认识SVM和使用开源工具LibSVM

夏睿 rxia@nlpr.ia.ac.cn





提纲

∨ SVM能解决什么问题？

- § 从机器学习谈起
- § 分类与回归

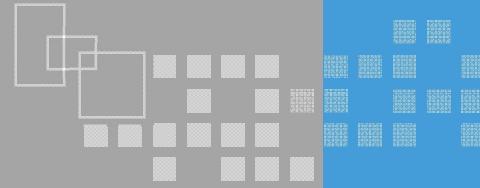
∨ 为什么选择SVM？

- § 从ANN到SVM
- § SVM的两个核心思想
- § SVM算法

∨ 怎么用SVM？

- § 用LibSVM做分类
- § 用LibSVM做回归
- § Python平台下的LibSVM

从机器学习谈起



✓ 目的

根据给定的训练样本，对某系统输入输出之间依赖关系的估计，使它能够对未知输出作出尽可能准确的预测。

✓ 机器学习的三个基本问题

- § 模式识别——分类
- § 函数拟合——回归
- § 概率密度估计

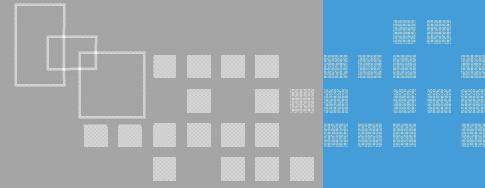
✓ 数学表述

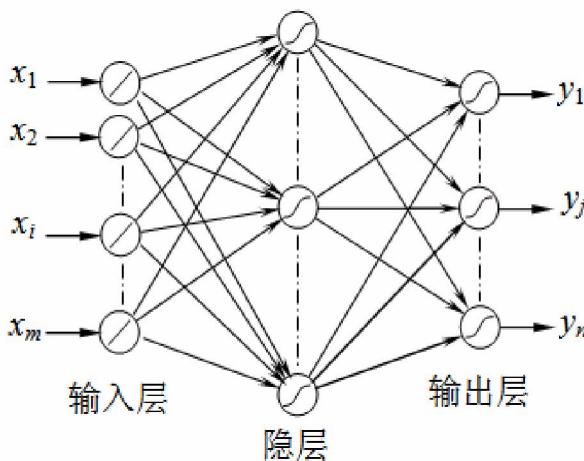
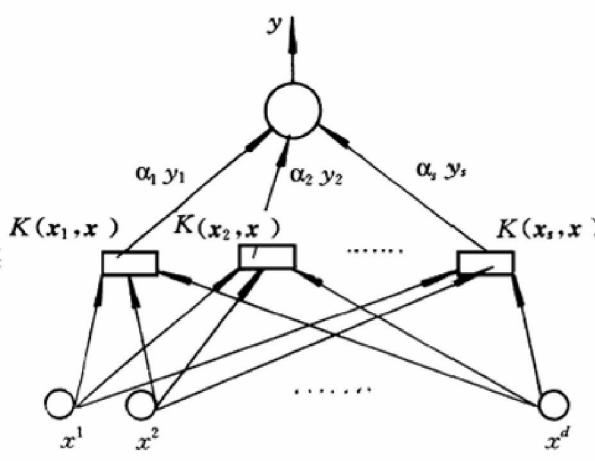
- § 给定条件：n个独立同分布观测样本 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$
- § 目标：求一个最优函数 $f(x, w^*)$
- § 最理想的要求：最小化期望风险 $R(w) = \int L(y, f(x, w))dF(x, y)$

✓ 机器学习方法的代表

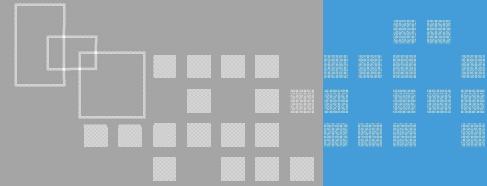
- § 人工神经网络（ANN）& 支持向量机（SVM）

ANN VS SVM



ANN	VS	SVM
	a	
传统统计学	à	统计学习理论
经验风险最小化(ERM)	à	结构风险最小化(SRM)
过学习	à	推广能力的控制 (过人之处1)
训练较慢	à	训练较快
容易陷入局部最小	à	全局最优解
完全的黑匣子，高度非线性，人工难以理解和干预	à	这个黑匣子要透明一点，怎么个透明法？ (过人之处2)

广义最优分类面

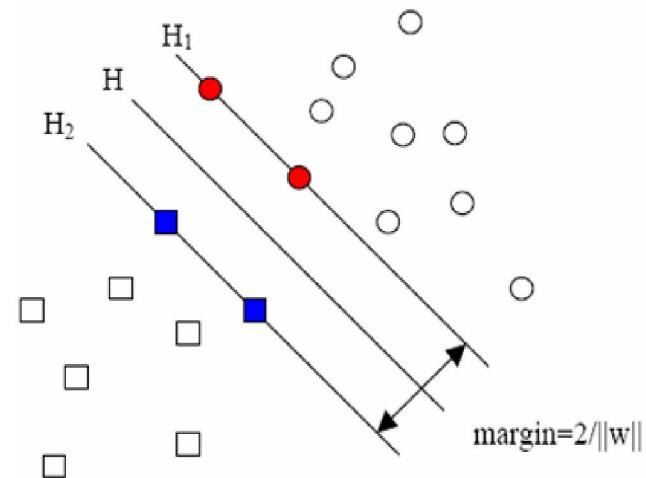


✓ SVM的两点过人之处

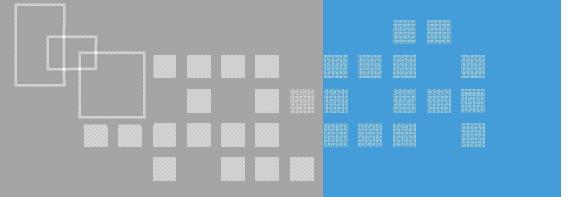
- § 推广能力的控制
——广义最优分类面
- § 处理非线性问题的方式
——核函数

✓ SVM核心思想（一）：广义最优分类面

- § 最优分类面（线）方程 $y = w \cdot x + b$
- § 最大的分类间隔 $\text{margin} = 2 / \|w\|$
使分类间隔最大实际上就是对推广能力的控制
- § SVM得名由来：支持向量是什么？
- § 怎么求解广义最有分类面？—— w^*
这是一个不等式约束下的二次函数寻优问题：
利用Lagrange优化方法将原问题转化为其对偶问题。



求解广义最优分类面



✓ 线性可分下的最优分类面求解

$$\{x_i, y_i\}, i=1, \dots, n, y_i \in \{-1, 1\}, x_i \in R^d$$

$$\min \frac{1}{2} \|w\|^2$$

原始问题

$$s.t. \quad y_i(w \cdot x_i + b) \geq 1 \quad (i=1, 2, \dots, n)$$



对偶问题

$$\min \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^n \alpha_i$$

$$s.t. \quad y_i(w \cdot x_i + b) \geq 1 \quad (i=1, 2, \dots, n)$$

✓ 线性不可分时，加入松弛项，折衷考虑最小错分样本和最大分类间隔

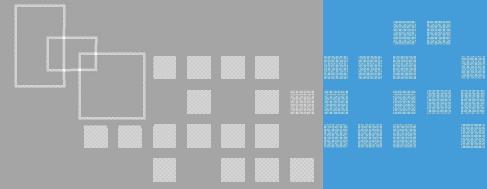
$$\min \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \right)$$

$$s.t. y_i(w \cdot x_i + b) \geq 1 - \xi_i \quad (i=1, 2, \dots, n), \xi_i \geq 0$$

✓ 最优解（广义最优分类面）

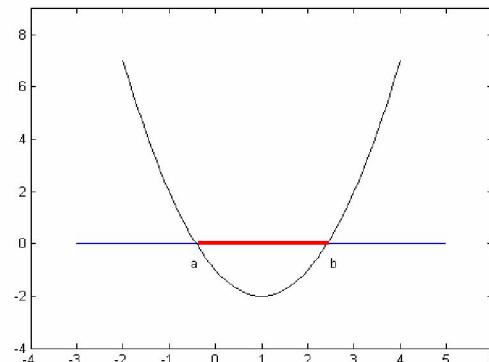
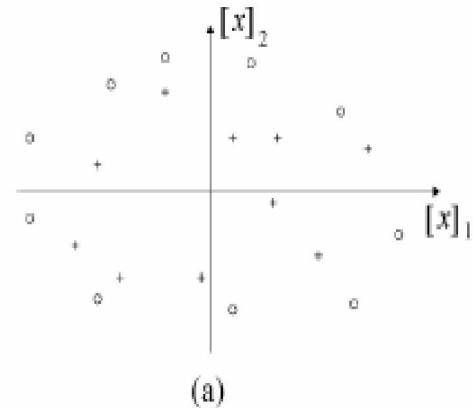
$$f(x) = \text{sgn}\{w^* \cdot x + b^*\} = \text{sgn}\{\sum_{i=1}^n \alpha_i^* y_i (x_i \cdot x) + b^*\}$$

非线性的解决



✓ 解决非线性问题

通过合理的非线性变化，将非线性问题转化为某个高维空间的线性问题。



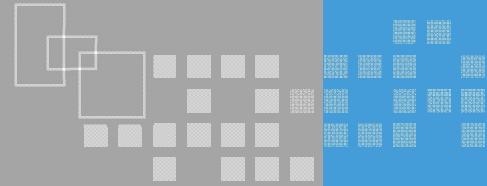
✓ SVM怎么实现低维到高维的变换

§ 从广义最优分类面能得到什么启示？

$$h = \phi(x), g(x) = f(h) = \text{sgn}\{\mathbf{w}^* \cdot h + b^*\} = \text{sgn}\{\sum_{i=1}^n \alpha_i^* y_i (\phi(x_i) \cdot \phi(x)) + b^*\}$$

§ 关键问题：怎么计算 $\phi(x_i) \cdot \phi(x)$

需要知道变换的具体形式吗？灾难维数？NO!



核函数与SVM算法

✓ SVM核心思想（二）：核函数 $(\phi(x_i) \cdot \phi(x_j)) = K(x_i, x_j) = \varphi(x_i \cdot x_j)$

§ 低维内积的函数

§ 对应某一高维变换空间的内积

§ 常用的核函数

Linear	Polynomial	RBF	sigmoid
$K(x_i, x_j) = x_i^T x_j$	$(\gamma x_i^T x_j + r)^d$	$\exp(-\gamma \ x_i - x_j\ ^2)$	$\tanh(\gamma x_i^T x_j + r)$

✓ 非线性问题的SVM算法

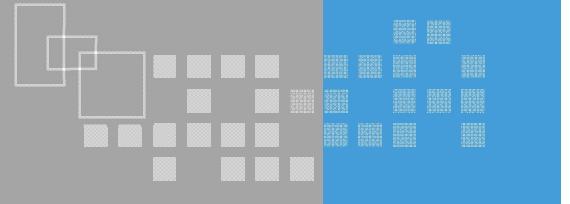
$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j K(x_i, x_j) - \sum_{j=1}^n \alpha_j$$

$$s.t. \quad \sum_{i=1}^n y_i \alpha_i = 0$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, l$$

$$f(x) = \text{sgn}(\sum_{i=1}^l y_i \alpha_i K(x_i, x)) + b^*, b^* = y_j - \sum_{i=1}^l y_i \alpha_i K(x_i, x_j) \quad j \in \{j \mid 0 < \alpha_j^* < C\}$$

SVM开源工具——LibSVM

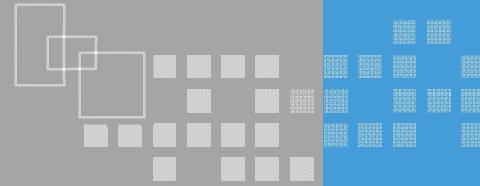


∨ 为什么选择LibSVM (<http://www.csie.ntu.edu.tw/~cjlin/libsvm>)

- § Different SVM formulations
- § Efficient multi-class classification
- § Cross validation for model selection
- § Probability estimates
- § Weighted SVM for unbalanced data
- § Both C++ and Java sources
- § [GUI](#) demonstrating SVM classification and regression
- § [Python](#), [R](#) (also Splus), [MATLAB](#), [Perl](#), [Ruby](#), [Weka](#), [Common LISP](#) and [LabVIEW](#) interfaces. [C# .NET](#) code is available.
- § Automatic model selection which can generate contour of cross validation accuracy.

∨ 使用LibSVM的一些准备工作

- § 平台
 - Win32+python+pnuplot
 - Linux+python+pnuplot
- § 数据
 - Training Set
 - Test Set
- § SVM基础知识



样本文件格式

✓ 文本编码 ASCII/ANSI

✓ 数据存储格式

§ 每行格式 : label feature1:value1 index2:value2 ...

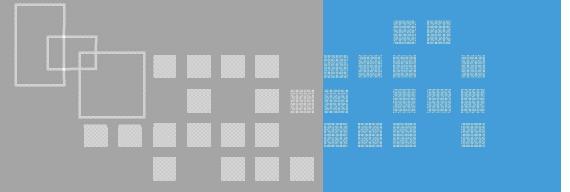
- label为类别标号，feature为特征序号，value为特征的值
- value为0时该项可以省略（大规模数据时节省存储空间）

§ 示例 : iris.tr (UCI / Iris Plant, 4 features, 3 classes)

```
1 1:-0.555556 2:0.5 3:-0.694915 4:-0.75
3 1:-0.166667 2:-0.333333 3:0.38983 4:0.916667
2 1:-0.333333 2:-0.75 3:0.0169491 4:-4.03573e-08
1 1:-0.833333 3:-0.864407 4:-0.916667
1 1:-0.611111 2:0.0833333 3:-0.864407 4:-0.916667
3 1:0.611111 2:0.333333 3:0.728813 4:1
3 1:0.222222 3:0.38983 4:0.583333
2 1:0.222222 2:-0.333333 3:0.220339 4:0.166667
2 1:-0.222222 2:-0.333333 3:0.186441 4:-4.03573e-08
...
```

✓ 格式检验脚本 checkdata.py

```
python checkdata.py iris.tr.txt
```



数据标准化

∨ 为何需要数据标准化?

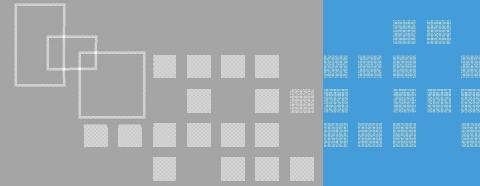
- § 去除量纲
- § 简化运算

∨ 常见的数据标准化方法

极值标准化 (libSVM采 用)	归一化标准化	标准差标准化
$x_{i,j}^* = \frac{x_{i,j} - m_j}{M_j - m_j}$	$x_{i,j}^* = \frac{x_{i,j}}{\sum_i x_{i,j}}$	$x_{i,j}^* = \frac{x_{i,j} - \bar{x}_j}{S_j}$

∨ 一些经验之谈

- § 训练集与测试集一起标准化！
- § 对于新来的测试集，怎么办？
- § 对于回归问题，量纲大的标签也需要标准化，此时预测值需要反标准化



LibSVM数据标准化

✓ svm-scale命令（使用的是极值标准化）

§ 格式：svm-scale [options] filename

options:

- 上下界（默认[-1,1]）：-l lower -u upper
- 存储标准化尺度：-s scalefile
- 加载标准化尺度：-r scalefile
- 标签的标准化（用于回归）：-y lower upper

§ 使用提醒

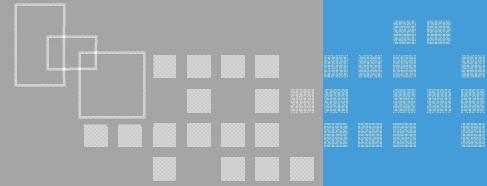
- 训练集和测试集一起scale，将所有数据缩放到[lower, upper]
- 新来的测试样本，应该使用训练时候的标准化尺度进行标准化

§ 示例

```
svm-scale -s iris.scale iris.train
```

```
svm-scale -l -0.8 -u 0.8 -s iris.scale iris.train > iris.train.scaled
```

```
svm-scale -r iris.scale iris.test
```



LibSVM训练 - 1

✓ svm-train 命令

§ 格式 : svm-train [options] filename [modelfile]

options (部分)

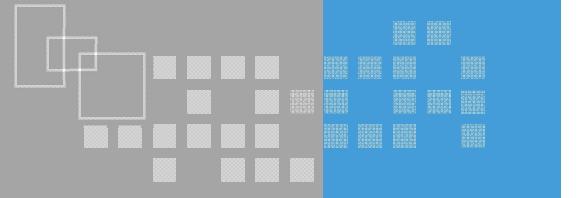
- -s svm_type : set type of SVM

0 (default)	1	2	3	4
C-SVC	one-class SVM	One-class SVM	Epsilon-SVR	Nu-SVR

- -t kernel_type : set type of kernel function

0	1	2(default)	3
linear	polynomial	radial basis function (RBF)	sigmoid

- -v n: n-fold cross validation mode
- -g gamma (γ) : set gamma in kernel function (default 1/k)
- -c cost : set the parameter C of C-SVC, epsilon-SVR, and nu-SVR (default 1)
- -b probabilityestimates: whether to train a SVC or SVR model for probability estimates, 0 or 1 (default 0)
- -m cachesize : set cache memory size in MB (default 100)



LibSVM训练 - 2

∨ 示例

§ 最简单的训练，所有参数均默认

```
svm-train iris.train
```

§ 任务类型默认(C-SVC)、核函数默认(RBF)，10-fold, c=100, g=0.01，保存训练模型

```
svm-train -v 10 iris.train iris.model
```

§ 任务类型默认(C-SVC)，选用线性核函数，10-fold, c=100

```
svm-train -t 0 -v 10 -c 100 -g 0.01 iris.train iris.model
```

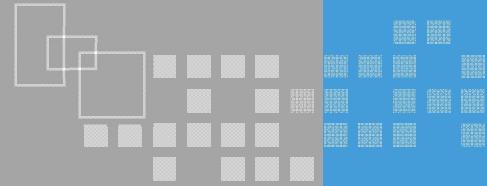
§ 采用概率模型，其余同上

```
svm-train -b 1 -t 0 -v 10 -c 100 -g 0.01 iris.train iris.model
```

∨ 一个重要问题，怎么选择参数？

- § 自动：libSVM提供的寻优脚本
- § 手动：用试的！！

LibSVM训练参数寻优



✓ 参数自动寻优的训练脚本 grid.py (Cross-validation and Grid-search)

§ 适用任务：分类问题 & RBF核(或linear核)

§ 格式：python [options] grid.py trainingfilename

§ options

- -svmtrain pathname
- -gnuplot pathname
- -out pathname
- -png pathname
- -log2c begin,end,step
- -log2g begin,end,step
- additional same options for svm-train

§ 示例

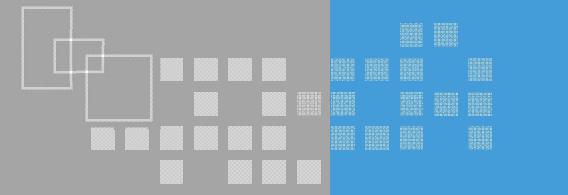
```
python grid.py iris.train
```

```
python grid.py -svmtrain d:\libsvm\svm-train.exe -gnuplot d:\gnuplot\bin\pgnuplot.exe  
-png d:\iris.gird.png -log2c -8,8,2 -log2g 8,-8,-2 -v 10 iris.train
```

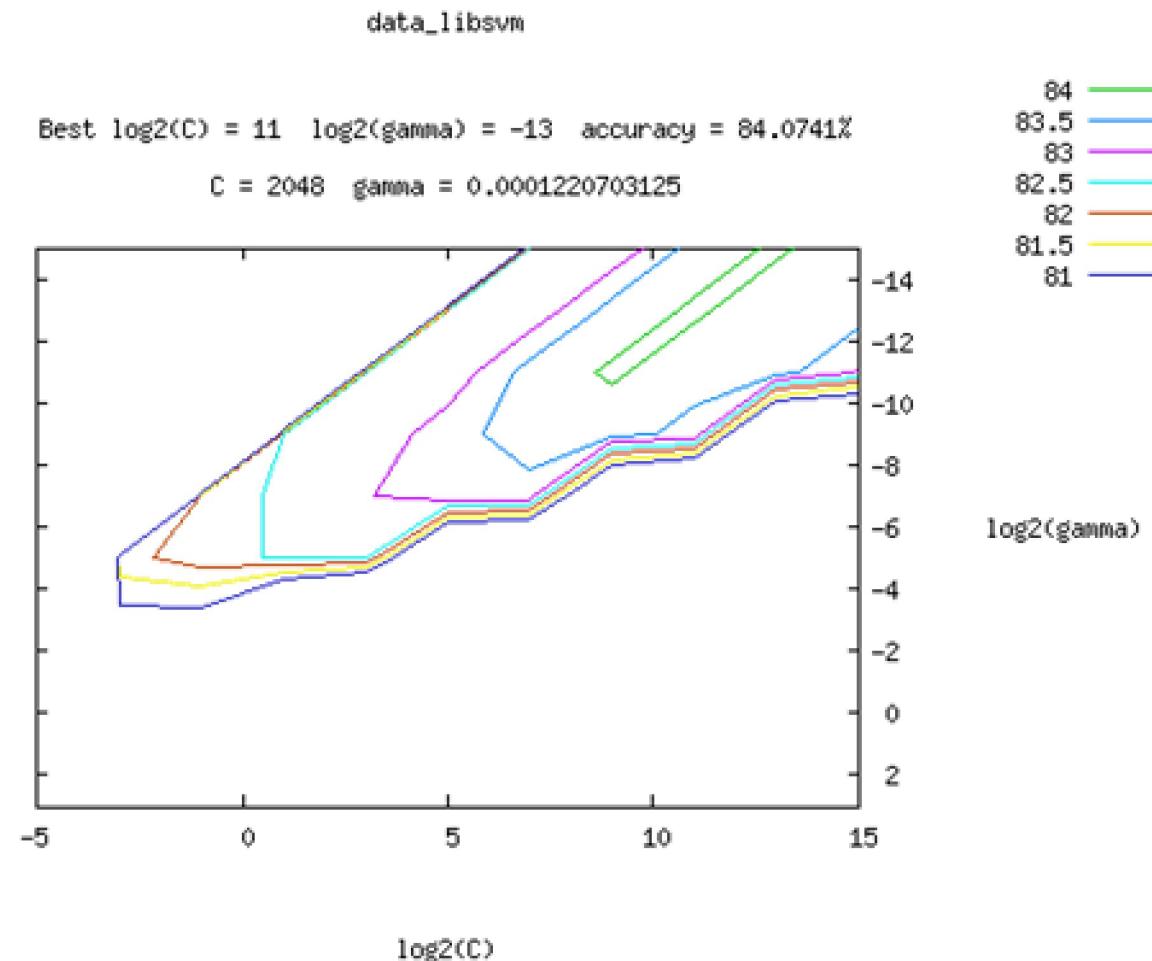
§ linear核怎么使用？——设置一个虚拟的gamma参数: -log2g 1,1,1

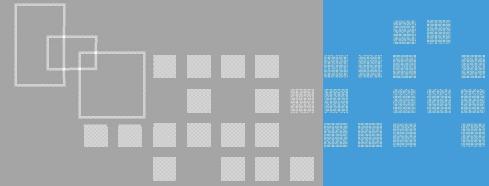
```
python grid.py -log2c -8,8,2 -log2g 1,1,1 -t 0 -v 10 iris.train
```

寻优结果



▽ 参数寻优图示





LibSVM测试

- ✓ 格式 : svm-predict [options] testfile modelfile resultfile
 - options
 - § -b probability : -b 0只输出类别； -b 1输出各类概率
- ✓ 返回结果
 - § 各测试样本的类别（-b 1时为各类后验概率）
 - § 正确率
- ✓ 示例

```
svm-predict iris.test iris.model iris.result
```

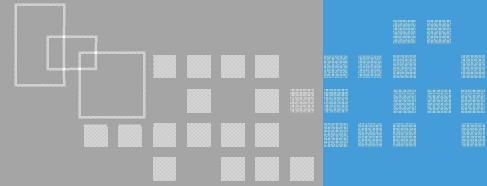
```
svm-predict -b 1 iris.test iris.model iris.result
```

- ✓ 值得注意的
 - § 部分任务不支持概率输出（比如SVR, one-class SVM）
 - § -b参数需要svm-train的时候建立概率模型与之对应

```
svm-train -b 1 iris.train iris.model
```

§ 新来的样本按照训练集标准化的尺度进行标准化

```
svm-scale -r iris.train.scale iris.test > iris.test.scaled
```



怎么用LibSVM做回归？

✓ 数据标准化

- § 对label同时进行标准化（量纲较小的时候可以忽略该步）

```
svm-scale -y -1 1 regression.train.scaled regression.model
```

✓ 参数寻优

- § 脚本：grid.py à gridregression.py
- § 寻优的参数：-c -g à -c -g -p

```
python gridregression.py -log2c -8,8,2 -log2g 8,-8,-2 -log2p -8,8,2 -v 10 regression.train
```

✓ 训练建模

- § 任务的选择：-s 3 (epsilon - SVR)
- § 核函数的选择：通常选择 -t 2 (RBF核，默认) 或-t 0 (linear核)
- § 与分类任务相比，多了一个基本参数p，建模时就用寻优找到的参数

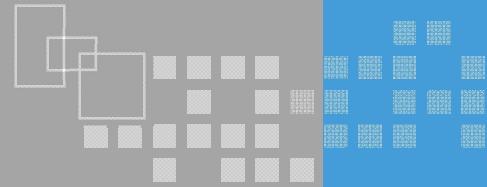
```
svm-train -s 3 -c 100 -g 0.01 -p 0.1 regression.train.scaled regression.model
```

✓ 测试

- § 评估指标：Rate à MSE

```
svm-predict regression.test regression.model regression.result
```

- § 返回值需要经过反标准化，恢复原来的量纲：好像要你自己做了！



Python平台下的libsvm - 1

∨ 安装

- § 将已经编译好的svmc.pyd文件（位于libsvm\windows\python\目录下）拷贝到系统环境变量目录（如python根目录）
- § 将svm.py文件拷贝到当前文件夹
- § 将cross_validation.py拷贝到当前文件夹

∨ 使用

§ 导入模块

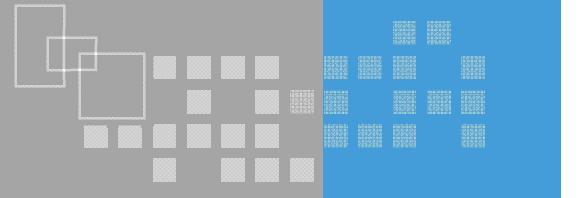
```
from svm import *
```

§ 设置训练参数（包含svm_type, kernel_type, gamma, C...）

```
param = svm_parameter(svm_type = C_SVC, kernel_type = LINEAR)  
param.kernel_type = RBF
```

§ 加载数据

```
ListLabel = [1, -1]  
ListValue = [[1, 0, 1], [-1, 0, -1]]  
# ListValue = [{1:1, 3:1}, {1:-1, 3:-1}]  
prob = svm_problem(ListLabel, ListValue)
```



Python平台下的libsvm - 2

§ 建模

```
mod = svm_model(prob, param)
```

```
target = cross_validation (prob, param, n)
```

§ 模型保存与加载

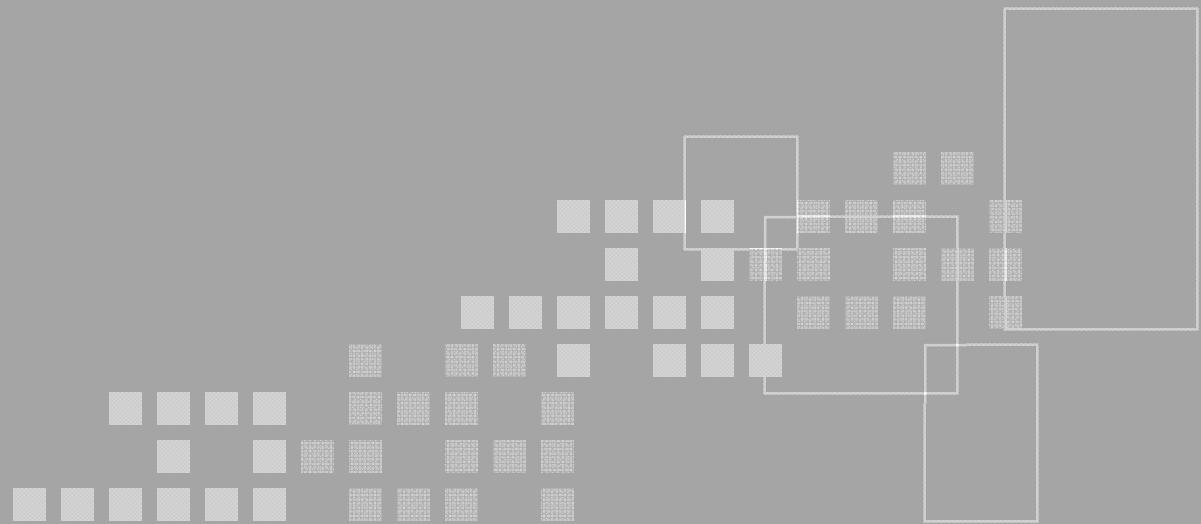
```
mod.save('modelfile')
```

```
mod2 = svm_model('modelfile')
```

§ 测试

```
r = mod.predict ([1, 1, 1])
d = mod.predict_values([1, 1, 1])
prd, prb = m.predict_probability([1, 1, 1])
```

LOGO



Thank you!

Q? / A

