

LS-SVM 稳健设计及正则化性能分析*

宋叶志¹, 胡小工¹, 黄 勇¹, 周旭华¹, 茅永兴², 何 峰^{1,3}, 张 勇¹

(1. 中国科学院上海天文台·上海·200030; 2. 中国卫星海上测控部·江苏江阴·214431;
3. 北京环球信息开发应用中心·北京·100094)

摘 要: LS-SVM(最小二乘支持向量机)把传统的支持向量机求解由二次规划变为求解线性方程组问题,使得在计算效率和算法设计的简单性上都有很大提高。然而,LS-SVM 由于其误差函数是二次函数,对训练样本中的野值比较敏感,采用传统的 LS-SVM 方法,容易歪曲系统,并可能直接导致函数逼近失败。针对这一情况,基于最优化理论及稳健估计思想,提出了 RLS-SVM(稳健 LS-SVM)的设计方法。数值计算表明,在有野值的情况下,RLS-SVM 对函数逼近具有良好的稳健性。另外,分析了正则化因子与核函数的选择对逼近性能的影响,并给出了在不同情况下的一些使用规则。

关键词: 最小二乘支持向量机(LS-SVM);稳健性;正则化;最优化;函数逼近

中图分类号:V556

文献标志码:A

文章编号:1674-5620(2012)06-0080-06

A Robust Design of LS-SVM and Analysis of Regularization Performance

SONG Yezhi¹, HU Xiaogong¹, HUANG Yong¹, ZHOU Xuhua¹,
MAO Yongxing², HE Feng^{1,3}, ZHANG Yong¹

(1. Shanghai Astronomical Observatory, the Chinese Academy of Sciences, Shanghai 200030;
2. China Satellite Maritime Tracking and Control Department, Jiangyin, Jiangsu Province 214431;
3. Beijing Global Information Application and Development Center, Beijing 100094)

Abstract: LS-SVM (Least Square Support Vector Machine) has received much attention in recent years due to its efficient and convenient algorithms that switch training process by solving a set of linear equations rather than a quadratic programming problem. However, LS-SVM regressors are not robust to outliers because of the square error function. A design of Robust LS-SVM (RLS-SVM) is proposed in this paper with a description of the algorithm that provides a solution to the problem. Numerical computation results indicate that RLS-SVM exerts robust performance in presence of outliers in training data. Regularization factors and kernel functions on approximation performance are also analyzed and rules on how to make choices are given.

Keywords: Least Square Support Vector Machine (LS-SVM); robust; regularization; optimization; approximation

0 引 言

在飞行器跟踪数据处理中,很多内容实质表现为函数逼近问题,如目标分类、识别、弹道逼近等。这类问题的通俗表述是:给定来自某种依赖关系的数据集,推断数据之间的函数依赖关系。其研究基础可以追溯到高斯、拉普拉斯等人的工作,而系统分析这些问题始于 20 世纪 20 年代。

处理这类问题的方法大体分为 2 类不同的思维过程:归纳推理与转导推理。

归纳推理试图发现样本的一般性自然规律,进而把其演绎到其他数据上。通常的做法是,约定某种模型,通过样本给出某种最优意义准则下的参数最优估值,进而达到对其他数据逼近目的。归纳推理的理念是由特殊到一般,然后再由一般到特殊。

转导推理则是直接进行从特殊到特殊的推理过

* 收稿日期:2012-09-03;修回日期:2012-09-12;网络出版时间:2012-12-13 09:35:24

网络出版地址:<http://www.cnki.net/kcms/detail/11.4230.TV.20121213.0935.004.html>

基金项目:国家自然科学基金(No. 11073047, No. 11173049);上海市导航实验室开放课题(No. Y224353002);上海市科学技术委员会(No. 06DZ22101)

第一作者简介:宋叶志(1981-),男,硕士,助理研究员,主要从事卫星轨道理论与数据处理研究;E-mail: song.yz@foxmail.com

程,避免推理问题中可能存在不适定的情况^[1-2]。基于这一理念,Vapnik 等人^[1-2]提出了著名的 SVM (支持向量机)理论。这一理论从 20 世纪 90 年代末起成为国际上最重要的统计学习方法。

经典 SVM 方法的求解需要用到二次规划方法,SVM 学习行为随着训练样本数目增加而渐进地线性增长^[3-11]。LS-SVM(最小二乘支持向量机)方法,其数据的训练过程由二次规划转变为解非线性方程组问题。

LS-SVM 方法在工程应用中由于程序设计简单、稳定性好而得到了广泛应用。然而,在系统噪声为高斯分布的情况下,LS-SVM 学习效果较为理想;若噪声不服从高斯分布,LS-SVM 学习性能则不佳,尤其对野值非常敏感,此时用 LS-SVM 对函数逼近很容易歪曲系统的真实情况。

Huber 从 20 世纪 60 年代开始对参数统计的稳健方法(Robust 亦有译为抗差估计、鲁棒估计等)展开研究,并给出了可行的方法。近二三十年来,我国测绘、数学等领域的学者也在这一领域进行了一系列深入研究,其研究成果已经广泛应用于航天器轨道确定、空间大地测量等领域^[12]。

本文借鉴了稳健估计的一些思想,并结合最优化理论中的正则化方法,给出了在含有野值情况下的 LS-SVM 设计方法,下称为 RLS-SVM(稳健最小二乘支持向量机)。

这里的稳健设计与普通的稳健估计有根本的区别,在普通的稳健估计中,当数据评估时如果数据质量较差,则在下一次迭代时对该数据降权。

在 LS-SVM 方法构造中,其代价函数是最小二乘方,但要求解的方程是适定方程。在该情况下,如果有数据存在野值且被剔除,则系统变为欠定方程,存在无穷多解。即便不设置阈值,若把数据权降得很低,则方程接近奇异,无法求解。

针对这一问题,这里从另一个思路出发:若数据评估质量较差,不改变该数据本身的权重,而是降低支持向量在其张成的 Hilbert 空间坐标的权重。

1 LS-SVM 原理

对于训练样本数据 $(x_i, y_i)(i = 1, \dots, M)$, $x_i \in \mathbb{R}^n, y_i \in \mathbb{R}$, 可以构造如下逼近函数

$$f(x) = \mathbf{w}^T \Phi(x) + b$$

其中 \mathbf{w} 是 l 维权向量; b 是偏置项; $\Phi(x)$ 是 n 维向量 x 到 l 维特征空间的映射函数。最小二乘支持向

量机可以描述为

$$\min J(\mathbf{w}, b, \xi) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{2} \sum_{i=1}^M \xi_i^2$$

$$\text{s. t. } y_i = \mathbf{w}^T \Phi(x_i) + b + \xi_i, \quad i = 1, \dots, M$$

其中 J 为代价函数; C 是正则参数; ξ_i 为 x_i 的松弛变量, $\xi = (\xi_1, \dots, \xi_M)^T$ 。

采用优化理论中的 Lagrange 乘子法,得到增广函数

$$J(\mathbf{w}, b, \xi, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{2} \sum_{i=1}^M \xi_i^2 - \sum_{i=1}^M \alpha_i \left[\mathbf{w}^T \Phi(x_i) + b + \xi_i - y_i \right]$$

其中 $\alpha = (\alpha_1, \dots, \alpha_M)^T$ 为乘子向量。

增广函数对自变量求导得

$$\begin{cases} \mathbf{w} = \sum_{i=1}^M \alpha_i \Phi(x_i), \sum_{i=1}^M \alpha_i = 0 \\ \mathbf{w}^T \Phi(x_i) + b + \xi_i - y_i = 0, i = 1, \dots, M \\ \alpha_i = C \xi_i \end{cases}$$

消除变量 \mathbf{w}, ξ , 得矩阵方程

$$\begin{bmatrix} \Omega & \mathbf{I} \\ \mathbf{I}^T & 0 \end{bmatrix} \begin{bmatrix} \alpha \\ b \end{bmatrix} = \begin{bmatrix} \mathbf{y} \\ 0 \end{bmatrix} \quad (1)$$

其中 $\mathbf{I} = (1, \dots, 1) \in \mathbb{R}^m; \{\Omega_{ij}\} = \Phi^T(x_i) \Phi(x_j) + \frac{\delta_{ij}}{C}; \mathbf{y} = (y_1, \dots, y_M)^T$ 。

核函数即 $K(x_i, x_j) = \Phi^T(x_i) \Phi(x_j)$ 。由此,逼近函数可以表述为

$$f(x) = \sum_{i=1}^M \alpha_i K(x, x_i) + b \quad (2)$$

核函数的选择有多种,常用的如多项式核、径向基函数核等。第 3 节将给出无穷多节点样条核和高斯核函数构造方法。

2 LS-SVM 的稳健设计

对于样本数据,令等价权及等价权矩阵分别为

$$\bar{p}_i = p_i \omega_i = p_i \frac{\psi(v_i)}{v_i}$$

$$\bar{\mathbf{P}} = \text{diag}(\bar{p}_1, \bar{p}_2, \dots, \bar{p}_M)$$

其中 $\omega_i, \psi(v_i)$ 为标准等价权和等价权函数; v_i 为标准化的残差。这里取

$$\psi(v) = \begin{cases} v, & |v| \leq k_0 \\ k_0 \text{sign}(v), & k_0 < |v| \leq k_1 \\ v \varepsilon, & |v| > k_1 \end{cases}$$

$$\omega(v) = \begin{cases} 1, & |v| \leq k_0 \\ \frac{k_0}{|v|}, & k_0 < |v| \leq k_1 \\ \epsilon, & |v| > k_1 \end{cases}$$

ϵ 为一个小量,这里取 $\epsilon = 10^{-6}$,注意不能取为 0,否则其倒数在计算时将会出现无穷大,导致计算失败。由此定义增广权矩阵

$$\bar{P} = \text{diag}(\bar{p}_1, \bar{p}_2, \dots, \bar{p}_M, 1)$$

欲使最小二乘支持向量机具有稳健性(即对于不可靠的数据具有抗差性),与通常的稳健最小二乘类似,这里通过选权迭代来实现。下面给出其算法:

- 1) 设定最大允许迭代次数 I_{\max} , 误差容限 η 。
- 2) 对所有样本数据计算

$$\{\Omega_{ij}\} = \Phi^T(x_i)\Phi(x_j)$$

并构造出方程 (1) 的所有系数。计算出 $\theta_1 = [\alpha^T, b_1]^T$ 。

- 3) 设置 $k := 1$, 对 4)~8) 做循环。
- 4) 对于样本数据根据式 (2) 反算样本理论值, 并计算残差。
- 5) 由残差得到等价权矩阵 \bar{P} 。
- 6) 对 $i = 1, \dots, M$

$$\Omega_{ii} := \Omega_{ii} + \frac{1}{C \times \omega_i}$$

- 7) 计算出 $\theta_2 := [\alpha_2^T, b_2]^T$, 如果 $\|\theta_2 - \theta_1\| \leq \eta$ 或者 $k > I_{\max}$, 则退出循环。
- 8) 令 $k := k + 1, \theta_2 := \theta_1$ 。
- 9) 结束。

在该算法中,方程为适定方程且对称正定。可以采用改进的 Cholesky 分解方法,也可以根据其他抗差方法构造类似的稳健设计算法,其他抗差方法可以参考文献[13-14]。

3 实函数估计核的构造

本文采用无限节点样条核与径向基高斯核 2 种典型的核函数进行了数值实验。

对于区间 $(0, a)$ 上的函数,可以用包含无限节点的 d 阶样条逼近

$$f(x) = \sum_{i=0}^d a_i x^i + \int_0^a a(t)(x-t)_+^d dt$$

其中 $(x-t)_+^d = \begin{cases} 0, & x \leq t \\ (x-t)^d, & x > t \end{cases}$

由此可以构造包含无限节点 d 阶样条的核

$$K(x_j, x_i) = \int_0^a (x_j-t)_+^d (x_i-t)_+^d dt + \sum_{r=0}^d x_i^r x_j^r =$$

$$\sum_{r=0}^d \frac{C_d}{2d-1+1} (x_j \wedge x_i)^{2d-r+1} |x_j - x_i|^r + \sum_{r=0}^d x_i^r x_j^r$$

其中 $(x \wedge x_i) = \min(x, x_i)$ 。

高斯核函数是径向基神经网络与支持向量机理论及工程实践中使用最广泛的核函数之一。一般的径向基函数核形式为

$$K(x, x_i) = K(|x - x_i|)$$

高斯核函数为

$$K(|x - x_i|) = \exp[-\gamma|x - x_i|^2] \quad (3)$$

对比正态分布密度函数,很容易理解 γ 为核的控制半径相关的参数。

4 数值实验

4.1 滤波稳健性分析

在文献[1-3]中,使用了 sinc 函数进行逼近、回归分析。为了对比,这里采用了文献[1]中的函数,用最小二乘支持向量机进行函数逼近与估计。

实验函数取 $f(x) = \frac{\sin(x-10)}{x-10} + \epsilon$, 函数定义

在区间 $x \in [0, 20]$ 上, ϵ 为噪声。在实验中,对该函数以步长 0.23 进行采样,得到原始样本数据。为了测试本文中方法的有效性,在其中 3 个元素中分别人为地加入较大的“野值”。试验中,取 $\epsilon \sim N(0, 0.08)$ 。图 1 显示经典 LS-SVM 与 RLS-SVM 的性能比较,图中的野值用菱形标注。可以看到,在系统含有野值的情况下,经典 LS-SVM 估计函数在异常点附近的估值出现了异常,而 RLS-SVM 却对野值表现出良好的自适应性能。

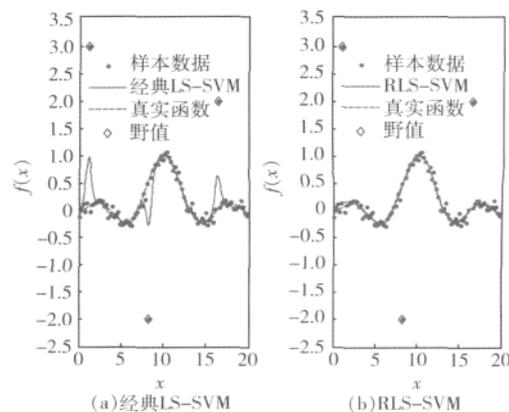


图 1 训练样本中含有野值时 LS-SVM 与 RLS-SVM 学习性能比较

Fig. 1 Comparison of learning performance between LS-SVM and RLS-SVM when training samples contain outliers: (a) classical LS-SVM; (b) robust LS-SVM

为了进一步看清 RLS-SVM 的性能, 图 2 对函数逼近图像进行局部显示, 该图的数据与图 1 同, 仅仅是没有显示野值。

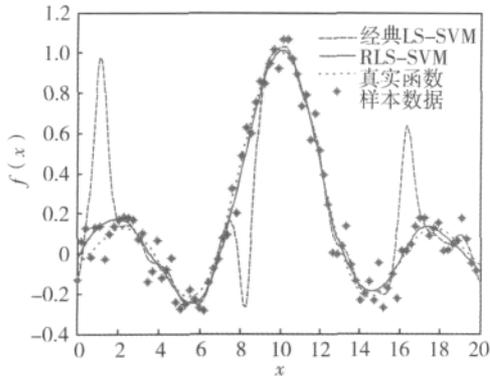


图 2 细节比较

Fig. 2 Details

从图 2 中可以看出, RLS-SVM 几乎与原始的无噪声函数重合。实际上, 当把野值去掉以后, LS-SVM 与 RLS-SVM 二者也几乎重合, 都能非常好地逼近原函数。这说明最小二乘支持向量机具有非常优良的函数逼近能力。然而, 在有野值的情况下, 经典 LS-SVM 与 RLS-SVM 二者的逼近能力有了明显区别。RLS-SVM 以非常明显的优势表现出很强的稳健性。

这里进一步对野值情况下 LS-SVM 函数逼近出现异常的情况进行讨论。从图 1(a) 可以看到, 函数逼近异常主要出现在异常的样本附近, 而正常样本处受影响较小。这是 SVM 函数逼近区别于全局参数化模型的一个特征。在本实验中, 野

值取得并不是特别大, 当野值更大时, LS-SVM 函数逼近异常的范围将扩大, 甚至完全歪曲系统, 而 RLS-SVM 则不会受到野值变得更大的影响。

4.2 噪声水平与正则化性能分析

本文给出的稳健设计之所以有效, 这与泛函的正则化理论密切相关。在这里目标泛函为

$$\min \left[\sum_{i=1}^M \| (f(x_i) - y_i)^2 \|, \| \Theta \odot \omega \| \right]$$

$$\omega = [\omega_1, \omega_2, \dots, \omega_M]^T$$

其中 $f(x_i)$ 为按照特定的支持向量机理论设计的非参数逼近模型; Θ 为支持向量张成基的坐标; ω_i 为各个支持向量的权重, 这个权重随着每次对系统作评估不断变化; \odot 表示矩阵的 Hadamard 积。

如果数据没有误差, 那么普通的支持向量机(包括最小二乘支持向量机)会对函数逼近表现出非常优良的性能。而在数据有误差的情况下, 经典的 LS-SVM 最基本的出发点与普通的最小二乘参数估计一样, 是让残差平方和最小。

野值的存在, 将使采用这一目标函数作为系统的代价函数变得不合适。从另一角度而言, 也可以认为通过正则化的思想把目标函数一部分重心转移到 $\min(\| \Theta \odot \omega \|)$ 上, 而原始数据的符合程度作为一种约束, 但不是严格约束, 最终约束在参数 C 中得到体现。当 C 过大时, 约束较强; 当 C 过小时, 约束较弱。使用时根据需求在两者间权衡。图 3 给出了不同情况下的比较。

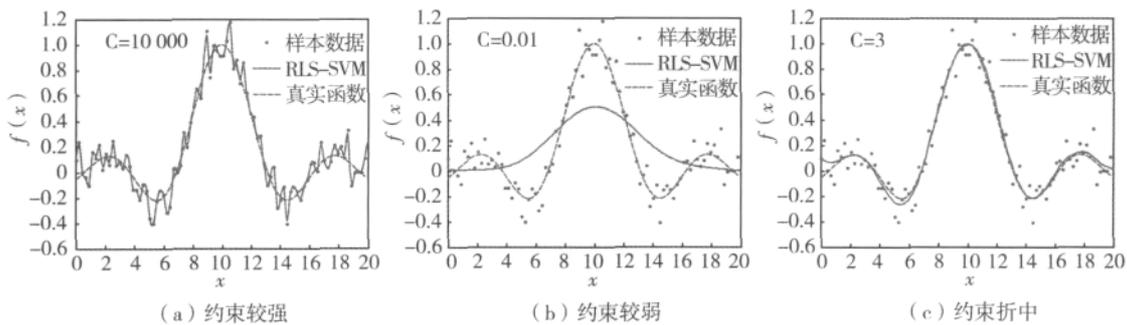


图 3 不同约束情况下的结果比较

Fig. 3 Comparison of results under different constraints: (a) strong constraints; (b) weak constraints; (c) compromised constraints

图 3(a) 为约束较强的情况, 这里 $C = 10\ 000$ 。这种情况下, 代价函数要求尽量满足向量机估计结果等于样本测量值, 因而出现曲线不光滑的现象。图 3(b) 则出现另一种极端, 即对约束要求甚低, 对

应于 $C = 0.01$, 虽然向量机的曲线很光滑, 但显然不是我们想要的结果。图 3(c) 中, C 是一个折中的考虑, 这里 $C = 20$ 。

没有一个绝对的对任何支持向量机都优的准则

选择合适的 C , C 的选择很重要一点是来源于使用者的目的。约束是否较强的另一个因素跟噪声水平有关。如果噪声较大,则可以对约束放宽一些,对应于本文 C 取得大一些。

需要进一步说明的是,这里的 C 仅仅是一个初值,大体反映了噪声水平相当的大部分样本的一个因子。在计算中,真正起作用的是因子向量

$$\left[\frac{1}{C \times \omega_1}, \frac{1}{C \times \omega_2}, \dots, \frac{1}{C \times \omega_M} \right]^T$$

而该因子向量是不断调整的。在普通的 LS-SVM 中, $\omega_i = 1, i = 1, \dots, M$ 。若系统无野值,则 C 在这里的性能与 LS-SVM 的性能是一致的。

4.3 正则化参数与核函数参数之间的耦合与权衡

支持向量机的好处之一是,可以在很大范围内选择合适的核函数以适应函数逼近或者模式识别的需求。

不同的核通常会表现出不同的性态,而核函数参数反映了核的性能。其中一个基本的性能是核对邻域数据的影响能力,这个性能在 2 种情况之间折中,一种情况是对全局函数逼近性能具有大致相当的影响能力,另一种情况是对最临近区域有非常强的影响能力。

这一点与 4.2 节介绍的正则化参数变化引起的逼近性能似乎有点相似,但这本身是 2 个问题,而这两者之间又出现了一定的耦合。

这里以函数 $f(x) = e^{-x} \sin 3x + \epsilon$ 作为测试,其中 ϵ 为噪声, $\epsilon \sim N(0, 0.1)$ 。图 4 给出了高斯核函数 γ 的不同取值函数逼近的性能比较。

在式(3)中 γ 越大,表明影响半径显著趋于越小;反之, γ 越小,影响半径显著趋于越大。图 4(a) 中 $\gamma = 10$, 图 4(c) 中 $\gamma = 0.6$, 可以看到,图 4(a) 中逼近效果对局域数据的依赖性强于图 4(c), 因而出现了锯齿现象,而图 4(c) 则较为光滑。当然,也不是随着 γ 变小,逼近性能就会更优,当 γ 过小时,出现了图 4(b) ($\gamma = 0.1$) 中的现象。当核作用半径过大时候,核对远端的数据影响力相当,造成方程系数矩阵列向量之间出现了相关性,系数矩阵条件数变大,方程接近病态。

因而,在实际应用中,并无通用的准则选择合适的核参数,这主要取决于用户的经验与使用支持向量机的目的。这里给出一个简单但有些粗糙的经验,高斯核函数适合最临近数据类型的逼近,而样条核则较适合更大范围的逼近,前者在噪声较小的情况下较为合适,而后者则在噪声较大时较为合适。

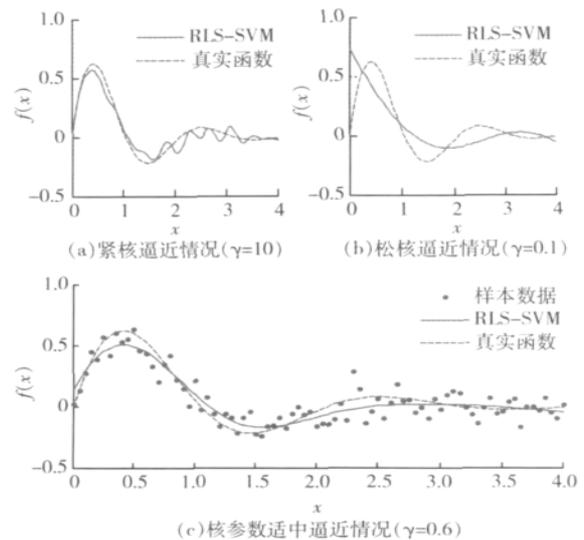


图 4 紧核与松核逼近性能比较

Fig. 4 Approximation performance; (a) compact kernel; (b) slack kernel; (c) proper kernel

5 结 论

1) 依据最优化理论,通过调整正则化泛函因子向量,可以使支持向量机学习方法函数逼近具备良好的稳健性能。对于系统有野值的情况,具备良好的自适应性,而这是经典 LS-SVM 所不具备的。

2) 正则化因子向量在最小二乘支持向量机函数逼近中起非常重要的作用。正则化表现为对样本约束程度的体现,选择合适因子的主要依据包括经验、噪声水平及逼近或分类的需求等因素。通常在噪声方差较大的情况下,应适当放松样本数据对机器学习的约束;当噪声方差较小的时候,可以适当加强样本对机器学习的约束。

3) 理论上,不同核函数的选择通常不会改变支持向量机逼近或模式识别性能。然而,每种核函数都有自己的性态,使用时必须清楚核函数参数调节对代价函数的影响,否则容易导致机器学习失败。一般而言,当样本噪声方差较大时,应该尽量选择对邻域数据影响较宽的核函数,如无限节点样条核;反之应选择对邻域影响较为集中的核函数,如高斯核函数。

本文从最优化原理出发,讨论了最小二乘支持向量机的正则化原理及性能分析,并由此分析了在测量含有野值情况下的稳健设计方法。本文给出的算法简便,容易实施,对影响系统性能的若干细节进

行了深入分析,具一定的理论价值,同时对 LS-SVM 的工程应用也有一定的促进作用。

参考文献(References)

[1] Vapnik V N. Statistical Learning Theory[M]. New York: John Wiley & Sons, Inc, 1998: 194-216

[2] Vapnik V N. The Nature of Statistical Learning Theory[M]. 2nd ed. New York: Springer, 1999: 194-216

[3] 焦李成,周伟达,张莉,等. 智能目标识别与分类[M]. 北京: 科学出版社, 2010: 274-275 (Jiao Licheng, Zhou Weida, Zhang Li, et al. Intelligent Target Identification and Classification[M]. Beijing: Science Press, 2010: 274-275)

[4] 韩崇昭,朱洪艳,段战胜,等. 多源信息融合[M]. 北京: 清华大学出版社, 2006: 108-109 (Han Chongzhao, Zhu Hongyan, Duan Zhansheng, et al. Multi-source Information Fusion [M]. Beijing: Tsinghua University Press, 2006: 108-109)

[5] 史忠植. 神经网络[M]. 北京: 高等教育出版社, 2009: 172-177 (Shi Zhongzhi. Neural Networks[M]. Beijing: Higher Education Press, 2009: 172-177)

[6] Press W H, Teukolsky S A, Vetterling W T, et al. Numerical Recipes [M]. 3rd ed. New York: Cambridge University Press, 2007: 883-898

[7] Hastie T, Tibshirani R, Friedman J. The Elements of Statis-

tical Learning Data Mining, Inference, and Prediction [M]. 2nd ed. New York: Springer, 2008: 417-455

[8] Haykin S. Neural Networks and Learning Machines [M]. 3rd ed. New York: Person Education, Inc. , 2009: 269-312

[9] Theodoridis S, Koutroumbas K. Pattern Recognition [M]. 4th ed. San Diego: Academic Press, 2008: 198-215

[10] Bishop C M. Pattern Recognition and Machine Learning[M]. New York: Springer, 2006: 338-356

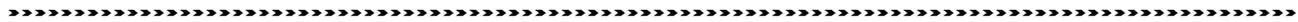
[11] Abe S. Support Vector Machines for Pattern Classification [M]. 2nd ed. New York: Springer, 2010: 432-435

[12] 贾沛璋,吴连大. 初轨的稳健估计算法[J]. 天文学报, 2000, 41(2): 123-128 (Jia Peizhang, Wu Lianda. A Robust Algorithm of the Initial Orbit Determination[J]. Acta Astronomica Sinica;2000,41(2);123-128)

[13] 杨元喜. 抗差估计理论及其应用[M]. 北京: 八一出版社, 1993:13-16,104-111 (Yang Yuanxi. Robust Estimation Theory and Its Application[M]. Beijing: Bayi Press, 1993:13-16,104-111)

[14] 周江文,黄幼才,杨元喜,等. 抗差最小二乘估计[M]. 武汉: 华中理工大学出版社, 1997: 104-167 (Zhou Jiangwen, Huang Youchai, Yang Yuanxi, et al. Robust Least Squares Estimation[M]. Wuhan: Huazhong University of Science and Technology Press, 1997:104-167)

(责任编辑:李 彤)



欧洲完成“数据中继卫星系统”设计工作

欧洲 EDRS(数据中继卫星系统)的设计工作已经完成并通过审批。这标志着该系统获得了首个用户——欧盟的 GMES(全球环境与安全监测)计划(的“哨兵”-1 和“哨兵”-2 卫星)的认可。

EDRS 将提供一个快速、可靠、无缝的通信网络,按需实时从卫星获取信息,这将成为首个商业运营的向对地观测界提供服务的数据中继系统。未来所有配备 EDRS 的地球观测卫星将能更快速地传送数据并且进行更长时间的传送。

该系统由在静地轨道上运行的 2 个有效载荷组成。用户数据经由在较低轨道的卫星的专用信号传输到 EDRS 有效载荷,然后再中继回地面。只要有 1 颗用户卫星处在 EDRS 网络覆盖范围内,就能实现即时宽带数据传输。

首个 EDRS 有效载荷(包括 1 个激光通信终端和 1 个 Ka 频道星间链路)将随阿斯特里姆公司的 Eutel-sat-EB9B 卫星于 2014 年发射升空。德国 TESAT 公司研制的激光终端能在较低轨道的卫星与静地轨道的 EDRS 间以 1.8Gbit/s 的速度传输数据,传输距离超过了 40 000 km。

第 2 个 EDRS 有效载荷预计 2016 年搭乘德国 OHB 公司建造的专用卫星发射升空。