

基于光谱和纹理特征的高光谱图像分类

朱萌[†], 俞阳, 翟千惠, 何玮, 康雨萌

(国网江苏省电力有限公司 营销服务中心, 江苏 南京 210000)

摘要:针对高光谱图像分类技术利用空间信息不足的问题,提出了一种光谱特征和纹理特征相结合的高光谱图像分类方法。通过二维 Gabor 小波提取高光谱图像纹理特征,利用函数型数据分析(FDA)框架分析高光谱数据,采用三次 B 样条基系统生成光谱特征和纹理特征的函数型数据,结合函数主成分分析(FPCA)提取每个像素的函数主成分(FPC),运用概率 SVM 分别对光谱特征和纹理特征进行分类。通过实验调参找到光谱特征和纹理特征的最佳参数组合,从而提高分类精度。通过在两个具有不同空间分辨率的高光谱图像数据集上进行实验,分析了参数的变化对分类精度的影响,并与其他同类方法相比较,随机选择 5% 的样本和 10% 的样本作为训练样本的总体精确度(OA)较 EMAP+SVM 方法分别提高了 1.39% 和 3.87%。

关键词:高光谱图像;图像分类;纹理特征;光谱特征;空间信息

中图分类号:TP751;TP183 **文献标识码:**A

Hyperspectral Image Classification Based on Spectral and Texture Features

ZHU Meng[†], YU Yang, ZHAI Qianhui, HE Wei, KANG Yumeng

(Marketing Service Center of State Grid Jiangsu Electric Power Co., Ltd., Nanjing, Jiangsu 210000, China)

Abstract: A hyperspectral image classification method based on the combination of spectral features and texture features is proposed to solve the problem of using insufficient spatial information in hyperspectral image classification technology. The texture features of hyperspectral images are extracted by two-dimensional Gabor wavelet, hyperspectral data are analyzed by functional data analysis (FDA) framework, functional data of spectral features and texture features are generated by cubic B-spline basis system, functional principal component analysis (FPCA) is used to extract the functional principal component (FPC) of each pixel, and probabilistic SVM is used to classify spectral features and texture features respectively. The best parameter combination of spectral features and texture features is found by adjusting parameters in experiments, so as to improve the classification accuracy. Through experiments on two hyperspectral image datasets with different spatial resolutions, the influence of parameter changes on classification accuracy is analyzed. Compared with other similar methods, the overall accuracy (OA) of randomly selecting 5% samples and 10% samples as training samples is 1.39% and 3.87% higher than that of EMAP+SVM respectively.

Key words: hyperspectral image; image classification; texture features; spectral features; spatial information

随着高光谱成像传感器出现,许多无法通过传统多光谱成像传感器分辨的目标,现在可以通过高光谱成像仪进行数据分析^[1]。目标分类作为高光谱成像的重要应用,空间信息有助于提高高光谱图像分类精度^[2]。

通常,高光谱图像的光谱空间分类有三大类:(1)基于目标的分类:经过分割后的图像被划分为一组相互连接的组成部分(即目标),其中,每个目标确定一个特征或一组特征。利用基于像素的分类器对像素进行逐个目标分类。文献[3]提出了支持向量机(SVM)分类器和组合核(SVM-CK)的分类方法,通过从光谱数据中提取超像素图,利用SVM得到目标间加权平均特征数据和平均特征数据立方体,结合原始光谱数据和数据立方体生成的组合核(CK)进行分类。(2)基于组合特征的分类:基于光谱数据和空间信息生成的组合特征用于分类。纹理是用于分析不同类型图像的最重要特征,文献[4]利用基于形态学属性滤波器的扩展属性轮廓(EAP)和扩展多形态属性轮廓(EMAP)来提取空间信息,研究表明,与扩展形态轮廓(EMP)相比,EMAP结合SVM分类器(EMAP+SVM)所表示的特征能够更好地建模空间信息并进行高效分类。(3)分类和分割的集成:利用空间信息和决策规则(如多数投票或概率标签松弛)来细化像素,达到分类目的。马尔可夫随机场(MRF)是用于将空间信息纳入高光谱图像分类的概率模型,文献[5]提出了利用SVM后验概率结合改进多尺度MRF的遥感图像分类(SVMMRF)方法。文献[6]提出在隐马尔可夫随机场中引入SVM分类器(HMRF+SVM),通过决策规则实现多尺度分类,在每个尺度中生成分层超像素分割并用于改进超像素分类结果。

通常,传统分类方法属于多元分析框架(MAF),其中像素特征由光谱或纹理特征数量决定的维数向量表示。然而,在函数型数据分析(FDA)框架中,高维数据视为连续函数。如果高维高光谱数据由连续函数表示,则可以使用隐藏在波长带之间的额外信息。同时,FDA框架中的高光谱图像分类优于MAF框架中的传统分类方法。同时,基于光谱、纹理和形状特征等多个特征提取组合特征作为高光谱图像分类的常用方法,但需要大量计算才能将多个特征以最佳方式组合,进而获取统一的组合特征进行分类。

本文提出了一种基于光谱特征和纹理特征的高光谱图像分类方法,通过Gabor滤波器进行纹

理特征提取,利用概率SVM分别对光谱和纹理特征进行分类,求出每个像素的每类概率的光谱和纹理估计,运用先前概率的线性组合得到总概率,最终将每个像素分配到具有最高总概率的类别。光谱特征和纹理特征相互增强以提高分类精度,通过实验调整组合参数,从而找到各种区域中光谱和纹理特征的最佳组合。所提出的高光谱图像分类方法在MAF和FDA框架中分别对两个具有不同训练样本的真实高光谱数据进行了分类,验证了方法在分类精度方面的有效性。

1 研究框架

提出的高光谱图像分类方法主要分为三个组成部分:(1)使用Gabor滤波器的纹理特征提取;(2)FDA框架中的高光谱数据分析;(3)利用概率SVM分别对光谱特征和纹理特征进行分类。

1.1 纹理特征提取

采用二维Gabor小波提取纹理特征。Gabor滤波器可在不同方向和尺度上提取有用纹理特征。Gabor小波作为滤波器,其脉冲响应由椭圆高斯包络和复平面波定义^[7]。二维Gabor函数可以用数学公式表示为:

$$G_{s,d}(x,y) = G_{\vec{k}}(\vec{x}) = \frac{\delta^2}{\sigma^2} e^{-\frac{\vec{k}^2 - \vec{x}^2}{2\delta^2}} (e^{i\vec{k} \cdot \vec{x}} - e^{\delta^2/2}) \quad (1)$$

其中, $\vec{x} = (x,y)$ 为图像中像素的位置。参数 $\vec{k} = (\pi/2f^s)e^{i(\pi d/8)}$ 为频率向量, $f = 2$ 。参数 s 和 d 分别为尺度和方向。高斯包络下的振荡次数由 $\delta = 2\pi$ 决定。

Gabor纹理特征图像是通过将图像 $I(x,y)$ 与Gabor函数以特定尺度和方向进行卷积计算:

$$F_{s,d}(x,y) = G_{s,d}(x,y) * I(x,y) \quad (2)$$

像素的纹理特征由向量表示为:

$$v_i(x,y) = [F_{1,1}(x,y), \dots, F_{s,d}(x,y)] \in R^{s \times d} \quad (3)$$

1.2 高光谱数据分析

函数型数据由观察到的函数或平滑曲线组成,FDA框架作为一种统计方法,旨在解决函数型数据的统计建模和预测相关的问题。

令 $X = \{x_1, x_2, \dots, x_n\}$ 为高光谱图像的 n 个像素,其中 $x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]^T$ 表示第 i 个像素的反射率, d 为光谱带的数量。平滑函数 y_i 可以表示为第 i 个像素构成光谱曲线的基础。像素 x_i 在波长 $j \in [1,d]$ 处的反射率值是平滑函数

$y_i(\lambda)$ 在点 λ_j 处的值,其中, λ 为波长。

平滑函数 $y_i(\lambda)$ 可以用线性方程表示为:

$$y_i(\lambda) = \sum_{k=1}^K c_{i,k} \varphi_k(\lambda) \quad (4)$$

其中, $\{\varphi_k\}$ 为基函数集合, $c_{i,k}$ 为基函数相应控制点的系数, K 为基函数的数量。

假设 $T = t_0, t_1, \dots, t_{d-1}$ 为定义曲线的 d 个控制点集合,其中, $t_i \in (t_{\min}, t_{\max})$ 为结点。对参数 t 的唯一其他限制是 t_i 的值必须是单调相加的。阶数为 I 的第 k 个 B 样条基函数 $N_{k,I}(t)$ 可根据 Cox-De Boor 递推关系^[10] 计算为:

$$N_{k,I}(t) = \frac{(t-t_k)N_{k,I-1}(t)}{t_{k+I-1}-t_k} + \frac{(t_{k+I}-t)N_{k+1,I-1}(t)}{t_{k+I}-t_{k+1}} \quad (5)$$

其中,

$$N_{k,I}(t) = \begin{cases} 1, & t_k < t < t_{k+1} \\ 0, & \text{其他} \end{cases} \quad (6)$$

文献[11]指出,在三次 B 样条基系统中, $I = 4$ 时适用于高光谱图像。通过在两个控制点之间使用不同的三次多项式曲线来构造三次 B 样条,该函数非常光滑且任意点都具有连续的二阶导数。对式(4)中的三次 B 样条基函数的系数 $\{c_{i,k}\}$ 进行估计,从而使得所构造的曲线适合于特定程度的平滑数据。利用粗糙度惩罚方法来估计系数,通过最小化以下标准将平滑曲线 $y_i(t)$ 拟合到像素值 x_i :

$$F = \min \left\{ \sum_{j=1}^d [x_{i,j} - y_i(t_j)]^2 + \omega \int [D^2 y_i(s)]^2 ds \right\} \quad (7)$$

其中,第一项决定了第 i 个像素的反射率与平滑曲线数值之间的平方误差之和。第二项为粗糙度惩罚项,用于测量拟合函数 y_i 的可变性。 $D^2 y_i(s)$ 为函数 y_i 的二阶导数。平滑参数 ω 控制着使 y_i 适合数据与平滑函数 y_i 的平衡。当 $\omega = 0$ 时, y_i 适合于数据,而当 $\omega = 1$ 时, y_i 将根本不适合于数据。当 ω 从 0 变为 1 时,平滑性愈加明显。

通过对所构造的函数型数据直接进行比较较为困难,函数型数据可以通过主成分的线性组合来估计。函数主成分分析(FPCA)是标准主成分分析(PCA)的结构扩展。在标准 PCA 中,数据具有有限的维数,而 FPCA 适用于无限维数的数据。当 FPCA 应用于函数型数据时,提取称为函数主成分(FPC)的正交函数 $f_i = [f_{i,1}, f_{i,2}, \dots, f_{i,M}]$, $i \in [1, n]$, 其中, f_i 的元素称为 FPC 分数, M 为

每个特定应用中所需 FPC 分数的数量。

每个 FPC 由 M 个 FPC 分数组成。 y_i 的第 m 个 FPC 分数 $f_{i,m}$ 为:

$$f_{i,m} = \int \epsilon_{i,m} y_i dt \quad (8)$$

其中, $\epsilon_{i,m}$ 为主成分权重函数。 $\epsilon_{i,m}$ 的求取受限于以下约束条件:

$$\begin{cases} \int_{i,m}^{\epsilon} 2dt = 1 \\ \int \epsilon_{i,r} \epsilon_{i,m} dt = 0, \forall r < m \end{cases} \quad (9)$$

利用与 PCA 类似的方式,可以使用协方差函数的特征分析来求取主成分权重函数 $\{\epsilon_m\}$, 即第 i 个像素的特征值和特征函数组成序列对 $\{\rho_{i,m}, \epsilon_{i,m}\}$ 满足以下方程:

$$\begin{cases} \int v(s,t) \epsilon_{i,m} dt = \rho_{i,m} \epsilon_{i,m} \\ \int \epsilon_{i,r} \epsilon_{i,m} dt = \delta_{r,m}, \forall r < m \end{cases} \quad (10)$$

其中, δ 为克罗内克(Kronecker)函数, $v(s,t)$ 为协方差函数。协方差函数计算为:

$$v(s,t) = \frac{1}{n} \sum_{i=1}^n y_i(s) y_i(t) \quad (11)$$

如果曲线 y_i 由 $y_i(t) = \sum_{k=1}^K c_{i,t} N_{k,4}(t)$ 表示,且特征函数由 $\epsilon(t) = \sum_{q=1}^K b_q N_{q,4}(t)$ 给出,则式(10)可以改写为:

$$\int v(s,t) \epsilon(t) dt = \frac{1}{n} \sum \sum \sum \sum c_{i,k} c_{i,p} b_q N_{k,4}(s) \int N_{p,4}(t) N_{q,4}(t) dt = \rho \sum_{q=1}^K b_q N_{k,4}(s) \quad (12)$$

假设 $A = \left[\int N_{p,4}(t) N_{q,4}(t) dt \right]_{k \times k}$, $b = [b_1, b_2, \dots, b_k]'$, $C = \left[\sum_{i=1}^n c_{i,k} c_{i,p} \right]_{k \times k}$, $h = [N_{1,4}(t), \dots, N_{k,4}(t)]'$ 。因此,式(11)的矩阵形式为:

$$\frac{1}{n} h' C A b = \rho h' b \Rightarrow \frac{1}{n} C A b = \rho b \quad (13)$$

通过求解式(13)中的特征分析问题,利用 $\epsilon_m = h b_m$ 计算 $v(s,t)$ 的第 m 个特征函数,其中, b_m 为 $n^{-1} C A$ 的第 m 个特征向量。利用式(8)计算曲线 y_i 的第 m 个 FPC 分数 $f_{i,m}$, 从而提取 FPC 的正交函数 $f_i = [f_{i,1}, f_{i,2}, \dots, f_{i,M}]$, $i \in [1, n]$ 。

在高光谱图像中,提取每个像素的 FPC 作为光谱或纹理特征用于分类。

1.3 概率 SVM

在 SVM 分类中,与线性方法相比,核方法表

现出强大的优势^[12]。本文采用基于高斯径向基函数(RBF)核的多类单对一 SVM 分类器进行高光谱图像分类。尽管原始 SVM 不提供类概率估计,但可以使用不同的技术得到基于所有成对比较的类概率估计^[13]。本文使用 LIBSVM 库函数中的概率 SVM 方法^[14]。

2 图像分类

所提出的高光谱图像分类方法流程图如图 1 所示。其中,虚线表示应包括 MAF 或 FDA 框架中的相应特征(光谱和纹理)。

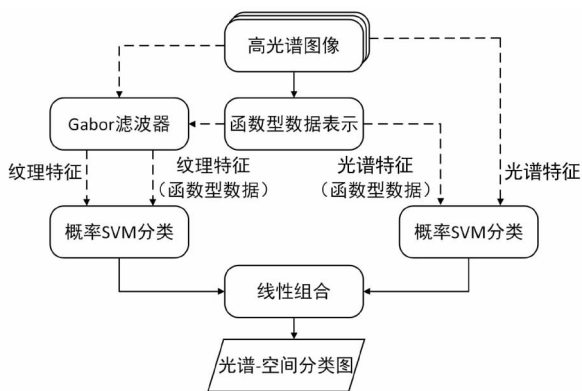


图 1 分类方法流程图

首先通过 Gabor 滤波器提取纹理特征。然后,将概率 SVM 分类器分别应用于光谱和纹理特征。随后,将两个概率线性组合得到总概率。最后,将每个像素分配给总概率最高的类。将所提出的基于光谱和纹理特征的分类方法分别在 MAF 和 FDA 框架中执行。两个概率线性组合估计的示例如图 2 所示。其中,示例中假设有 4 个不同的类别,且每个像素根据总概率分配给其中一个类。

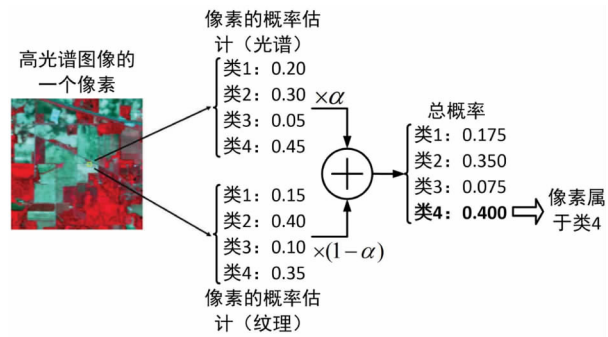


图 2 $\alpha = 0.5$ 时,分类方法示例

2.1 MAF 框架中的分类

假设将 d 维高光谱图像作为输入,并视为 n 个元素 $X = \{x_j \in R^d, j \in [1, n]\}$ 的像素向量集合,

这些像素被分配给 K 个不同的类别 $\{\omega_1, \omega_2, \dots, \omega_K\}$ 。在 MAF 框架中,对光谱和纹理特征进行概率 SVM 处理。因此,针对第 i 个像素计算空间和纹理两种概率估计分别为:

$$p_{\text{spectral}}(x_i) = \{p_{k, \text{spectral}}(x_i) = p_{\text{spectral}}(y = k | x_i)\} \quad (14)$$

$$p_{\text{texture}}(x_i) = \{p_{k, \text{texture}}(x_i) = p_{\text{texture}}(y = k | x_i)\} \quad (15)$$

将与像素 x_i 相关的总概率定义为:

$$p_{\text{total}}(x_i) = \alpha \times p_{\text{spectral}}(x_i) + (1 - \alpha) p_{\text{texture}}(x_i) \quad (16)$$

其中, α 为正常数, $\alpha \in (0, 1)$ 。它定义了光谱和纹理概率项在计算总概率中的重要性,参数 α 的最佳取值可以通过实验得出。

2.2 FDA 框架中的分类

与 MAF 框架中的分类相比, FDA 框架中的分类方法增加了一个步骤,即计算光谱特征的函数型数据和 FPC。将提取的函数型数据的 FPC 输入到概率 SVM 分类器中,从而估计每个像素的每类概率:

$$p_{\text{FDAspectral}}(x_i) = \{p_{k, \text{FDAspectral}}(x_i) = p_{\text{FDAspectral}}(y = k | x_i)\} \quad (17)$$

类似地,计算纹理特征的函数型数据和 FPC。使用概率 SVM 分类器对提取的函数型数据的 FPC 进行分类,从而估计每类概率:

$$p_{\text{FDAtexture}}(x_i) = \{p_{k, \text{FDAtexture}}(x_i) = p_{\text{FDAtexture}}(y = k | x_i)\} \quad (18)$$

最后,与像素 x_i 相关的总概率计算为:

$$p_{\text{FDAtotal}}(x_i) = \beta \times p_{\text{FDAspectral}}(x_i) + (1 - \beta) p_{\text{FDAtexture}}(x_i) \quad (19)$$

其中, β 为正常数, $\beta \in (0, 1)$ 。参数 β 的最佳取值也可以通过实验得出。

3 实验分析

使用来自农业和城市地区的两个具有不同空间分辨率的高光谱图像数据集来评估所提出方法的性能。实验在英特尔酷睿 i7-12700H 处理器和 16GB RAM 的计算机上运行 Windows 10 64 位操作系统,使用 MATLAB 2014a 版本软件对图像进行分析。

3.1 高光谱数据集

(1) 印度松树图像:该图像数据集是光谱分辨率高但空间分辨率低的高光谱图像集合,由机载可视红外成像光谱仪(AVIRIS)传感器在印第安纳州

西北部上空捕捉的农业区域图像组成。该数据集具有 145×145 像素的空间大小和 224 个光谱带,包含 16 个土地覆盖类别。通过去除覆盖吸水区域的噪声光谱带,本文使用剩下的 200 个光谱带,并选择了 9 个类别用于分类实验。印度松树图像数据集每个类别的样本数量如表 1 所示。

表 1 印度松树图像数据集每个类别的样本数量

类别名称	样本数量	类别名称	样本数量
玉米田	1434	大豆田	968
苜蓿田	834	薄荷田	2468
草场	497	小麦田	614
草树	747	树木	1294
干草堆	489	—	—

(2)帕维亚大学图像:该图像数据集是光谱分辨率高且空间分辨率高的高光谱图像集合,由反射光学系统成像光谱仪(ROSIS-03)光学传感器在意大利北部帕维亚上空捕捉的城市区域图像组成。该数据集具有 610×340 像素的空间大小和 115 个光谱带,包含 9 个类别。通过去除 12 个噪声最大的光谱带后,本文使用剩下的 103 个光谱带。帕维亚大学图像数据集每个类别的样本数量如表 2 所示。

表 2 帕维亚大学图像数据集每个类别的样本数量

类别名称	样本数量	类别名称	样本数量
柏油路面	6631	裸露土地	5029
草地	18649	沥青屋顶	1330
沙砾	2099	砖石	3582
树木	3064	阴影	947
金属板	1345	—	—

3.2 总体描述

对于这两种图像数据集,纹理特征由 Gabor 滤波器提取。Gabor 函数的参数 s 和 d 分别设置为 5 和 12。因此,大小为 60×1 的向量 $v_i \in R^{60}$ 表示高光谱图像每个像素的纹理特征。采用三次 B 样条基系统生成光谱特征和纹理特征的函数型数据。印度松树图像的前 3 个 FPC 如图 3 所示。




图 3 印度松树图像的前三个 FPC

光谱和纹理特征 FPC 用于光谱和纹理分类,因此,本文使用两个不同的训练集,即从整个场景的每个类别中随机选择 5% 的样本(称为集合 A)和 10% 的样本(称为集合 B)作为训练样本,其余作为测试样本。在所有分类中都选择基于 RBF 核的多类单对—SVM 分类器。通过实验得出了参数 α 和 β 组合的最佳取值。同时,使用了 4 种衡量准确度的方法:平均准确度(AA)、总体准确度(OA)、Kappa 系数(κ)、 z 分数。在实验测试中,当 $z_{ij} > 0$ 时,表示分类器 i 比分类器 j 更准确,反之亦然,即 $z_{ij} < 0$ 。如果 $|z_{ij}| > 1.96$,则两个分类器 i 和 j 之间的分类精度差异具有统计学意义。参数 z 定义为:

$$z = \frac{f_{ij} - f_{ji}}{\sqrt{f_{ij} + f_{ji}}} \quad (19)$$

其中, f_{ij} 为分类器 i 正确标记且分类器 j 错误标记的样本数量。

3.3 分类性能

(1)印度松树图像:在印度松树图像上使用两个不同的训练集进行光谱—空间分类方法。针对不同的控制参数 α 和 β ,对本文方法在 MAF 和 FDA 框架中的性能进行研究。本文方法对印度松树图像的分类准确度如表 3 所示。其中,最佳分类精度以粗体显示。

由表 3 可见,对于两个不同的训练集,控制参数最佳值 $\alpha \in [0.4, 0.5]$,对于 5% 的训练样本, $\beta \in [0.4, 0.5]$,对于 10% 的训练样本, $\beta \in [0.3, 0.5]$ 。尽管在 MAF 和 FDA 框架中,本文方法对参数 α 和 β 的选择都具有鲁棒性,但默认值 $\alpha = 0.5$ 和 $\beta = 0.5$ 对分类精度与最高分类精度没有显著差异,则光谱和纹理特征对提高分类的效果几乎相同。

为了验证本文方法在高光谱图像分类中的效率,将本文方法与 SVMRF^[5]、HMRF+SVM^[6]、EMAP+SVM^[4] 和 SVM-CK^[3] 等其他光谱—空间分类方法进行比较,如表 4 所示。

由表 4 可见,本文方法在 MAF 和 FDA 框架中总体上具有更高的分类精度。尤其本文方法在 FDA 框架中得出了最佳的全局和特定类别分类精度。然而,印度松树图像的低空间分辨率导致像素具有高度混合问题,并且不同类别之间以及某些类别内部的像素数量差异较大。本文方法在 MAF 和 FDA 框架中仍能正确分类超过 94% 的像素。其中,在 MAF 框架中,集合 A 和集合 B 的 OA 分别为 95.03% 和 97.76%,与 EMAP+SVM 相比,

分别提高了 1.35% 和 3.31%；在 FDA 框架中，集合 A 和集合 B 的 OA 分别为 95.07% 和 98.32%，与 EMAP + SVM 相比，分别提高了 1.39% 和 3.87%。实验结果证明了本文方法有能力将光谱和

纹理分类结果结合起来，从而提高像素分类精度，其中使用 FDA 框架能够得到最佳结果，这是由于在 FDA 框架中，高维数据被视为函数型数据，可以使用隐藏在频带之间的额外丰富信息。

表 3 本文方法对印度松树图像的分类准确度

训练样本	测量精度	本文方法在 MAF 框架中的控制参数 α					本文方法在 FDA 框架中的控制参数 β				
		0.2	0.36	0.4	0.5	0.6	0.3	0.4	0.5	0.6	0.7
集合 A (5%)	AA	93.19	94.67	94.74	93.95	91.13	93.35	94.59	94.87	93.10	90.01
	OA	93.44	94.93	95.03	94.45	91.74	93.35	94.86	95.07	93.58	90.58
	κ	92.28	94.03	94.15	93.46	90.26	93.83	93.95	94.19	92.42	88.85
集合 B (10%)	AA	96.85	97.42	97.33	97.09	94.67	92.73	98.66	98.00	95.39	93.11
	OA	97.38	97.76	97.70	97.43	94.98	98.45	98.32	98.00	95.52	93.17
	κ	96.92	97.37	97.30	96.98	94.00	97.93	98.03	97.69	94.72	91.93

表 4 不同分类方法对印度松树图像的分类结果

类别名称	本文方法在 MAF 中		本文方法在 FDA 中		SVMMRF ^[5]		EMAP+SVM ^[6]		HMRP+SVM ^[4]		SVM-CK ^[3]	
	集合 A	集合 B	集合 A	集合 B	集合 A	集合 B	集合 A	集合 B	集合 A	集合 B	集合 A	集合 B
玉米田	93.69	95.91	94.42	96.61	77.68	85.51	87.37	84.81	67.69	67.31	83.11	86.51
苜蓿田	93.43	97.52	87.75	97.75	57.32	83.69	94.82	94.42	48.14	85.15	66.92	86.87
草场	95.34	95.31	97.03	99.55	92.80	95.54	91.52	93.97	93.08	95.09	87.29	93.53
草树	89.86	99.85	92.82	99.85	97.32	99.70	91.83	98.66	97.03	98.37	93.66	100
干草堆	99.57	99.74	100	99.77	100	99.55	98.27	99.09	99.77	99.57	97.63	97.74
大豆田	89.89	96.11	87.83	96.79	63.70	85.11	87.17	89.80	73.88	83.39	79.24	84.65
薄荷田	97.44	99.19	97.91	98.52	97.57	97.76	97.95	98.96	92.37	93.68	89.81	91.57
小麦田	95.88	94.25	97.63	97.13	83.02	79.89	91.93	86.71	69.65	75.22	72.73	70.74
树木	97.56	99.32	97.48	100	98.62	99.57	97.64	99.65	97.35	98.72	97.48	99.15
AA	94.74	97.42	94.87	98.66	85.34	91.81	93.17	94.01	82.11	88.52	85.32	90.33
OA	95.03	97.76	95.07	98.32	86.46	92.52	93.68	94.45	82.71	88.05	86.17	90.43
κ	94.15	97.37	94.19	98.03	83.84	91.17	92.56	93.46	79.45	85.98	83.69	88.75

利用印度松树图像的集合 B 训练样本，将本文方法与 SVMMRF^[5]、EMAP + SVM^[6]、HMRP+SVM^[4] 和 SVM-CK^[3] 等其他光谱-空间分类方法进行比较，如图 4 所示。

由图 4 可见，尽管与其他分类方法相比，本文方法的分类图没有正确显示区域边缘，但可以更清晰地看到参考数据的所有区域。

同样，利用印度松树图像的集合 B 训练样本进行对比，不同方法的 z 分数结果如表 5 所示。

由表 5 可见，本文方法与其他方法之间在分类精度上的差异具有统计学意义。

(2) 帕维亚大学图像：针对不同的控制参数 α 和 β ，对本文方法在 MAF 和 FDA 框架中的性能进行研究。本文方法对帕维亚大学图像的分类准确度如表 6 所示。其中，最佳分类精度以粗体

显示。

表 5 不同方法对印度松树图像的 z 分数

分类器比较	z 分数	
	集合 A	集合 B
本文方法(MAF)vs. 本文方法(FDA)	-0.17	-4.10
本文方法(MAF)vs. SVMMRF	23.05	18.79
本文方法(MAF)vs. EMAP+SVM	5.01	14.00
本文方法(MAF)vs. HMRP+SVM	31.97	27.60
本文方法(MAF)vs. SVM-CK	20.28	22.99
本文方法(FDA)vs. 本文方法(MAF)	0.17	4.10
本文方法(FDA)vs. SVMMRF	24.28	20.05
本文方法(FDA)vs. EMAP+SVM	5.00	15.60
本文方法(FDA)vs. HMRP+SVM	33.26	28.50
本文方法(FDA)vs. SVM-CK	23.31	23.72

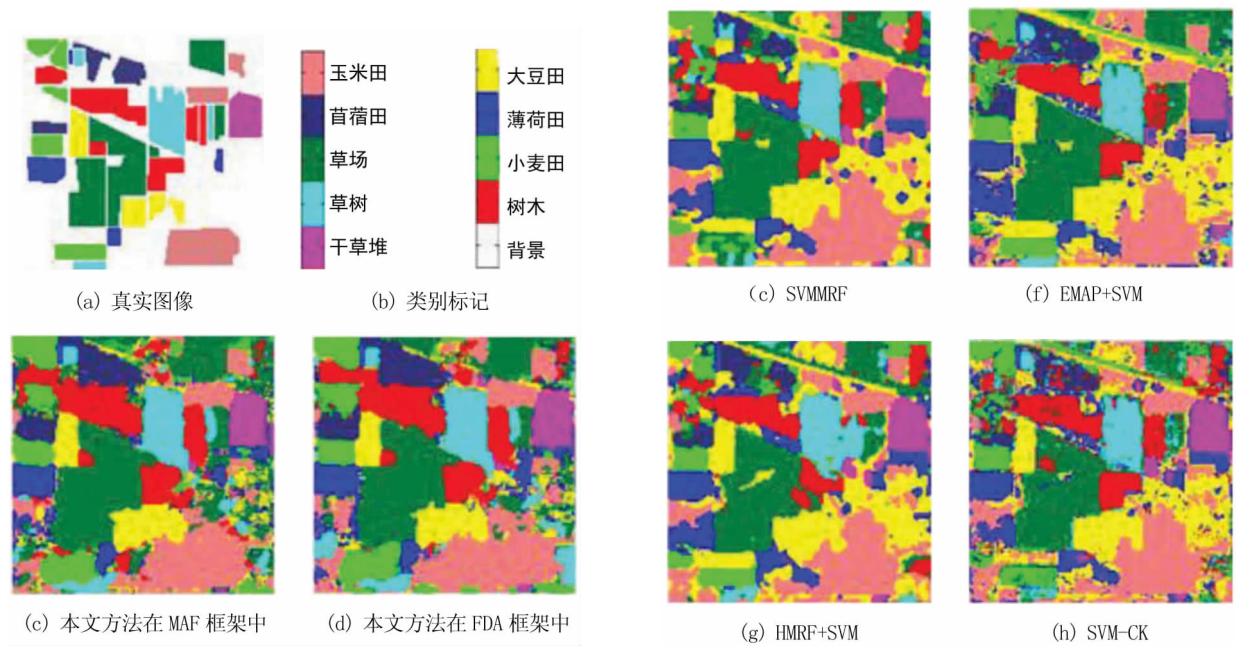


图 4 不同分类方法对印度松树图像集合 B 的分类结果

表 6 本文方法对帕维亚大学图像的分类准确度

训练样本	测量精度	本文方法在 MAF 中的控制参数 α					本文方法在 FDA 中的控制参数 β				
		0.3	0.4	0.5	0.6	0.7	0.3	0.48	0.5	0.6	0.7
集合 A (5%)	AA	95.38	96.24	96.53	95.03	93.40	94.80	97.05	97.14	95.99	94.74
	OA	97.38	97.98	98.11	96.71	95.23	96.45	98.10	98.21	97.21	96.15
	κ	96.53	97.32	97.49	95.63	93.65	95.30	97.48	97.63	96.29	94.88
集合 B (10%)	AA	96.70	97.45	98.11	96.32	94.34	97.86	98.97	98.78	96.80	95.46
	OA	97.71	98.23	98.74	97.22	95.67	98.71	99.39	99.26	97.61	96.59
	κ	96.95	97.65	98.32	96.30	94.23	98.28	99.19	99.00	96.82	95.47


由表 6 可见,对于两个不同的训练集合,控制参数最佳值分别为 $\alpha \in [0.4, 0.6]$ 和 $\beta \in [0.4, 0.5]$ 。

利用帕维亚大学图像的集合 B 训练样本,将本文方法与 SVMRF^[5]、HMRF + SVM^[6]、EMAP + SVM^[4] 和 SVM-CK^[3] 等其他光谱-空间分类方法进行比较,如图 5 所示。

4 结论

提出了一种基于光谱特征和纹理特征的分类方法来提高高光谱图像分类精度,并在 MAF 和 FDA 框架中得到了应用。通过将每个像素的光谱特征和纹理特征的两个概率线性地组合,从而提高了分类精度。利用 FDA 框架更好地估计高光谱图像分析的概率。在两个高光谱图像上进行了测试,得到的结果证实了本文方法的有效性,并与其

他同类方法的比较验证了本文方法具有更高的分类性能。在未来的研究中,将致力于利用基于机器学习的方法提取纹理特征,从而进一步提升高光谱图像分类精度。






图5 不同分类方法对帕维亚大学图像集合B的分类结果

参考文献

- [1] 魏长婧. 遥感技术在矿业领域的应用现状及发展趋势综述[J]. 北京测绘, 2022, 36(10): 1285-1292.
- [2] 任彦, 高晓文, 杨静, 等. 结合并行CNN与极限学习机的高光谱图像分类[J]. 遥感信息, 2022, 37(3): 34-41.
- [3] 陈军丽, 黄睿, 张国鹏. 基于超像素分割的形态学标准差属性剖面特征自动生成[J]. 工业控制计算机, 2018, 31(3): 23-24.
- [4] WANG Yongqi, XIAO Zengqi, TIONG L K, et al. Data-driven quantification of public-private partnership experience levels under uncertainty with Bayesian hierarchical model[J]. Applied Soft Computing, 2021, 103(5): 107-116.

- [5] 曲海成, 郭月, 王媛媛. 一种新的空谱联合高光谱图像分类方法[J]. 测绘科学, 2019, 44(8): 82-90.
- [6] 涂兵, 朱禹, 周承乐, 等. 多尺度超像素纹理特征保持与融合的高光谱图像分类[J]. 电子与信息学报, 2022, 44(6): 2207-2215.
- [7] PRATHIBHA V, SAROJA G. Hexagonal image enhancement using Hex-Gabor filter for machine vision applications[J]. Materials Today: Proceedings, 2022, 56(1): 555-558.
- [8] 赵鹤宇, 樊立艳, 常锦才. 基于三次样条基函数的模糊数据插值[J]. 华北理工大学学报(自然科学版), 2022, 44(4): 68-79.
- [9] 张梦珠, 王旭辉. 基于B样条的概率密度函数非参数估计[J]. 大学数学, 2022, 38(3): 1-6.
- [10] BECCARI C, CASCIOLA. A cox-de boor-type recurrence relation for C1 multi-degree splines[J]. Computer Aided Geometric Design, 2019, 75(9): 101-112.
- [11] 李锦鹏, 熊显名, 曾启林, 等. 基于三次B样条小波变换和Franklin矩亚像素级图像边缘检测算法[J]. 红外技术, 2022, 44(3): 255-261.
- [12] 李广洋, 寇卫利, 陈帮乾, 等. 多核学习算法及其在高光谱图像分类中的应用研究进展[J]. 地球信息科学学报, 2021, 23(3): 492-504.
- [13] 赵恒赫, 潘新, 马玉宝, 等. 基于RBF-SVM的草地高光谱图像分类[J]. 扬州大学学报(农业与生命科学版), 2022, 43(1): 128-134.
- [14] 孙玉杰, 张占强, 孟克其劳, 等. 基于FST和LibSVM的电能质量扰动信号分类[J]. 计算机仿真, 2022, 39(11): 146-152.

(上接第61页)

4 结论

低频低压减载装置的不适当使用会加大该装置的压力, 影响使用效果, 为此, 提出了基于改进孪生神经网络的低频低压减载装置在线解耦控制方法。该方法首先分析了低频低压减载装置特性, 以此为基础利用建立的混合模型生成出可训练的数据集, 从中确定减载节点数据。进一步将获取结果输入到改进孪生神经网络中分类训练, 其输出结果就是最佳类标签, 再将其分配到合适的减载节点内, 即可实现低频低压减载装置在线解耦控制。由于该方法在减载量获取方面还不够完善, 日后会加强对这一缺陷的研究。

参考文献

- [1] 刘克天, 张钧, 李军, 等. 基于频率偏移面积的功率缺额计算及低频减载整定[J]. 电工技术学报, 2021, 36(5): 1040-1051.

- [2] 刘庆楷, 刘明波, 陆文甜. 预防暂态低频减载的储能容量配置多目标动态优化方法[J]. 电力建设, 2021, 42(3): 81-88.
- [3] 林莉, 罗皓, 杨仕燕, 等. 基于节点电动机最大自启动量的配电网低压减载[J]. 电力系统保护与控制, 2020, 48(9): 77-87.
- [4] 王怀远, 何培灿, 江岳文, 等. 基于估测惯量计算的低频减载方法[J]. 电力自动化设备, 2019, 39(7): 51-56+63.
- [5] 李世春, 吕翔生, 钟浩, 等. 大规模双馈风电机组参与调频的电网自适应低频减载策略[J]. 电力系统自动化, 2019, 43(15): 109-115.
- [6] 孙涛, 仇宝云, 黄先北, 等. 双向钢闸门反向挡水启门力CFD分析与减载对策[J]. 排灌机械学报, 2021, 39(9): 904-909.
- [7] 赵允刚, 王鑫涛, 赵晋, 等. 减载式声屏障对高速列车气动阻力影响分析[J]. 北京交通大学学报, 2020, 44(1): 77-83.
- [8] 洪哲扬, 薛凌云, 钱依凡. 基于光电热理论和BP神经网络的LED阵列光功率计算方法[J]. 激光与光电子学进展, 2022, 59(5): 282-289.
- [9] 徐先峰, 张丽, 郎彬, 等. 引入感知模型的改进孪生卷积神经网络实现人脸识别算法研究[J]. 电子学报, 2020, 48(4): 643-647.
- [10] 张宏伟, 李晓霞, 朱斌, 等. 基于孪生神经网络的两阶段目标跟踪方法[J]. 红外与激光工程, 2021, 50(9): 341-352.
- [11] 梁海涛, 党凯, 王弋飞, 等. 综合低电压治理装置及其解耦控制研究[J]. 电力电容器与无功补偿, 2020, 41(3): 156-162.
- [12] 赵希梅, 吴岑. 基于滑模自抗扰的PMLSM电流偏差解耦控制[J]. 光学精密工程, 2022, 30(4): 431-441.