

可保证分类性能的最小二乘支持向量机

徐金宝¹,廖雷¹,业巧林²

XU Jin-bao¹,LIAO Lei¹,YE Qiao-lin²

1.南京工程学院 计算机工程学院,南京 211167

2.南京林业大学 信息技术学院,南京 210037

1.School of Computer Science,Nanjing Institute of Technology,Nanjing 211167,China

2.School of Information Technology,Nanjing Forestry University,Nanjing 210037,China

XU Jin-bao,LIAO Lei,YE Qiao-lin.Least squares support vector machine classifiers with guaranteed classification performance.Computer Engineering and Applications,2009,45(21):48–50.

Abstract: Support Vector Machine (SVM) is one of focuses of research and application in classification. A new least-squares-based algorithm that introduces a within-class scatter with guaranteed classification performance(VSLSVM) in the design of least squares support vector machines(LS-SVM) is presented. This algorithm can obtain better correctness that reformulates primal LS-SVM problems with optimality criterion Min $w'Mw$ where w is the weight vector corresponding the primal LS-SVM problems, M is the within-class scatter matrix. This method only requires to solve a linear system instead of a quadratic programming problem. Experiments are included to compare SVM and Suykens' approach.

Key words: least squares support vector machines(LS-SVM);with-class scatter;better correctness;linear system

摘要:当前支持向量机是分类研究与应用的一个热点。提出了一个新的最小二乘支持向量机算法,该算法向最小二乘支持向量机(LS-SVM)优化模型中融入了类内散度(VSLSVM)思想,即用优化准则 Min $w'Mw$ 对原 LS-SVM 进行重组合, w 为对应 LS-SVM 中的权向量, M 是类内散度矩阵。提出的方法仅仅需要求解一个线性系统而不是凸规划问题,实验主要对 SVM 和 Suykens 等人的方法进行了比较,并验证了提出的算法的有效性。

关键词:最小二乘支持向量机;类内散度;更好精度;线性系统

DOI:10.3778/j.issn.1002-8331.2009.21.012 文章编号:1002-8331(2009)21-0048-03 文献标识码:A 中图分类号:TP181

1 引言

支持向量机(Support Vector Machine—SVM)方法是建立在统计学习理论中的结构风险最小化和 VC 维基础上^[1-2]。在实际问题中,往往原空间中的样本是线性不可分的,解决这种线性不可分的问题,SVM 是通过核映射方法,将原空间中样本映射到高维空间,使得样本在此高维空间中线性分开^[3]。

SVM 以拥有较好的泛化能力而著称,其主要思想是寻找一个能使分类样本尽可能很好地分开的超平面。但是,标准 SVM 主要是通过一个二次规划问题求解的^[4],由于需要大量的迭代次数,从而带来了大量的时间代价,为了改进标准 SVM 的计算时间代价的问题,Mangasarian 等人已经提出了许多快速算法,如 PSVM^[5],LSVM^[6]和 SSVM^[7]。从分类精度角度出发,提出了一个可保证分类性能的 SVM 算法。提出的方法仅仅需要求解一个线性系统而不是凸规划问题,将类内散度的思想融入到最小二乘支持向量机(LS-SVM)中,即用优化准则 Min $w'Mw$ 对原 LS-SVM 进行重组合, w 为对应 LS-SVM 中的权向量, M 是类内散度矩阵。在 UCI 数据库上的计算结果显示,与 SVM 和 Suykens 等人提出的方法相比,提出的方法有更好的分类性能。

2 支持向量机

SVM 的主要思想可以用下面的 QP 问题来表示:

$$\text{Min } \frac{1}{2} w'w \quad (1)$$

subject to $D(Aw - eb) \geq e$

$$\text{式(1)中的 } D = \begin{bmatrix} y_1 & 0 & 0 & \cdots & 0 \\ 0 & y_2 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \cdots & y_n \end{bmatrix}_{m \times n}, y_i \text{ 是第 } i \text{ 个样本的类标,}$$

$A \in R^{m \times n}$ 。但是在大多情况下式(1)由于存在一些不能线性分开的样本点,所以仅仅用式(1)求解是不可行的,这样,可以向式(1)引入一个松弛因子 ξ ,得:

$$\text{subject to } D(Aw - eb) + \xi \geq e \quad (2)$$

$$\xi \geq 0$$

根据式(1)和式(2),可以得到一个最优化问题:

作者简介:徐金宝(1970-),男,讲师,研究方向:Java 新技术与 MIS 研制、数据挖掘;廖雷(1964-),男,副教授,主要研究方向:软件工具、软件自动化;业巧林(1983-),男,硕士,主要研究方向:机器学习、数据挖掘。

收稿日期:2008-12-16 修回日期:2009-05-21

$$\begin{aligned} \text{Min } & \frac{1}{2} \mathbf{w}' \mathbf{w} + C \mathbf{e}' \boldsymbol{\xi} \\ \text{subject to } & \mathbf{D}(\mathbf{A}\mathbf{w} - \mathbf{e}\mathbf{b}) + \boldsymbol{\xi} \geq \mathbf{e} \\ & \boldsymbol{\xi} \geq 0 \end{aligned} \quad (3)$$

式(3)中的正常数 C 是惩罚因子。

3 VSL SVM 算法

为了有效地说明提出的 VSL SVM 算法,首先讨论一下最小二乘 SVM(LS-SVM)^[8]:

$$\begin{aligned} \text{Min}_{(\mathbf{w}, b, \boldsymbol{\xi})} & \frac{1}{2} (\mathbf{w}' \mathbf{w}) + \frac{C}{2} \sum_{i=1}^n \xi_i^2 \\ \text{s.t. } & y_i [\langle \mathbf{w}' \boldsymbol{\varphi}(\mathbf{x}_i) \rangle + b] = 1 - \xi_i, i=1, \dots, n \end{aligned} \quad (4)$$

式(4)中 $\boldsymbol{\varphi}(\cdot)$ 是非线性函数。现在,重点讨论一下最优化问题(4)。为了达到较好的分类性能的目的,对优化问题(式(4))作如下修正:

$$\begin{aligned} \text{Min}_{(\mathbf{w}, b, \boldsymbol{\xi})} & \frac{1}{2} (\mathbf{w}' \mathbf{w}) + \frac{C}{2} \sum_{i=1}^n \xi_i^2 \\ & \sum_{i=1}^{n_1} \mathbf{w}' (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_1^\varphi) (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_1^\varphi)' \mathbf{w} + \\ & \sum_{i=1}^{n_2} \mathbf{w}' (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_2^\varphi) (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_2^\varphi)' \mathbf{w} \\ \text{s.t. } & y_i [\langle \mathbf{w}' \boldsymbol{\varphi}(\mathbf{x}_i) \rangle + b] = 1 - \xi_i, i=1, \dots, n \end{aligned} \quad (5)$$

式(5)中 n_1, n_2 分别为+1 类样本和-1 类样本数目, $\mathbf{m}_1^\varphi = \frac{1}{n_1} \sum_{i=1}^{n_1} \boldsymbol{\varphi}(\mathbf{x}_i) = \frac{1}{n_1} \boldsymbol{\varphi}(\mathbf{x}_1) \mathbf{1}_{n_1}$, $\mathbf{m}_2^\varphi = \frac{1}{n_2} \sum_{i=1}^{n_2} \boldsymbol{\varphi}(\mathbf{x}_i) = \frac{1}{n_2} \boldsymbol{\varphi}(\mathbf{x}_2) \mathbf{1}_{n_2}$ 由 n_i 个 1 组成的列向量,这里 $i=1, 2, n=n_1+n_2$; 优化问题(式(5))可以保证尽可能得到较大间隔的同时,保证了最小的类内散度^[9]。问题(式(5))不易求解,因此做如下组合:

$$\begin{aligned} \text{Min}_{(\mathbf{w}, b, \boldsymbol{\xi})} & \frac{1}{2} (\mathbf{w}' \mathbf{w}) + \frac{C}{2} \sum_{i=1}^n \xi_i^2 + \frac{1}{2} \mathbf{w}' \mathbf{M}^\varphi \mathbf{w} \\ \text{s.t. } & y_i [\langle \mathbf{w}' \boldsymbol{\varphi}(\mathbf{x}_i) \rangle + b] = 1 - \xi_i, i=1, \dots, n \end{aligned} \quad (6)$$

式(6)中 $\mathbf{M} = (\mathbf{M}_1 + \mathbf{M}_2) = \sum_{i=1}^{n_1} (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_1^\varphi) (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_1^\varphi)' + \sum_{i=1}^{n_2} (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_2^\varphi) (\boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{m}_2^\varphi)',$ 在文献[9]中,Mika 等人已经证明了特征空间中的权向量可有训练样本线映射表示:

$$\mathbf{w} = \sum_{i=1}^n a_i \boldsymbol{\varphi}(\mathbf{x}_i) = \boldsymbol{\varphi}(\mathbf{X}) \mathbf{a} \quad (7)$$

式(7)中 $\mathbf{a} = [a_1, a_2, \dots, a_n]',$ 如同文献[3][10],通过替换权向量 \mathbf{w} ,对式(6)进行同样修改,如下:

$$\begin{aligned} \text{Min}_{(\mathbf{w}, b, \boldsymbol{\xi})} & \frac{1}{2} (\mathbf{a}' \mathbf{a}) + \frac{C}{2} \boldsymbol{\xi}^2 + \frac{1}{2} \mathbf{a}' \mathbf{S}^\varphi \mathbf{a} \\ \text{s.t. } & \mathbf{D}(\mathbf{K}\mathbf{a} + \mathbf{e}\mathbf{b}) = \mathbf{e} - \boldsymbol{\xi} \end{aligned} \quad (8)$$

式中 $\mathbf{D} = \begin{bmatrix} y_1 & 0 & 0 & \cdots & 0 \\ 0 & y_2 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & y_n \end{bmatrix}_{m \times m}$, y_i 对应与第 i 个样本的类标, e 是由 n 个 1 组成的列向量, $\mathbf{S}^\varphi = \mathbf{K}_{n \times n_1} [\mathbf{I}_1 - \frac{1}{n_1} \mathbf{1}_1 \mathbf{1}'_1] \mathbf{K}'_1 + \mathbf{K}_2 [\mathbf{I}_2 - \frac{1}{n_2} \mathbf{1}_2 \mathbf{1}'_2] \mathbf{K}'_2$, \mathbf{S}^φ 由下面式子得到:

$$\begin{aligned} \mathbf{w}' \mathbf{M}^\varphi \mathbf{w} &= \sum_{i=1}^2 \mathbf{a}' \boldsymbol{\varphi}(X)' \left(\sum_{j=1}^{n_i} (\boldsymbol{\varphi}(\mathbf{x}_j^i) - \mathbf{e}_i^\varphi) (\boldsymbol{\varphi}(\mathbf{x}_j^i) - \mathbf{e}_i^\varphi)' \right) \boldsymbol{\varphi}(X) \mathbf{a} = \\ & \mathbf{e}_i^\varphi (\boldsymbol{\varphi}(X) \mathbf{a})' \boldsymbol{\varphi}(X) \mathbf{a} = \sum_{i=1}^2 \mathbf{a}' \boldsymbol{\varphi}(X)' (\boldsymbol{\varphi}(X_i) \boldsymbol{\varphi}(X_i)') \boldsymbol{\varphi}(X) \mathbf{a} = \\ & \frac{1}{n_i} \boldsymbol{\varphi}(X_i) \mathbf{1}_{n_i} \mathbf{1}'_{n_i} \boldsymbol{\varphi}(X_i)' \boldsymbol{\varphi}(X) \mathbf{a} = \\ & \sum_{i=1}^2 \mathbf{a}' \boldsymbol{\varphi}(X)' (\boldsymbol{\varphi}(X_i) [\mathbf{I}_{n_i} - \frac{1}{n_i} \mathbf{1}_{n_i} \mathbf{1}'_{n_i}] \boldsymbol{\varphi}(X_i)') \boldsymbol{\varphi}(X) \mathbf{a} = \\ & \mathbf{a}' (\mathbf{K}_{n \times n_1} [\mathbf{I}_1 - \frac{1}{n_1} \mathbf{1}_1 \mathbf{1}'_1] \mathbf{K}'_1 + \mathbf{K}_2 [\mathbf{I}_2 - \frac{1}{n_2} \mathbf{1}_2 \mathbf{1}'_2] \mathbf{K}'_{n \times n_2}) \mathbf{a} \quad (9) \end{aligned}$$

形成问题(式(8))对应的 Lagrangian 对偶问题:

$$L(\mathbf{a}, \mathbf{b}, \boldsymbol{\xi}, \boldsymbol{\lambda}) = \frac{1}{2} \mathbf{a}' \mathbf{a} + \frac{C}{2} \boldsymbol{\xi}^2 - \frac{1}{2} \mathbf{a}' \mathbf{S}^\varphi \mathbf{a} - \boldsymbol{\lambda} (\mathbf{D}(\mathbf{K}\mathbf{a} + \mathbf{e}\mathbf{b}) - \mathbf{e} + \boldsymbol{\xi}) \quad (10)$$

式(10)中 $\boldsymbol{\lambda}$ 为 Lagrangian 乘子,分别对上式中的变量 $\mathbf{a}, \mathbf{b}, \boldsymbol{\xi}$ 求偏导,并设为 0,于是可以得到如下的 KKT 条件:

$$\begin{aligned} \frac{\partial \mathbf{L}}{\partial \mathbf{a}} = 0 &\Rightarrow (\mathbf{I} + \mathbf{S}^\varphi) \mathbf{a} = \mathbf{DK} \boldsymbol{\lambda} \\ \frac{\partial \mathbf{L}}{\partial \mathbf{b}} = 0 &\Rightarrow -\mathbf{e}' \mathbf{D} \boldsymbol{\lambda} = 0 \\ \frac{\partial \mathbf{L}}{\partial \boldsymbol{\xi}} = 0 &\Rightarrow \boldsymbol{\lambda} = C \boldsymbol{\xi} \\ \frac{\partial \mathbf{L}}{\partial \boldsymbol{\lambda}} = 0 &\Rightarrow \mathbf{D}(\mathbf{K}\mathbf{a} + \mathbf{e}\mathbf{b}) = \mathbf{e} - \boldsymbol{\xi} \end{aligned} \quad (11)$$

式(11)中 \mathbf{I} 是 $n \times n$ 维的单位矩阵,矩阵 $(\mathbf{I} + \mathbf{S}^\varphi)$ 是正定的,因为 \mathbf{S}^φ 是半正定的,并且矩阵 \mathbf{I} 是正定的。对(11)中最后一个等式中的 $\mathbf{a}, \boldsymbol{\xi}$ 进行替换,于是可以得到:

$$\begin{bmatrix} 0 & \mathbf{De}' \\ \mathbf{eD} & \mathbf{H} \end{bmatrix} \cdot \begin{bmatrix} \mathbf{b} \\ \boldsymbol{\lambda} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{e}' \end{bmatrix} \quad (12)$$

式(12)中的 $\mathbf{H} = \mathbf{DK} (\mathbf{I} + \mathbf{S}^\varphi)^{-1} \mathbf{DK} + \mathbf{C}^{-1}$ 。这个矩阵是对称正定的,由于 $\mathbf{DK} (\mathbf{I} + \mathbf{S}^\varphi)^{-1} \mathbf{DK}$ 是对称半正定的,而 \mathbf{C}^{-1} 是正定的,式(12)中的矩阵不是正定的,因此,问题(式(12))不易求解。为了较方便地求解式(12),可以修正式(12),得:

$$\begin{bmatrix} \mathbf{De}' \mathbf{H}^{-1} \mathbf{eD} & 0 \\ 0 & \mathbf{H} \end{bmatrix} \cdot \begin{bmatrix} \mathbf{b} \\ \boldsymbol{\lambda} + \mathbf{H}^{-1} \mathbf{eDb} \end{bmatrix} = \begin{bmatrix} \mathbf{De}' \mathbf{H}^{-1} \mathbf{e}' \\ \mathbf{e}' \end{bmatrix} \quad (13)$$

对于问题(式(13))来说,可以用文献[11–12]中提到的 CG 方法求解。但 CG 存在许多缺陷,如分类性能的不稳定性,由于不适合的终止因子而导致的过长的计算时间^[13–14],为了避免 CG 的缺陷,采用下面方法对 VSL SVM 求解:

VSL SVM 算法:

(1)求解 \mathbf{H} :首先,求解 $(\mathbf{I} + \mathbf{S}^\varphi) \mathbf{x} = \mathbf{DK}$ 中的中间变量 \mathbf{x} ,可以得到 $\mathbf{x} = (\mathbf{I} + \mathbf{S}^\varphi)^{-1} \mathbf{DK} \mathbf{x}$,所以, $\mathbf{H} = \mathbf{DK} \mathbf{x} + \mathbf{C}^{-1}$ 。

(2)从方程 $\mathbf{H}\boldsymbol{\delta} = \mathbf{eD}$ 和 $\mathbf{H}\boldsymbol{\rho} = \mathbf{e}'$ 中分别求解 $\boldsymbol{\delta}, \boldsymbol{\rho}$,即: $\boldsymbol{\delta} = \mathbf{H}^{-1}(\mathbf{eD}), \boldsymbol{\rho} = \mathbf{H}^{-1}(\mathbf{e}')$ 。

(3)计算 $\mathbf{De}' \mathbf{H}^{-1} \mathbf{eD} = \mathbf{De}' \boldsymbol{\delta} / \mathbf{De}' \mathbf{H}^{-1} \mathbf{eD}, \mathbf{b} = \boldsymbol{\delta}' \mathbf{e}' / \mathbf{De}' \mathbf{H}^{-1} \mathbf{eD}, \boldsymbol{\lambda} = \boldsymbol{\rho} - \boldsymbol{\delta} \mathbf{b}$ 。

(4)计算 $\mathbf{a} = (\mathbf{I} + \mathbf{S}^\varphi)^{-1} \mathbf{DK} \boldsymbol{\lambda}$ 。

4 实验结果与分析

为了说明 VSL SVM 算法的有效性,在 UCI 数据库^[15]上进行了实验。Suykens 的方法中的终止因子设置为 0.001,计算机是运行在装有 MATLAB 2008 的 Windows XP 系统上,计算机内

存为512 MB。

表1中显示了高斯核(Gauss)SVM、VSL SVM和Suykens方法的比较结果。在实验中,参数C与核参数 σ 分别是在 $\{10^i | i = -3, -2, \dots, 4\}$ 与 $\{10^i | i = -4, -3, -2, \dots, 4\}$ 范围内调节获得。表1中结果表明,提出的方法有较好的分类性能,且优于SVM和Suykens的方法。例如,在数据集PIDD上VSL SVM得到了76.1的测试精度,而在SVM与Suykens提出的方法上的测试精度分别为68.0和67.8,可以看出VSL SVM分类性能的有效性。

表1 在UCI数据库中的6个数据集上非线性SVM、Suykens方法和VSL SVM的分类精度

数据集	分类精度/ (%)		
	SVM	Suykens' method ^[1]	VSL SVM
Spect(267×45)	55.6	92.0	92.0
WBCD(699×10)	100	100	100
WDBC(569×32)	94.1	75.5	95.5
Yeast(1 484×8)	70.6	69.0	70.1
PIDD(768×8)	68.0	67.8	76.1
BSWD(625×4)	96.3	63.4	91.6
ISD(2 130×19)	98.9	99.6	99.6
Wine(1 473×9)	83.8	70.0	92.3
Monk2(432×6)	82.0	57.6	82.0
Monk1(432×6)	86.8	52.0	86.8
Pidd(768×8)	68.0	67.9	70.8

注:黑体表示最好性能

5 结论

提出一个简单的分类算法VSL SVM,与标准SVM相比,该方法能得到较好的分类性能,它主要通过求解线性方程组求解,而不是求解凸规划问题。将类内散度的思想融入最小二乘支持向量机(LS-SVM)中,使得在获得最大间隔的同时,保证类内散度最小化。实验结果也验证了VSL SVM的有效性能。

参考文献:

- [1] Vapnik V N.The nature of statistical learning theory[M].New York: Springer-Verlag, 1995.
- [2] Cherkassky V,Mulier F.Learning from data:Concept,theory and method[M].NY:John Wiley&sons, 1997.
- [3] Lee Yuh-Jye,Mangasarian O LSSVM:A smooth support vector machine, Technical Report 99-03[R].Data Mining Institute, Computer Sciences Department, University of Wisconsin, Madison, Wisconsin, September 1999.
- [4] 李国正,王猛,曾华军.支持向量机导论[M].北京:电子工业出版社,2004:96-100.
- [5] Fung G,Mangasarian O L.Proximal support vector machine classifiers[C]//Provost F,Srikant R.Proceedings KDD-2001:Knowledge discovery and data mining.San Francisco,CA, New York: Association for Computing Machinery,2001:77-86.
- [6] Mangasarian O L,Musicant D R.Lagrangian support vector machines, Technical Report 00-06[R].Data Mining Institute, Computer Sciences Department, University of Wisconsin, Madison, Wisconsin, 2001:161-177.
- [7] Shewchuk J R.An introduction to the conjugate gradient method without the agonizing pain, technical report CS-94-125[R].Carnegie Mellon University, Pittsburgh, 1994.
- [8] Suykens J A K, Van Gestel, Brabanter T.D, et al.Least Squares Support Vector Machines[M].Singapore:World Scientific Publishing Co, 2002.
- [9] Mika S,Ratsch G,Weston J,et al.Fisher discriminant analysis with kernels[C]//Hu Y H,Larsen J,Wilson E.Neural Networks for Signal Processing IX,1999:41-48.
- [10] Mangasarian O L.Generalized support vector machines[C]//Smola A,Bartlett P,Scholkopf B.Advances in Large Margin Classifiers. Cambridge, MA:MIT Press, 2000.
- [11] Suykens J A K,Lukas L,Van Dooren P,et al.Least squares support vector machine classifiers:A large scale algorithm[J].Neural Processing Letters, 1999, 9(3):293-300.
- [12] Wei C,Chong J O,Keerthi S.An improved conjugate gradient scheme to the solution of least squares SVM[J].IEEE Transactions on Neural Networks, 2004, 1(11).
- [13] Lee Yuh-Jye,Mangasarian O LSSVM:A smooth support vector machine, Technical Report 99-03[R].Data Mining Institute, Computer Sciences Department, University of Wisconsin, Madison, Wisconsin, 1999-09.
- [14] MATLAB.User's Guide[M/OL].The MathWorks, Inc, 1994-2001. <http://www.mathworks.com>.
- [15] Newman D J,Hettich S,Blake C L.UCI repository of machine learning databases[DB/OL].(1992).<http://www.ics.uci.edu/~mlearn/MLRepository.html>.

(上接43页)

- [8] Papadimitriou S,Kitagawa H,Gibbons P B.LOCI:Fast outlier detection using the local correlation integral[C]//Proceedings of the 19th International Conference on Data Engineering,Bangalore.Los Alamitos:IEEE Computer Society,2003:315-326.
- [9] Sanjay C,Sun Pei.SLOM:A new measure for local spatial outliers[J].

Knowledge and Information Systems, 2006, 9(4):412-429.

- [10] He Z,Xu X,Deng S.Discovering Cluster-based Local outliers[J]. Pattern Recognition Letters, 2003, 24(9-10):1642-1650.
- [11] He Z,Xu X,Huuug J Z,et al.Mining Class outliers:Concepts, algorithms and applications in CRM[J].Experts System with Applications, 2004, 27(4):294-299.