

遥感图像分类的多核 SVDD 算法

陈赛英, 何建农

(福州大学 数学与计算机科学学院, 福建 福州 350108)

摘要: 将 K 型核函数和指数径向基核函数分别与径向基核函数组合成多核函数, 并利用其构造出性能更加优越的支持向量域描述(SVDD)算法. 将提取的遥感图像各波段光谱特征组成特征向量, 分别用基于径向基核函数和多核函数的 SVDD 算法进行遥感图像分类. 仿真实验结果表明:改进核函数的 SVDD 分类算法提高了分类精度, 缩短了训练时间.

关键词: 遥感图像; 分类; 支持向量域描述; K 型核函数; 指数径向基核函数

中图分类号: TP 751 **文献标志码:** A

遥感图像分类是模式识别技术在遥感技术领域的一个具体应用, 是对遥感图像信息进行属性的分类, 达到识别图像信息所对应的实际地物, 最后提取所需地物信息的目的. 支持向量域描述(SVDD)算法具有复杂程度低、扩充性强, 以及对训练样本数据规模上要求不高等优点, 已经广泛应用于故障诊断、异常检测、语音识别等多种领域^[1-4]. SVDD 算法的核心部分是核函数的选择, 传统 SVDD 算法通常是以径向基核函数为核函数, 但径向基核函数存在计算量大、泛化性能较弱等缺点^[5]. 基于此, 本文分别将 K 型核函数和指数径向基核函数与径向基核函数组合成多核函数, 构造 SVDD 的改进算法, 并应用于遥感图像分类.

1 SVDD 模型的原理^[6]

SVDD 算法是基于贝叶斯最优决策理论的, 其基本思想是通过非线性变换将数据点映射到高维特征空间, 然后找到包含大部分映射到特征空间数据点的最小超球体(图 1). 令 $\{x_i\} \subset X$ 是数据空间 $X \subset R^n$ 的一个给定训练数据集, 用一个非线性变换 Φ 把 X 映射到某个高维特征空间, 然后找到半径为 R 的最小封闭超球体, 可描述为下列最优化问题, 即

$$\min R^2 + C \sum_j \xi_j,$$
$$\text{s. t. } \|\Phi(x_j) - a\|^2 \leq R^2 + \xi_j, \quad \xi_j \geq 0, \quad j = 1, \dots, N.$$

(1)

式(1)中: $C < 1$ 是惩罚因子, 调节超球体, 控制误差; a 是球心; ξ_j 是松弛变量. 为了解决这个问题, 引进拉格朗日算式

$$L = R^2 - \sum_j (R^2 + \xi_j - \|\Phi(x_j) - a\|^2) \beta_j - \sum_j \xi_j \mu_j + c \sum_j \xi_j.$$

(2)

令 $\partial L / \partial R = 0$ 和 $\partial L / \partial a = 0$, 可分别得到 $\sum_j \beta_j = 1$ 和 $a = \sum_j \beta_j \Phi(x_j)$. 最后将式(1)的问题转化为如下对偶问题, 即

$$\min W = \sum_j K(x_i, x_j) \beta_j - \sum_{i,j} \beta_i \beta_j K(x_i, x_j),$$
$$\text{s. t. } 0 \leq \beta_j \leq C, \quad \sum_j \beta_j = 1, \quad j = 1, \dots, N.$$

(3)




图 1 二维空间最优超球体示意图

Fig. 1 Optimal sphere schematic diagram of two-dimensional space

式(3)中: $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ 是核函数. 只有满足 $0 < \beta_j < C$ 的点在超球体边界, 称为支持向量 (support vectors, SVs). 训练高斯核支持函数是用 $\Phi(x)$ 到球心的平方径向距离来定义的, 有

$$f(X) := R^2(x) = \|\Phi(x) - a\|^2 = K(x, x) - 2 \sum_j \beta_j K(x_j, x) + \sum_{i,j} \beta_i \beta_j K(x_i, x_j). \quad (4)$$

式(4)中: $\{x : f(x) = R^2\}$ 为支持向量.

2 核函数

2.1 K 型核函数

K 型核函数具有泛化能力强的优点, 避免了径向基核函数复杂的指数运算, 同时具有多项式核函数计算量少和径向基核函数逼近精度高的优点, 性能更加优越^[7]. K 型核函数的公式为

$$K_K(x, y) = \prod_{i=1}^n \frac{1}{1 + k^2(x_i - y_i)^2}. \quad (5)$$

式(5)中: $x = (x_1, \dots, x_n)'$; $y = (y_1, \dots, y_n)'$; $k > 0$ 反映 K 型核函数的宽度.

2.2 指数径向基核函数

径向基核函数具有的优势, 指数径向基核函数也具有, 同时还具有计算量比径向基核函数少的特点. 指数径向基核函数^[8-9]的公式为

$$K_E(x, y) = \exp\left(-\frac{\|x - y\|}{2\sigma^2}\right). \quad (6)$$

式(6)中: σ 是核函数参数.

2.3 多核函数

为了权衡各种特征向量的差异, 在单核函数的基础上, 综合考虑引入多核函数. 多核函数 1, 多核函数 2 的公式分别为

$$\begin{cases} K_1 = \alpha_1 K_R + (1 - \alpha_1) K_K, \\ K_2 = \alpha_2 K_R + (1 - \alpha_2) K_E. \end{cases} \quad (7)$$

式(7)中: $\alpha_1, \alpha_2 \in [0, 1]$ 是多核函数参数; $K_R(x, y) = \exp\left(-\frac{\|x - y\|}{2\sigma^2}\right)$ 是径向基核函数.

由文献[10]可知, 上述多核函数是合理的核函数. 径向基核函数、K 型核函数和指数径向基核函数具有各自的优势, 将径向基核函数分别与 K 型核函数、指数径向基核函数组合得到多核函数可以将两者的优势互补. 利用多核函数, 可以构造出性能更加优越的 SVDD 算法.

3 基于核函数改进的 SVDD 分类算法

算法的基本思想是, 利用光谱特征组合的特征向量, 采用基于多核函数 1 和多核函数 2 的 SVDD 改进算法对遥感图像进行分类. 分类的实现主要分如下 3 个主要阶段: 1) 把训练样本输入 SVDD 进行训练; 2) 用训练好的 SVDD 对测试样本和待分类图像进行分类; 3) 对结果进行评价分析.

算法的实现步骤: 设标记样本集为训练集 $\{(x_i, y_i)\}_{i=1}^N \subset X \times Y$, $x_i \in X$ 表示一个输入模式, $y_i \in Y = \{\omega_1, \dots, \omega_c\}$ 表示对应的输出类. 用 SVDD 算法进行多类分类的中心思想, 是利用由 SVDD 得到的领域描述信息来估计每个类的分布, 然后通过贝叶斯决策规则对数据点分类^[6].

算法的训练阶段有如下 3 个具体步骤.

步骤 1 数据预处理及模型参数初始化. 将提取各波段遥感图像的光谱特征组合成的特征向量作为训练集. 初始化惩罚因子 $C=0.1$, 径向基核函数和指数径向基核函数的参数 $\sigma=3$, K 型核函数的参数 $k=0.001$ 和多核函数参数 $\alpha=0.01$, 分别在 $(0, 1)$, $[3, 25]$, $(0, 1)$ 和 $[0, 1]$ 内取 C, σ, k 和 α , 步长分别为 $0.1, 1, 0.001$ 和 0.01 , 使用网格搜索法^[11]找到最优参数组合使得分类精度最高.

步骤 2 数据分区. 根据输出类把给定的训练集分成 c 个不相交的子集 $\{D_k\}_{k=1}^c$. 例如, 第 k 类数据集 D_k , 包含 N_k 个元素, 即 $D_k = \{(x_{i_1}, \omega_k), \dots, (x_{i_{N_k}}, \omega_k)\}$, 其中 x_i 是第 k 类遥感图像的特征向量, ω_k 是对应的类别标签.

步骤 3 对每类数据集做 SVDD. 对每类数据集 D_k , 通过 SVDD 建立一个训练高斯核支持函数. 具体是解式(3)的对偶问题, 记解为 $\bar{\beta}_{i_l}, l=1, \cdots, N_k, J_k \subset \{1, \cdots, N_k\}$ 是非零 $\bar{\beta}_{i_l}$ 的指标集合. 每类数据集 D_k 的训练高斯核支持函数由下式给出

$$f_k(x) = 1 - 2 \sum_{i_l \in J_k} \bar{\beta}_{i_l} K(x, x_{i_l}) + \sum_{i_l, i_m \in J_k} \bar{\beta}_{i_l} \bar{\beta}_{i_m} K(x_{i_l}, x_{i_m}).$$

(8)

算法的测试阶段有 2 个具体步骤.

步骤 1 为每个类构造伪密度函数. 即为每个类 $k(k=1, \cdots, c)$ 构造伪密度函数 $\hat{p}(x|\omega_k) = \frac{1}{2}(r_k - f_k(x))$. 对任意 $f_k(\cdot)$ 的支持向量 $x_{s_k}, r_k = R^2(x_{s_k})$.

步骤 2 用估计伪后验概率分布函数进行分类. 即对每个类 $k(k=1, \cdots, c)$ 估计伪后验概率分布函数为

$$\delta(\omega_k | x) = \sum_{i=1}^c p(x | \omega_k) p(\omega_k) \hat{p}(\omega_k | x) = \hat{p}(\omega_k) \cdot \hat{p}(x | \omega_k) = \frac{N_k}{N} (-f_k(x) + r_k).$$

(9)

式(9)中: $\hat{p}(x|\omega_k)$ 是从测试阶段的步骤 1 得到的伪密度函数. 最后每个样本 x 按照 $\arg \max_{k=1, \cdots, c} \delta(\omega_k | x)$ 的值进行分类.

4 仿真实验与结果分析

首先对美国 Lanier lake 湖区 Landsat E TM+遥感图像选取波段 3,4,5 组合成多波段图像作为原始的遥感图像(图 2(a)); 然后, 对合成图进行降噪等预处理, 并选择大小为 200 px×200 px 的图像作为待分类图像(图 2(b)), 再次分别提取第 3,4,5 波段遥感图像(图 2(c,d,e))的光谱特征组合成特征向量; 最后用特征向量进行训练和测试分类效果.

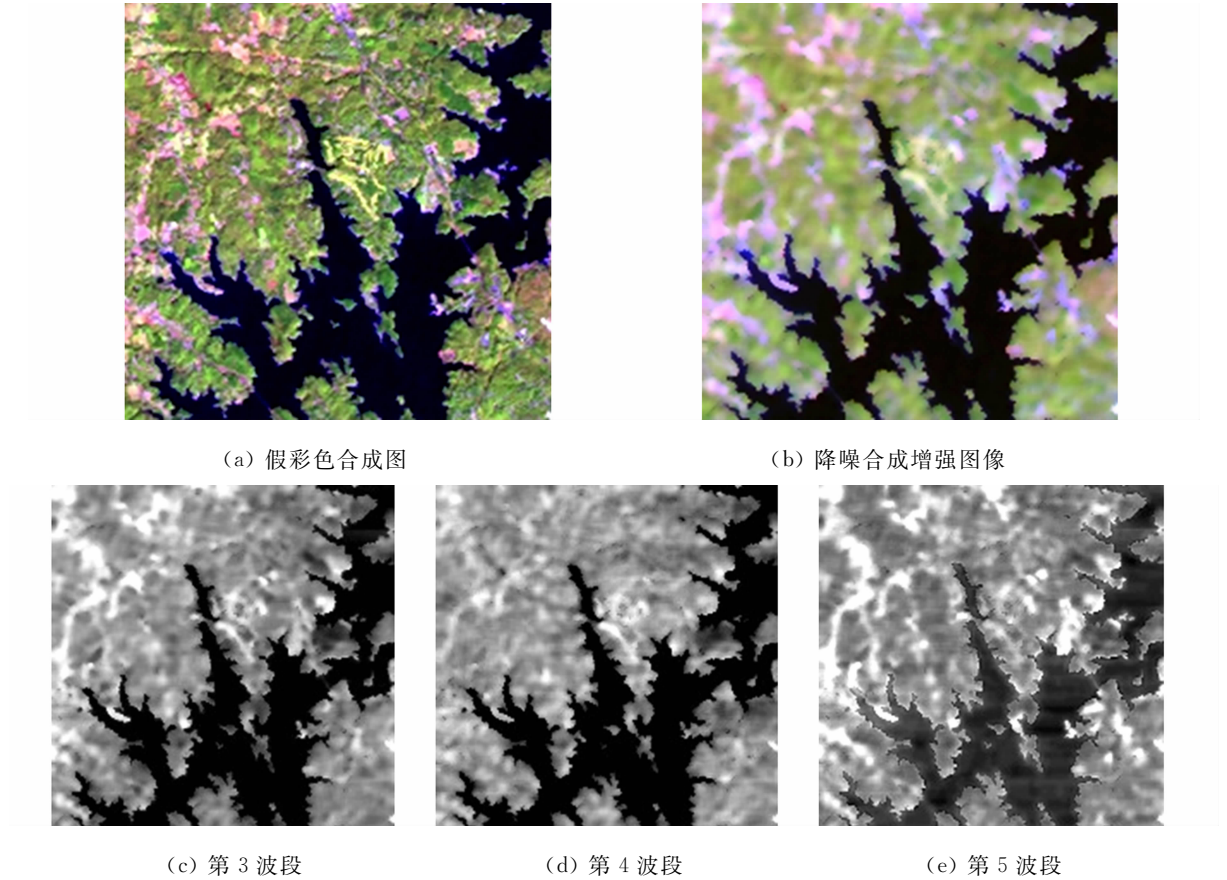


图 2 美国 Lanier lake 湖区遥感图像

Fig. 2 Remote sensing image of American Lanier lake

参照土地利用图, 采用目视解译, 确定该地区地面覆盖类型为水域(W)、草地(G)、落叶林(D)、针叶

林(P)、耕地(A)、居民区(U)和裸地(B). 对以上每类各选取 200 个样本, 并将其中的 100 个样本作为训练样本, 剩余 100 个样本作为测试分类样本.

为了验证算法的有效性, 在环境为 Matlab R2010b, 机器配置为 Pentium(R)Dual-Core cpu T4400 2.20 GHz, 内存为 1.93 GB 的计算机上进行仿真实验. 利用实验得到的训练模型对分类图像进行分类, 结果如图 3 所示.

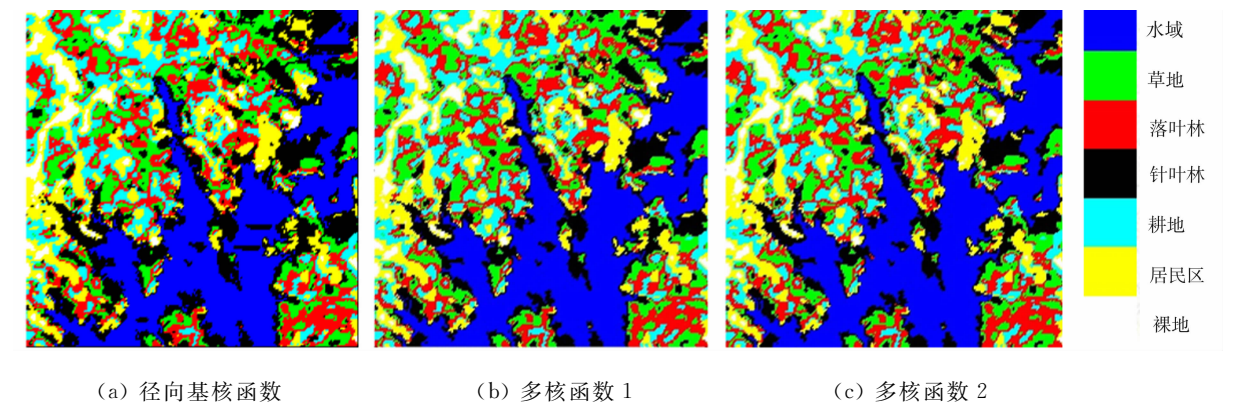


图 3 训练模型对分类图像的分类

Fig. 3 Clasification of training model on image

分类精度(P)是遥感图像中正确分类的百分比, 而 Kappa 系数(K)是用来评价分类精度的多元统计方法^[12], 在遥感图像处理中主要用于精确性评价和图像的一致性判断. 分类精度、Kappa 系数越大, 分类结果越可靠, 其表达式分别为

$$P = \frac{\sum a_{i,i}}{N}, \tag{10}$$

$$K = \frac{N \times \sum a_{i,i} - \sum (T_{i \cdot} \times T_{\cdot i})}{N^2 - \sum (T_{i \cdot} \times T_{\cdot i})}. \tag{11}$$

式(10), (11)中: $a_{i,i}$ 代表分类混淆矩阵 \mathbf{A} 的对角元素; N 为各样本总数; $T_{i \cdot}$ 和 $T_{\cdot i}$ 分别表示 \mathbf{A} 的第 i 行之和以及第 i 列之和.

从待分类图像中 7 类地物的每一类中分别选取 100 个样本点进行仿真, 计算各个样本所属类别, 并将每类样本分类结果数据看作矩阵, 计算分类总精度 (P_{tot}) 及 Kappa 系数. 然后, 将 3 次实验所得的分类混淆矩阵中的总体分类精度, Kappa 系数和训练时间 (t) 作为评价标准, 结果如表 1 所示.

表 1 SVDD 分类算法的遥感图像分类结果

Tab. 1 Remote sensing image clasification results of of SVDD clasification algorithm

算法	$P/\%$							t/s	$P_{\text{tot}}/\%$	K
	水域	草地	落叶林	针叶林	耕地	居民区	裸地			
基于径向基核函数	100.00	74.00	90.00	100.00	95.00	97.00	84.00	5.703 126	91.43	0.900 0
基于多核函数 1	100.00	82.00	92.00	100.00	97.00	99.00	91.00	4.887 402	94.43	0.935 0
基于多核函数 2	100.00	81.00	92.00	100.00	98.00	99.00	91.00	3.713 251	94.43	0.935 0

从表 1 可知: 基于多核函数 1 的 SVDD 算法具有学习能力强、泛化能力强和计算量小的优势; 基于多核函数 2 的 SVDD 算法具有学习能力强和计算量小的优势. 从表 1 还可以看出: 和基于径向基核函数的 SVDD 算法相比, 基于多核函数 1 和多核函数 2 的 SVDD 算法分类精度得到提高, 训练时间也减少了. 其中, 基于多核函数 2 的 SVDD 算法所用时间最短.

5 结束语

文中首次将 K 型核函数和指数径向基核函数应用于 SVDD 算法中, 并将构造的多核函数 SVDD 算法应用于遥感图像分类. 通过对遥感图像的分类, 验证了基于核函数改进的 SVDD 算法缩短了分类过程的训练时间, 提高了分类精度, 具有较强的现实意义.

参考文献：

[1] TAX D M J,DUIN R P W. Support vector data description[J]. Machine Learning,2004,54(1):45-66.

[2] 李卫鹏,李凌均,孔维峰,等. 正交小波变换支持向量数据描述在故障诊断中的应用[J]. 机械科学与技术,2011,30(3):466-470.

[3] 成宝芝,赵春晖,王玉磊. 结合光谱解混的高光谱图像异常目标检测 SVDD 算法[J]. 应用科学学报,2012,30(1):82-88.

[4] 王震宇. 基于支持向量数据描述的说话人识别研究[D]. 杭州:浙江工业大学,2011:13-50.

[5] 汪廷华,赵东岩,张琼. 多类核极化及其在多宽度 RBF 核参数选择中的应用[J]. 北京大学学报:自然科学版,2012,48(5):727-731.

[6] LEE D,LEE J. Domain described support vector classifier for multi-classification problems[J]. Pattern Recognition, 2007,40(1):41-51(doi:10. 1016/j. patcog. 2006. 06. 008).

[7] 孙翠娟. 基于 K 型核函数的支持向量机[J]. 淮海工学院学报:自然科学版,2006,15(2):4-7.

[8] 王春燕,夏乐天,孙毓蔓. 基于不同核函数的 SVM 用于径流预报的比较[J]. 人民黄河,2010,32(9):35-36.

[9] LIMA C A M,COELHO A L V,CHAGAS S. Automatic EEG signal classification for epilepsy diagnosis with relevance vector machines[J]Expert Systems with Applications,2009,36(6):10054-10059.

[10] 杜培军,谭琨,夏俊士. 高光谱遥感影像分类与支持向量机应用研究[M]. 北京:科学出版社,2012:117-118.

[11] 王兴玲,李占斌. 基于网格搜索的支持向量机核函数参数的确定[J]. 中国海洋大学学报,2005,35(5):859-862.

[12] LAM K W K,LAU W L,LI Zhi-lin. The effects on image classification using image compression technique[J]. International Archives of Photogrammetry and Remote Sensing,2000,33(B7):744-750.

Multi-Kernel SVDD Algorithm of Remote Sensing Image Classification

CHEN Sai-ying, HE Jian-nong

(College of Mathematics and Computer Science, Fuzhou University, Fuzhou 350108, China)

Abstract: Combine K-type kernel function and exponential radial basis kernel function with radial basis kernel function into multi-kernel functions respectively, which is used to construct support vector domain description (SVDD) with more superior performance. Each band spectral characteristics of remote sensing image are extracted to compose feature vector, which is used for remote sensing image classification with support vector domain description algorithm. The simulation experiments show that SVDD recognition algorithm of improved kernel function has higher classification accuracy and shorter training time.

Keywords: remote sensing image; classification; support vectors domain description; K-type kernel function; exponential radial basis kernel function

(责任编辑：黄仲一 英文审校：吴逢铁)