

# 基于组合核函数相关向量机的高光谱图像分类

孙 琤<sup>1\*</sup>, 刘东好<sup>2</sup>

<sup>1</sup>中国五洲工程设计集团有限公司, 北京

<sup>2</sup>中兵勘察设计研究院有限公司, 北京

收稿日期: 2023年6月15日; 录用日期: 2023年7月13日; 发布日期: 2023年7月21日

## 摘 要

本文提出了一种基于组合核函数相关向量机的高光谱图像分类方法。基于核函数的特性构造出三种形式的组合核函数。使用多尺度数学形态学方法从主成分变换后的图像上提取空间特征, 通过组合核函数融合图像的光谱特征与空间特征, 采用组合核函数相关向量机进行分类。使用AVIRIS高光谱图像对算法进行了验证。实验结果表明, 与传统的基于光谱特征的相关向量机分类器相比, 组合核函数相关向量机方法的总体精度和Kappa系数均有明显提升。同时, 组合核函数相关向量机能够用较少的训练样本获得较高的分类精度, 在高光谱图像分类中具有实用价值。

## 关键词

图像分类, 相关向量机, 组合核函数, 多尺度形态学特征, 高光谱图像

# Hyperspectral Image Classification Based on Composite Kernel Relevance Vector Machine

Cheng Sun<sup>1\*</sup>, Donghao Liu<sup>2</sup>

<sup>1</sup>China Wuzhou Engineering Group Corporation Ltd., Beijing

<sup>2</sup>China Ordnance Industry Survey and Geotechnical Institute Co., Ltd., Beijing

Received: Jun. 15<sup>th</sup>, 2023; accepted: Jul. 13<sup>th</sup>, 2023; published: Jul. 21<sup>st</sup>, 2023

## Abstract

This paper presents a composite kernel Relevance Vector Machine (RVM) algorithm for hyperspectral image classification. This paper constructs three forms of composite kernels based on the properties of kernels. The spatial feature is extracted using multi-scale morphological method

\*第一作者。

from the image after principal components transform. The final classification is achieved by our composite kernel RVM algorithm. The proposed approach is tested in experiments on AVIRIS data. Compared with spectral kernel RVM, the overall accuracy and Kappa coefficient of the composite kernel RVM algorithm increased obviously. However, the training time dose not increase. Meanwhile, composite kernel RVM has ability to get high accuracy with relative small raining set. The proposed method has practical use in hyperspectral imagery classification.

## Keywords

Image Classification, Relevance Vector Machine, Composite Kernel, Multi-Scale Morphological Profiles, Hyperspectral Image

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

高光谱图像具有光谱分辨率高、成像波段多的特点,使其在地物分类、反演、目标识别等方面有着巨大的优势。传统的分类方法在高光谱分类中效果不理想,会出现维数灾难(Hughes)现象,给高光谱图像分类问题带来了挑战[1]。

针对高光谱图像分类的挑战,国内外利用机器学习领域的算法展开了高光谱图像分类的研究,例如:支撑向量机(SVM) [2] [3] [4] [5]、粒子群算法[6]、人工免疫算法[7]等。其中,支撑向量机方法因核函数的计算不受训练样本维数的影响,并且分类精度较高,在高光谱图像分类中具有一定优势[2]。然而该算法也存在局限性:如支持向量的数量随着训练样本的增长而增加,导致计算时间长;模型参数较多,计算复杂;无法得到概率预测;核函数有一定限制,必须满足 Mercer 条件等[8]。文献[8] [9]提出了基于卷积神经网络的高光谱图像分类算法,但是上述算法都是基于光谱特征实现的图像分类。文献[10]提出融合图像的邻域信息进行非监督分类,用高分辨率城市遥感影像进行了实验,提高了非监督分类的精度;Benediktsson 等利用形态学方法提取图像的空间信息,采用神经网络方法进行分类,并且针对城市高光谱图像进行了实验,取得了良好的效果[11] [12]。文献[13]将图像的光谱特征和空间特征叠加,采用 SVM 方法分类,提高了该方法的分类精度。

RVM 是一种基于稀疏贝叶斯理论的算法[14]。RVM 算法具有如下优势:相关向量的数量小,核函数的选择无需满足 Mercer 条件,能够给出概率预测等。RVM 提出后逐渐应用于目标识别[15]、图像分类 [16]等领域。Demir [17]于 2007 年将 RVM 应用于高光谱遥感影像分类,并与 SVM 方法进行了对比。文献[18]采用 mahalanobis 核函数构造 RVM 分类器,通过高光谱图像分类实验证明了该方法的精度和鲁棒性。文献[19]提出一种改进型相关向量机的高光谱图像分类方法,然而上述 RVM 分类方法都只采用了高光谱图像的光谱特征构造 RVM 分类器。

为提高图像分类精度,本文提出一种组合核函数 RVM 分类方法。根据核函数理论设计了组合核函数,使用多尺度形态学方法提取高光谱图像的空间特征,用组合核函数融合图像的光谱特征和空间特征,训练 RVM 分类器,基于高光谱图像进行了实验,从精度、训练时间等方面将本文方法与已有的基于光谱特征的 RVM 分类方法进行了对比分析和精度评价。实验证明与基于光谱特征的 RVM 分类器相比,本文方法精度更高,并且能以较少的样本取得更高的分类精度。

## 2. 算法原理

### 2.1. RVM 分类模型

RVM 方法假定训练样本集为  $\{x_n, t_n\}_{n=1}^N$ ,  $x_n \in R^d$ ,  $t_n \in R$ , 根据概率论, 假设目标值含有误差  $\varepsilon_n$ , 则目标值  $t_n$  可以表示为[9]:

$$t_n = y(x_n; w) + \varepsilon_n \quad (1)$$

其中, 误差  $\varepsilon_n$  是独立的, 且服从零均值 Gauss 分布, 方差为  $\sigma^2$ , 即  $p(t_n | x) = N(t_n | y(x_n), \sigma^2)$ 。  $y(x_n)$  采用基函数的线性组合来计算, 即:

$$y(x_i; w) = \sum_{i=1}^N [w_i K(x, x_i) + w_0] \quad (2)$$

其中,  $K(x, x_i)$  为核函数,  $w = (w_0, w_1, \dots, w_n)^T$  为权重系数。

假设训练样本独立同分布, 根据 Bernoulli 分布的定义, 训练样本集的似然函数可以表示为:

$$p(t | w, \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{1}{2\sigma^2} \|t - \Phi w\|^2\right\} \quad (3)$$

其中,  $t_n \in \{0, 1\}$  为训练样本标号,  $\Phi = [\varphi(x_1), \varphi(x_2), \dots, \varphi(x_N)]^T$ , 是  $n(n+1)$  维设计矩阵,  $\varphi(x_n) = [1, K(x_n, x_1), K(x_n, x_2), \dots, K(x_n, x_N)]^T$  是定义在训练样本点上的核函数。

RVM 的权值向量  $w_i$  为服从均值为 0 方差为  $\alpha_i^{-1}$  的 Gauss 条件概率分布:

$$p(w | \alpha) = \prod_{i=0}^N N(w_i | 0, \alpha_i^{-1}) \quad (4)$$

其中,  $\alpha = [\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_N]^T$ ,  $\alpha$  是  $N+1$  维超参数向量。

RVM 模型为每一个权值  $w$  定义一个独立的超参数。由于超参数  $\alpha$  的超先验概率分布服从自动相关判定先验分布。在模型迭代计算的过程中, 大部分超参数会趋近于无限大, 其对应的权值  $w$  为 0, 使得 RVM 模型具有很高的稀疏特性。本文使用 Trring 提出的快速边缘似然最大化方法[20]来估计超参数  $\alpha$ 。

RVM 模型最初是用于解决两类分类问题的, 而遥感图像分类属于多类分类问题, 可以通过分解成一系列两类分类问题求解。本文采用一对一法(One Against One, OAO)解决 RVM 多类分类问题。

### 2.2. 组合核函数 RVM

基于核函数的分类器的性能, 核函数的选择起着关键作用[21]。本文根据核函数理论构造组合核函数分类器, 由 Mercer 定理的推论[20]: 设  $k_1$  和  $k_2$  是定义在  $X \times X$  上的核,  $x, x', X \in R$ ,  $a \in R^+$ ,  $f(\cdot)$  是定义在  $X$  上的一个实值函数,  $\phi: X \rightarrow R^N$ , 那么下列函数仍然是核函数:

$$k(x, x') = k_1(x, x') + k_2(x, x') \quad (5)$$

$$k(x, x') = ak_1(x, x') \quad (6)$$

$$k(x, x') = k_1(x, x') \cdot k_2(x, x') \quad (7)$$

根据 Mercer 定理及其性质, 上述三种核函数, 可以作为一种新的核函数来训练分类器[22]。

根据上述理论, 构造了三种组合核函数融合图像的空间特征和光谱特征。定义样本的光谱特征为  $x_i^s$ , 空间特征  $x_i^w$ , 相应的光谱特征与空间特征的核矩阵分别为  $K_s$  和  $K_w$ 。根据核函数的性质, 分别定义两个非线性变换  $\phi_1(\cdot)$  和  $\phi_2(\cdot)$ , 可以分别将样本的光谱特征和空间特征变换到 Hilbert 空间  $H_1$  和  $H_2$  中。本文

分别定义了基于加法和基于乘法的组合核函数来结合图像的光谱特征和空间特征。基于加法运算的组合核函数的数学表达如下:

$$\begin{aligned} K_{sum}(x_i, x_j) &= \{\phi_1(x_i^s), \phi_2(x_i^w)\} \\ &= \langle \{\phi_1(x_i^s), \phi_2(x_i^w)\}, \{\phi_1(x_j^s), \phi_2(x_j^w)\} \rangle \\ &= K_s(x_i^s, x_j^s) + K_w(x_i^w, x_j^w) \end{aligned} \quad (8)$$

在此基础上可以构造基于加权加法的组合核函数, 其数学表达如下:

$$\begin{aligned} K_{weight}(x_i, x_j) &= \{\phi_1(x_i^s), \phi_2(x_i^w)\} \\ &= \mu K_s(x_i^s, x_j^s) + (1 - \mu) K_w(x_i^w, x_j^w) \end{aligned} \quad (9)$$

其中,  $0 \leq \mu \leq 1$ , 它控制着两个核函数的权重。

基于乘法运算的组合核函数:

$$\begin{aligned} K_{product}(x_i, x_j) &= \{\phi_1(x_i^s), \phi_2(x_i^w)\} \\ &= K_s(x_i^s, x_j^s) * K_w(x_i^w, x_j^w) \end{aligned} \quad (10)$$

光谱核  $K_s$  与空间核  $K_w$  的基函数均采用径向基核函数计算。光谱核矩阵的具体计算方法如下:

$$K_s = \exp(-\gamma \|x_i^s - x_j^s\|^2) \quad (11)$$

其中,  $x^s$  为光谱特征向量。

空间核矩阵的计算公式如下:

$$K_w = \exp(-\gamma \|x_i^w - x_j^w\|^2) \quad (12)$$

其中,  $x^w$  为空间特征向量。

相关向量机使用的核函数不必满足 Mercer 条件[9], 本文仍然采用满足 Mercer 条件的核函数来构造组合核函数。常用的核函数包括: 1) 线性核函数  $K(x_i, x_j) = \langle x_i, x_j \rangle$ , 2) 多项式核函数  $K(x_i, x_j) = (\langle x_i, x_j \rangle + 1)^d$  与 3) 径向基核函数  $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ 。其中,  $\gamma$  为径向基核函数参数, 控制着核函数的宽度。本文使用径向基核函数作为 RVM 分类器的基函数。

### 2.3. 基于多尺度形态学的空间特征提取

数据形态学基于结构元素对图像进行腐蚀、膨胀、开启(Opening)和闭合(Closing)运算提取出图像的空间信息。本文采用一系列半径逐渐增大的结构元素作为模板, 对图像重复进行开启和闭合运算, 从而提取出一组特征向量, 称为图像的多尺度形态学特征[22]。

设  $f \ominus B$  和  $f \oplus B$  分别表示对图像做腐蚀运算和膨胀运算。基于膨胀和腐蚀重建运算的定义, 可以得到基于膨胀的开重构运算的表达式为:

$$\gamma_\lambda^* = \delta^{(rec)}(f \ominus B, f) \quad (13)$$

基于腐蚀的闭重构运算的表达式为:

$$\phi_\lambda^* = \varepsilon^{(rec)}(f \oplus B, f) \quad (14)$$

设  $\gamma_\lambda^*(x)$  是开重构算子,  $\Pi\gamma(x)$  是通过开重构运算得到的形态学特征, 则  $\Pi\gamma(x)$  的数学表达式为:

$$\Pi\gamma(x) = \{\Pi\gamma_\lambda : \Pi\gamma_\lambda = \gamma_\lambda^*(x), \forall \lambda \in [0, n]\} \quad (15)$$

设  $\varphi_\lambda^*(x)$  是闭重构运算算子, 由闭重构运算得到的形态学特征  $\Pi\varphi(x)$  的数学表达式为:

$$\Pi\varphi(x) = \{\Pi\varphi_\lambda : \Pi\varphi_\lambda = \varphi_\lambda^*(x), \forall \varphi \in [0, n]\} \quad (16)$$

其中, 根据形态学的定义, 当  $\lambda = 0$  时,  $\Pi\gamma_0(x) = \Pi\varphi_0(x) = I(x)$ 。

经过开重构与闭重构运算之后, 利用相邻两幅形态学特征图像的差值可以得到的图像的多尺度形态学特征, 其数学表达式为:

$$\Delta(x) = \left\{ \Delta_c : \begin{cases} \Delta_c = \Delta\varphi_{\lambda=n-c+1}, \forall c \in [1, n] \\ \Delta_c = \Delta\gamma_{\lambda=c-n}, \forall c \in [n+1, 2n] \end{cases} \right\} \quad (17)$$

其中,  $n$  为开闭运算的次数,  $c = 1, 2, \dots, 2n$ 。

对高光谱图像的每个波段都进行上述多尺度形态学运算, 就得到图像的空间特征向量。

### 3. 实验与结果分析

#### 3.1. 实验数据

本文实验采用 AVIRIS 传感器于 1992 年拍摄的 Indian Pine 地区高光谱图像[23]。该图像大小为  $145 \times 145$ , 共有 220 个波段, 覆盖的波长范围为  $0.4 \sim 2.5 \mu\text{m}$ 。该地区的多种地物光谱较为相似、分类难度大, 是高光谱分类算法性能测试的标准数据。实验之前预先去除该数据的水吸收波段和低信噪比波段, 剩余 169 个波段。该图像共包含 16 种地物类别, 本文的实验采用 9 种典型地物, 共包含 9345 个样本点。样本分布情况如表 1 所示。

**Table 1.** Ground information satatictal form of Indian Pine experimental region

**表 1.** Indian Pine 实验区图像典型地物信息统计表

类别	名称	样本数
C1	玉米地 1	1434
C2	玉米地 2	834
C3	牧草	497
C4	树干	747
C5	干草	489
C6	大豆地 1	968
C7	大豆地 2	2468
C8	大豆地 3	614
C9	树林 1	1294
Total		9345

实验采用的计算机硬件环境为 Intel Core2 双核 CPU, 1.58 GHz/3.25 GB 内存, 软件环境为 Microsoft Windows XP、Matlab R2008a。

实验环节从精度、计算效率方面比较了基于单一特征的 RVM 分类器与组合核函数 RVM 分类器的性能。

### 3.2. 实验过程

通过多尺度形态学运算可以有效地提取图像的空间特征, 但是将导致数据量急剧增大, 因此本文首先使用 PCA 变换(Principal Components Analysis, PCA)对图像进行降维, 得到训练样本集的特征向量  $\{x_k, y_k\}_{k=1}^N$ ,  $x_n \in R^d$ ,  $t_n \in R$ 。其中,  $N$  是训练样本集的样本个数。  $x_k$  表示第  $k$  个样本。  $y_k$  是与样本  $k$  相对应的标签。然后针对主成分图像采用多尺度形态学算法提取图像的空间特征。

如表 2 所示, 实验区图像经过 PCA 变换的前三个主成分的信息量占整个图像的 99% 以上。实验选取 PCA 变换的前 3 个主成分计算图像的多尺度形态学特征。因此本文实验中采用方形结构元素。迭代次数  $n$  设为 5。

**Table 2.** PCA transform result of Indian Pine experimental region image

**表 2.** Indian Pine 实验区图像主成分变换结果

Principal Components	Value	Cumulative Value
$\lambda_1$	70.4312	70.4312
$\lambda_2$	27.3933	97.8246
$\lambda_3$	1.3648	99.1893
$\lambda_4$	0.2905	99.4798

利用主成份分析结果的第一个分量提取出来的多尺度形态学特征如图 1:



**Figure 1.** Multi-scale morphological profile from first principal components of experimental region image

**图 1.** 实验区图像第一分量多尺度形态学特征图

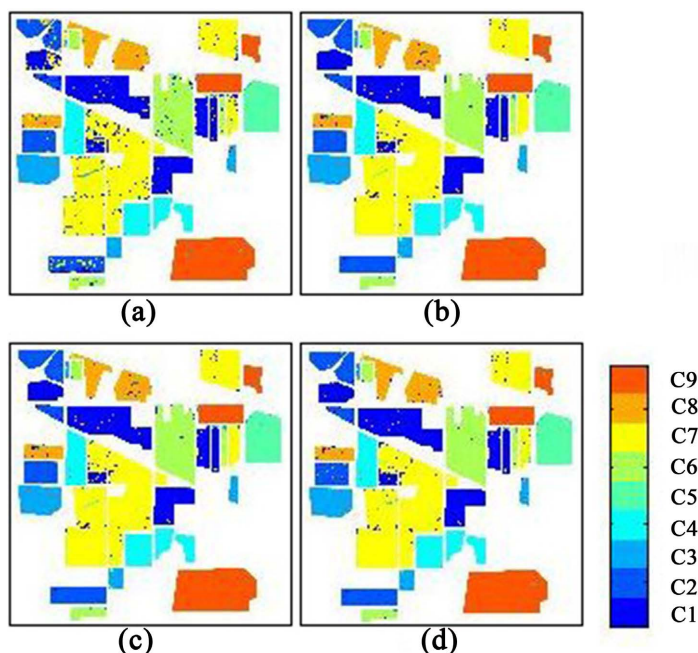
将各类样本按数量随机等分成两部分作为训练样本和测试样本。各类别取 50% 作为训练样本, 剩余的数据作为测试样本。RVM 的核函数参数通过交叉验证的方法获得。本文实验中核函数参数取 1。采用五种组合核函数的分类结果如图 2 所示。图中,  $K_s$  和  $K_w$  分别表示基于光谱特征的核函数和基于空间特征的核函数。  $K_{sum}$  是基于加权加法的组合核函数,  $K_{product}$  是基于乘法的组合核函数,  $K_{weight}$  是基于加权加法的核函数, 其权重取值 0.8。

### 3.3. 分类精度

为了验证本文算法性能, 本文采用总体精度(Overall Accuracy, OA)、Kappa 系数(Kappa Coefficient, KC)、训练时间和基函数数量 4 个指标作为分类器性能的评价标准。

实验区图像基于五种核函数的 RVM 分类器性能比较如表 3 和表 4 所示。表中,  $K_s$  和  $K_w$  分别表示基于光谱特征的核函数和基于空间的特征核函数。其中,  $K_{sum}$  是基于加法的组合核函数,  $K_{product}$  是基于乘法的组合核函数,  $K_{weight}$  是基于加权加法的核函数, 其权重取 0.8。





**Figure 2.** Classification result of four classification methods. (a) Classification result of the spectral kernel,  $K_s$  RVM; (b) Classification result of the summation kernel,  $K_{sum}$  RVM; (c) Classification result of the product kernel,  $K_{product}$  RVM; (d) Classification result of the weighted summation kernel,  $K_{weight}$  RVM

**图 2.** 四种方法的分类结果图。(a) 基于光谱核函数  $K_s$  的 RVM 分类结果; (b) 基于加法核  $K_{sum}$  的组合核函数 RVM 分类结果; (c) 基于乘法核  $K_{product}$  的组合核函数 RVM 分类结果; (d) 基于加权加法  $K_{weight}$  的组合核函数 RVM 分类结果

表 3 和表 4 是每类 50% 作为训练样本 5 种核函数 RVM 分类器的实验结果。从图 2 可以直观地看出, 基于光谱特征的 RVM 分类器针对 C3、C4、C5 和 C9 四类农作物精度较高, 而针对 C1、C2、C6、C7 和 C8 五种农作物误分率略高。结合表 3 可以看出, 三种组合核函数对于几乎所有地物类别的分类精度均有所提升。尤其是对于 C1、C2、C6、C7 和 C8 五种基于光谱特征较难分的农作物, 组合核函数 RVM 的分类精度提升最明显, 说明在 RVM 分类器中引入图像的空间特征能够有效改善分类器的性能。

**Table 3.** Classification accuracy of different methods

**表 3.** 不同方法的分类精度

方法	$K_s$	$K_w$	$K_{sum}$	$K_{product}$	$K_{weight}$
C1	0.8338	0.7283	0.9128	0.9146	0.8987
C2	0.8593	0.8273	0.9485	0.9245	0.9612
C3	0.9183	0.7594	0.9363	0.9134	0.9478
C4	0.9737	0.8799	0.9610	0.9585	0.9487
C5	1.0000	0.9741	1.0000	1.0000	1.0000
C6	0.8917	0.8755	0.9189	0.9198	0.9058
C7	0.8904	0.8665	0.9557	0.9612	0.9556
C8	0.8882	0.952	0.9747	0.942	0.9689
C9	0.9845	0.8813	0.9815	0.9859	0.9861
OA	0.9056	0.8489	0.9508	0.9475	0.9480

结合表 3 可以看出, 基于光谱特征的 RVM 分类器针对 C3、C4、C6、C9 这几个类别分类精度高, 而基于空间特征的 RVM 分类器针对 C5、C8 两个类别的分类精度高。说明图像的光谱特征和空间特征具有一定的互补性, 而本文提出的组合核函数的分类方法综合了光谱特征和空间特征的优势, 利用地物的结构特征丰富了图像分类的有效信息, 因此总体分类精度高于单一特征的 RVM 分类器。

**Table 4.** Classification performance comparison of different methods of experimental region  
**表 4.** 实验区图像基于不同分类方法的性能对比

核函数类型	OA	k	训练时间(s)
spectral kernel, $K_s$	0.9056	0.8892	216.9726
spatial kernel, $K_w$	0.8489	0.8227	279.9581
summation kernel, $K_{sum}$	<b>0.9508</b>	<b>0.9423</b>	219.6292
product kernel, $K_{product}$	0.9475	0.9385	250.3574
weighted summation kernel, $K_{weight}$	0.9480	0.939	<b>203.7916</b>

从表 4 可以得出以下结论:

1) 分类精度方面, 与基于光谱特征的 RVM 相比, 组合核函数 RVM 分类器的总体精度 OA 与 Kappa 系数均有了明显提高。基于乘法核函数的 RVM 分类器的总体精度 OA 与 Kappa 系数分别提高了 4.2%和 5.05%。基于加权加法核函数的 RVM 分类器总体精度 OA 与 Kappa 系数分别提高了 4.24%和 4.78%。基于加法核函数的组合核函数对总体分类精度的提升最明显, 总体精度 OA 与 Kappa 系数较光谱核函数 RVM 分类器分别提高了 4.52%和 5.11%。

2) 效率方面, 与基于单一特征的 RVM 分类器相比, 组合核函数 RVM 分类器的训练时间没有显著增加。其中, 基于乘法核函数的 RVM 训练时间与单一特征的 RVM 相当。基于乘法核的 RVM 分类器的训练时间略高于光谱核 RVM。

### 3.4. 算法稳定性

为了分析本文方法的稳定性, 从训练样本集中随机选取占总样本 20%, 30%, 40%, 50%的样本作为训练样本, 而测试数据集保持原有的样本不变。采用 5 折交叉验证方法确定径向基核函数的参数。表 5 列出了不同数量训练样本下, 基于光谱的 RVM 以及三种组合核函数 RVM 方法的总体精度。表 5 中,  $K_s$  表示基于光谱特征的核函数,  $K_{sum}$  是基于加法的组合核函数,  $K_{sum}$  是基于乘法的组合核函数,  $K_{weight}$  是基于加权加法的核函数, 权重取 0.8。

**Table 5.** Overall accuracy of different methods with different training sample size  
**表 5.** 选取不同数量的训练样本时不同方法分类的总体精度

样本数量	20%	30%	40%	50%
spectral kernel, $K_s$	0.8606	0.8790	0.8981	0.9056
summation kernel, $K_{sum}$	<b>0.9047</b>	0.9268	<b>0.9478</b>	<b>0.9508</b>
product kernel, $K_{product}$	0.8979	0.9264	0.9439	0.9475
weighted summation kernel, $K_{weight}$	0.8985	<b>0.9289</b>	0.9454	0.9480



从表 5 可以看出: 随着训练样本的增加, 三种形式的组合核函数 RVM 方法的分类精度都比单一特征的 RVM 分类器有所提升。尤其是加法核函数 RVM 分类器, 在训练样本数量仅有 20% 时, 仍然能取得较高的分类精度。然而当训练样本占总样本的比例超过 40% 之后, 三种形式的组合核函数 RVM 分类器对分类精度的提升趋于稳定。

#### 4. 结论

本文针对现有的高光图图像分类方法存在的问题, 基于核函数的理论设计了基于乘法、加法和加权加法三种形式的组合核函数 RVM 分类器, 融合光谱特征和空间特征进行分类。通过高光谱图像分类实验表明, 组合核函数 RVM 分类器的性能优于单一特征的 RVM 分类器。与使用单一特征的 RVM 分类器相比, 组合核函数 RVM 分类器的训练时间没有显著增加, 而总体分类精度 OA 和 Kappa 系数均有明显提高, 能获得更高的分类精度。总体来看, 组合核函数 RVM 方法能够用较少的训练样本取得较高的分类精度, 在高光谱图像分类问题中具有实用价值。

对于如何选取 RVM 的核函数以及相应的参数, 可以进一步优化。另外, 本文采用了形态学方法提取图像的空间特征, 还可以进一步提取出图像的形状特征和其他特征, 一起构造组合核函数, 进行高光谱图像分类。

#### 基金项目

本文受中国兵器工业集团有限公司科技开发费项目(JM2021005)资助。

#### 参考文献

- [1] 杜培军, 夏俊士, 薛朝辉, 等. 高光谱遥感影像分类研究进展[J]. 北京遥感学报, 2016, 20(2): 236-256.
- [2] 张锦水, 何春阳, 潘耀忠, 等. 基于 SVM 的多源信息复合的高空间分辨率遥感数据分类研究[J]. 遥感学报, 2006, 10(1): 49-57.
- [3] Melgani, F. and Bruzzone, L. (2004) Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. *IEEE Transactions on Geoscience and Remote Sensing*, **42**, 1778-1790.  
<https://doi.org/10.1109/TGRS.2004.831865>
- [4] 胡潭高, 潘耀忠, 张锦水, 李苓苓, 等. 基于线性光谱模型和支撑向量机的软硬分类方法[J]. 光谱学与光谱分析, 2011, 31(2): 508-511.
- [5] Tarabalka, Y., Fauvel, M., Chanussot, J. and Benediktsson, J.A. (2010) SVM-and MRF-Based Method for Accurate Classification of Hyperspectral Images. *IEEE Geoscience and Remote Sensing Letters*, **7**, 736-740.  
<https://doi.org/10.1109/LGRS.2010.2047711>
- [6] Ren, Y.M., Zhang, Y.N., Meng, Q.J. and Zhang, L. (2012) Hyperspectral Image Classification Based on Multiple Improved Particle Swarm Cooperative Optimization and SVM. *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*, Tsukuba, 11-15 November 2012, 2274-2277.
- [7] 钟燕飞, 良培, 李平湘. 基于多值免疫网络的多光谱遥感影像分类[J]. 计算机学报, 2007, 30(12): 2181-2188.
- [8] 孔毅, 纪定哲, 程玉虎, 等. 基于光谱注意力图卷积网络的高光谱图像分类[J]. 电子与信息学报, 2023, 45(4): 1426-1434.
- [9] 宋廷强, 宗达, 刘童心, 等. 联合分离卷积与密集连接轻量级神经网络的高光谱图像分类[J]. 遥感学报, 2022, 26(11): 2317-2328.
- [10] Jimenez, L.O., Rivera-Medina, J.L., Rodríguez-Díaz, E., Arzuaga-Cruz, E. and Ramirez-Velez, M. (2005) Integration of Spatial and Spectral Information by Means of Unsupervised Extraction and Classification for Homogenous Objects Applied to Multispectral and Hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, **43**, 844-851.  
<https://doi.org/10.1109/TGRS.2004.843193>
- [11] Benediktsson, J.A., Palmason, J.A. and Sveinsson, J.R. (2005) Classification of Hyperspectral Data from Urban Areas Based on Extended Morphological Profiles. *IEEE Transactions on Geoscience and Remote Sensing*, **43**, 480-491.  
<https://doi.org/10.1109/TGRS.2004.842478>

- 
- [12] Benediktsson, J.A., Pesaresi, M. and Amason, K. (2003) Classification and Feature Extraction for Remote Sensing Images from Urban Areas Based on Morphological Transformations. *IEEE Transactions on Geoscience and Remote Sensing*, **41**, 1940-1949. <https://doi.org/10.1109/TGRS.2003.814625>
- [13] Tuia, D., Ratle, F., Pozdnoukhov, A. and Camps-Valls, G. (2010) Multisource Composite Kernels for Urban-Image Classification. *IEEE Geoscience and Remote Sensing Letters*, **7**, 88-92. <https://doi.org/10.1109/LGRS.2009.2015341>
- [14] Tipping, M.E. (2001) Sparse Bayesian Learning and the Relevance Vector Machine. *The Journal of Machine Learning Research*, **1**, 211-244.
- [15] 吴慧兰, 刘国栋, 浦昭邦. 基于相关向量机的惯性约束聚变实验靶识别技术研究[J]. 光学学报, 2009, 29(7): 1888-1891.
- [16] Foody, G.M. (2008) RVM-Based Multi-Class Classification of Remotely Sensed Data. *International Journal of Remote Sensing*, **29**, 1817-1823. <https://doi.org/10.1080/01431160701822115>
- [17] Demir, B. and Erturk, S. (2007) Hyperspectral Image Classification Using Relevance Vector Machines. *IEEE Geoscience and Remote Sensing Letters*, **4**, 586-590. <https://doi.org/10.1109/LGRS.2007.903069>
- [18] Camps-Valls, G., Rodrigo-Gonzalez, A., Munoz-Mari, J., Gomez-Chova, L. and Calpe-Maravilla, J. (2007) Hyperspectral Image Classification with Mahalanobis Relevance Vector Machines. 2007 *IEEE International Geoscience and Remote Sensing Symposium*, Barcelona, 23-28 July 2007, 3802-3805. <https://doi.org/10.1109/IGARSS.2007.4423671>
- [19] 赵春晖, 齐滨, 张焱. 基于改进型相关向量机的高光谱图像分类[J]. 光学学报, 2012, 32(8): 256-261.
- [20] Tipping, M.E. and Faul, A. (2003) Fast Marginal Likelihood Maximisation for Sparse Bayesian Models. *Proceedings of the Ninth International Workshop on Artificial Intelligence and Statistics*, Key West, 3-6 January 2003, 276-283.
- [21] Vapnik, V.N. (1998) *Statistical Learning Theory*. Wiley, New York, 423.
- [22] Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances, J. and Calpe-Maravilla, J. (2006) Composite Kernels for Hyperspectral Image Classification. *IEEE Geoscience and Remote Sensing Letters*, **3**, 93-97. <https://doi.org/10.1109/LGRS.2005.857031>
- [23] MultiSpec (2022) A Freeware Multispectral Image Data Analysis System. <http://ftp.ecn.purdue.edu/biehl/MultiSpec/92AV3C/>