

文章编号 1004-924X(2019)07-1649-12

改进高斯过程回归的高光谱空谱联合分类算法

陈 静^{1,3*}, 张 静²

(1. 广东工业大学 华立学院, 广东 广州 511325;

2. 西安科技大学 测绘科学与技术学院, 陕西 西安 710054;

3. 中国科学院南海海洋研究所 广东省海洋遥感重点实验室, 广东 广州 510301)

摘要:针对高斯过程回归在高光谱图像分类中计算量较大、分类精度较低等问题,提出一种基于改进高斯过程回归的高光谱空谱联合分类算法。算法以最大方差为指标选取样本的子集缩小高斯过程回归参数求解的计算范围,采用平方根矩阵分解法对新添加样本进行模型结果预测,有效提升运算效率;算法以空间-光谱特征信息为基础,在像元近邻空间中重新定义邻域像元空-谱关联距离,将融入空间近邻信息的空-谱关联距离作为权值来度量邻域像元相似性,加大同类地物归为近邻的概率,从而提高地物分类的精度。在 Indian Pines 和 Pavia University 两组高光谱数据集上进行仿真实验,实验结果可知,与其他同类算法横向相比,本文提出的改进算法在总体分类精度、平均分类精度和 Kappa 系数等评价指标至少提高了 2.3%, 1.4% 和 1.07%, 与改进前的模型算法纵向对比可知,本文提出的改进算法在取得较高总体分类精度的同时,大幅降低了算法的运行时间。

关键词:高光谱图像分类;高斯过程回归;最大方差;平方根矩阵分解;空-谱关联距离

中图分类号: TP751, P237 **文献标识码:** A **doi:** 10.3788/OPE.20192707.1649

Spectral-spatial joint classification of hyperspectral image algorithm based on improved Gaussian process regression

CHEN Jing^{1,3*} ZHANG Jing²

(1. Huali College Guangdong University of Technology, Guangzhou 511325, China;

2. College of Geomatics, Xi'an University of Science And Technology, Xi'an 710054, China;

3. Guangdong Key Laboratory of Ocean Remote Sensing, South China Sea

Institute of Oceanology Chinese Academy of Sciences, Guangzhou 510301, China)

* Corresponding author, E-mail: chenjing981@sina.com

Abstract: To solve the problems of high calculation amounts and low classification accuracy of Gaussian process regression in hyperspectral image classification, a spectral-spatial joint classification algorithm for hyperspectral images based on improved Gaussian process regression was proposed. A subset of samples was selected using maximum variance as the index to narrow the calculation range of the Gaussian process regression parameter solution, and a square root matrix decomposition method was introduced to predict the model results for incoming added samples, all of which effectively improve

收稿日期:2018-12-24;修订日期:2019-03-04.

基金项目:广东省海洋遥感重点实验室基金资助项目(No. 2017B030301005-LORS1804);国家海洋局空间海洋遥感与应用研究重点实验室基金资助项目(No. 201702002)

the efficiency of calculation. A spatial-spectral correlation distance of neighborhood pixels was redefined in the pixel neighbor space based on spatial-spectral feature information. In addition, a space-spectrum correlation distance integrated with spatial neighbor information was used as the weight to measure the similarity of neighborhood pixels. These increase the probability that similar features would be classified as neighbors, thus improving the accuracy of feature classification. Simulation experiments were conducted on two sets of hyperspectral datasets from Indian Pines and Pavia University. Experimental results show that, compared with other similar algorithms, the proposed algorithm improves overall classification accuracy, average classification accuracy, and the Kappa coefficient by at least 2.3%, 1.4%, and 1.07%, respectively. Compared with the model algorithm prior to enhancements, the improved algorithm not only achieves higher overall classification accuracy but also considerably reduces the running time.

Key words: classification of hyperspectral images; Gauss process regression; maximum variance; square root matrix decomposition; spectral-spatial associated distance

1 引言

分类是对给定的一组观测量赋以唯一类别标记的过程。高光谱遥感影像具有波段小而多、光谱精细连续、谱像合一等优点,但也存在维数灾难、信息冗余、特定噪声类内光谱异质性、非线性数据空间等难点^[1-2]。因此,设计合理的算法提高分类的有效性、稳定和计算效率,具有很大的研究价值和科学意义。针对分类高光谱图像所面临的困难,国内外学者一方面通过挖掘特征,降低数据维度,在低维空间对高光谱图像进行有效分类^[3-8];另一方面引入模式识别和机器学习理论,利用高光谱蕴含的信息,不断提升分类识别的精度^[9-14]。虽然降维或多特征融合能较好的对高光谱图像分类,但一味地降维或再多的特征融合都无法精确的区分光谱图像。

高斯过程模型是伴随着贝叶斯神经网络发展起来的一种新的核方法,可较容易的处理机器学习中的分类和回归。正因为高斯过程模型在分类和回归方面的优越性,国内外学者对此进行了大量研究。文献[15]利用高斯过程模型来降低数据维数,以进一步数据分类;文献[16]将高斯过程模型扩展到半监督学习;文献[17]将高斯回归过程模型应用到遥感图像对植被叶绿素分布分类上,取得了较好的结果;文献[18]提出了一种异方差高斯回归过程模型,并将其应用到高光谱图像物理参数的预估上,取得了不错的效果;文献[19]使用高斯回归过程模型对红外短波光谱区间进行回

归预测。

综上所述,高斯过程模型在分类回归方面有很大的优势,但其在高光谱图像分类上应用较少,并且大部分研究都是直接应用高斯过程模型进行分类,并没有考虑高光谱图像的光谱信息和空间信息。为此本文将高光谱图像自身的空谱信息加入到模型中,以提升原始高斯过程模型的分类精度,同时针对高斯过程模型的机器学习计算量太大,有新样本加入后,高斯过程模型的更新较慢等问题,本文利用最大方差近似法选择训练子集以缩小高斯过程回归参数求解的集合范围,采用平方根矩阵分解法对新添加样本进行模型结果预测,与使用更新后样本子集对模型进行训练相比,大幅度降低了计算量。

2 高斯过程回归模型

高斯过程是概率论和数理统计中随机过程的一种,对高斯过程进行建模和预测是机器学习的重要内容之一,其中常见的模型包括高斯过程回归和高斯过程分类。这里重点介绍高斯过程回归模型在高光谱图像分类上的应用,高斯过程回归(Gaussian Process Regression, GPR)是使用观测数据对连续函数定义的高斯过程进行参数估计的监督学习过程。假设训练数据集 $D = \{x_i, y_i | i = 1, 2, \dots, N\}$ 含有 N 个训练数据, (x, y) 为样本的输入和输出。回归就是利用训练数据集 D 去求输入到输出间的映射函数 f 。从而依据映射函数求出给定 x_α 所对应的回归函数值 $y_\alpha = f(x_\alpha)$ 。

高斯过程回归为一种非参数化回归模型,其不确定映射函数的参数形式,而是直接对映射函数的分布进行建模。针对高斯过程回归模型中是否含有噪声,可将模型分为两类,一种含噪模型,另一种为不含噪模型。

2.1 无噪高斯过程模型

假设 N 个输入 $X = \{x_1, x_2, \dots, x_N\}$, 有 N 个随机函数变量 $f = \{f_1, f_2, \dots, f_N\}$, 其中有 $f_i = f(x_i)$ 。若均值函数为 0 则映射函数 f 的先验分布服从高斯分布:

$$p(f) = N(o, \mathbf{K}). \quad (1)$$

协方差 \mathbf{K} 为样本间核函数计算值的集合,这里所用核函数为高斯径向基核函数:

$$k(x, x') = \delta_f^2 \exp\left(-\frac{\|x - x'\|^2}{2h^2}\right), \quad (2)$$

其中: δ_f 表示高斯过程方差, h 表示水平尺度参数, 高斯径向基核函数参数集可表示为: $\varphi = [\delta_f, h]$ 。对 M 个测试样本 $X_* = \{x_1, x_2, \dots, x_M\}$, 其对应回归函数值为 f_* :

$$\begin{aligned} p(f, f_* | X, x_*) &= N\left(o, \begin{bmatrix} \mathbf{K} & \mathbf{K}_* \\ \mathbf{K}_*^T & \mathbf{K}_{**} \end{bmatrix}\right) \\ \mathbf{K} &= k(X, X) \\ \mathbf{K}_* &= k(X, X_*) \\ \mathbf{K}_{**} &= k(X_*, X_*). \end{aligned} \quad (3)$$

由高斯分布的多元特征可知:

$$\begin{aligned} p(f_* | X, f, X_*) &= N(\boldsymbol{\eta}_*, \boldsymbol{\Sigma}_*) \\ \boldsymbol{\eta}_* &= \mathbf{K}_*^T \mathbf{K}^{-1} f \\ \boldsymbol{\Sigma}_* &= \mathbf{K}_{**} - \mathbf{K}_*^T \mathbf{K}^{-1} \mathbf{K}_*. \end{aligned} \quad (4)$$

测试样本 x_* 对应的输出 f_* 分布为:

$$\begin{aligned} p(f_* | X, f, x_*) &= N(\boldsymbol{\eta}_*, \boldsymbol{\mu}_*) \\ \boldsymbol{\eta}_* &= \mathbf{k}_*^T \mathbf{K}^{-1} f \\ \boldsymbol{\mu}_*^2 &= \mathbf{k}_{**} - \mathbf{k}_*^T \mathbf{K}^{-1} \mathbf{K}_* \\ \mathbf{k}_* &= k(X, x_*) \\ \mathbf{k}_{**} &= k(x_*, x_*). \end{aligned} \quad (5)$$

根据式(5), 可以将预测分布均值作为测试样本 x_* 的输出结果 y_* :

$$y_* = \boldsymbol{\eta}_* = \mathbf{k}_*^T \mathbf{K}^{-1} f. \quad (6)$$

2.2 含噪高斯过程模型

若测试样本 x 到预测值 y 存在的映射函数 f 间含有噪声, 则:

$$y = f(x) + \epsilon, \quad (7)$$

其中噪声 ϵ 服从 $N(0, \sigma^2)$, σ^2 表示噪声方差。 \mathbf{E} 表示单位对角矩阵, 则预测值 y 相对于映射函数 f

似然函数为:

$$p(\mathbf{y} | f) = N(f, \sigma^2 \mathbf{E}). \quad (8)$$

将映射函数 f 积分可得边缘似然函数:

$$\begin{aligned} p(\mathbf{y} | X) &= \int p(\mathbf{y} | f) p(f) df = \\ &= N(o, \mathbf{K} + \mathbf{E}\sigma^2). \end{aligned} \quad (9)$$

在噪声干扰下, 对 M 个测试样本 $X_* = \{x_1, x_2, \dots, x_M\}$, 其对应的输出值 y_* , 则联合分布表示为:

$$p(\mathbf{y}, \mathbf{y}_*) = N\left(o, \begin{bmatrix} \mathbf{K} + \mathbf{E}\sigma^2 & \mathbf{K}_* \\ \mathbf{K}_*^T & \mathbf{K}_{**} + \mathbf{E}\sigma^2 \end{bmatrix}\right). \quad (10)$$

由高斯分布的多元特征可知, 输出值 y_* 分布仍服从高斯分布:

$$\begin{aligned} p(\mathbf{y}_* | \mathbf{y}) &= N(\boldsymbol{\eta}_*, \boldsymbol{\Sigma}_*) \\ \boldsymbol{\eta}_* &= \mathbf{K}_*^T \mathbf{H}^{-1} \mathbf{y} \\ \boldsymbol{\Sigma}_* &= \mathbf{K}_{**} - \mathbf{K}_*^T \mathbf{H}^{-1} \mathbf{K}_* + \mathbf{E}\sigma^2. \end{aligned} \quad (11)$$

当仅关心单测试样本 x_* 所对应的预测输出 y_* 时, 预测输出分布满足高斯分布态势:

$$\begin{aligned} p(y_* | \mathbf{X}, \mathbf{y}, x_*) &= N(\boldsymbol{\eta}_*, \boldsymbol{\sigma}_*) \\ \boldsymbol{\eta}_* &= \mathbf{k}_*^T \mathbf{H}^{-1} \mathbf{y} \\ \boldsymbol{\sigma}_*^2 &= \mathbf{k}_{**} - \mathbf{k}_*^T \mathbf{H}^{-1} \mathbf{K}_* \\ \mathbf{k}_* &= k(X, x_*) \\ \mathbf{k}_{**} &= k(x_*, x_*). \end{aligned} \quad (12)$$

需要得到公式(12)测试样本 x_* 的无噪输出结果, 但与公式(11)中的 $\boldsymbol{\Sigma}_* = \mathbf{K}_{**} - \mathbf{K}_*^T \mathbf{H}^{-1} \mathbf{K}_* + \mathbf{E}\sigma^2$ 相比公式(12)中的 $\boldsymbol{\sigma}_*^2 = \mathbf{k}_{**} - \mathbf{k}_*^T \mathbf{H}^{-1} \mathbf{K}_*$ 没有噪声方差, 上式中 $\boldsymbol{\mu}_*^2$ 没有噪声方差表示项, 为得到测试样本 x_* 所对应的无噪预测输出, 需将预测输出分布均值作为 x_* 的预测均值, 即:

$$\overline{y_*} = \boldsymbol{\eta}_* = \mathbf{k}_*^T \mathbf{H}^{-1} \mathbf{y}. \quad (13)$$

设 $\boldsymbol{\rho} = \mathbf{H}^{-1} \mathbf{y}$, 则测试样本 x_* 所对应的预测均值 $\overline{y_*}$ 为:

$$\begin{aligned} \overline{y_*} &= \boldsymbol{\eta}_* = \mathbf{k}_*^T \mathbf{H}^{-1} \mathbf{y} = \mathbf{k}_*^T \boldsymbol{\rho} = \\ &= \sum_{i=1}^M \boldsymbol{\rho}_i \mathbf{k}_*(x_i, x_*). \end{aligned} \quad (14)$$

2.3 高斯过程回归模型的参数学习

高斯过程回归模型中的未知参数 φ 需要借助训练样本数据进行学习求得。利用极大似然法对公式(9)进行参数预估:

$$\tau(\varphi) = -\ln p(\mathbf{y} | X, \varphi) =$$

$$\frac{1}{2} \ln |\mathbf{H}| + \frac{1}{2} \mathbf{y}^T \mathbf{H}^{-1} \mathbf{y} + \frac{M}{2} \ln(2\pi), \quad (15)$$

式中 $\mathbf{H} = \mathbf{K} + \mathbf{E}\sigma^2$, 为了学习最优参数 $\hat{\varphi}$, 对公式(15)进行极小化:

$$\hat{\varphi} = \underset{\varphi}{\operatorname{argmin}}(\tau(\varphi)). \quad (16)$$

对公式(15)中的参数 φ 求导:

$$\begin{aligned} \frac{\partial \tau(\varphi)}{\partial \varphi} &= \frac{1}{2} \frac{\partial}{\partial \varphi} (\ln |\mathbf{H}|) + \frac{1}{2} \mathbf{y}^T \frac{\partial}{\partial \varphi} (\mathbf{H}^{-1}) \mathbf{y} = \\ &= \frac{1}{2} \operatorname{tr} \left(\mathbf{H}^{-1} \frac{\partial \mathbf{K}}{\partial \varphi} \right) - \frac{1}{2} \mathbf{y}^T \mathbf{H}^{-1} \frac{\partial \mathbf{K}}{\partial \varphi} \mathbf{H}^{-1} \mathbf{y} = \\ &= \frac{1}{2} \operatorname{tr} \left[(\mathbf{H}^{-1} - \boldsymbol{\rho}^T \boldsymbol{\rho}) \frac{\partial \mathbf{K}}{\partial \varphi} \right], \end{aligned} \quad (17)$$

$$\frac{\partial \mathbf{K}}{\partial \varphi} = \left[\frac{\partial \mathbf{K}_{ij}}{\partial \varphi} \right]_{M \times M}. \quad (18)$$

这里所用核函数为高斯径向基核函数, 对公式(2)的参数 δ_f 和 h 求导:

$$\frac{\partial \mathbf{K}_{ij}}{\partial \delta_f} = 2\delta_f \exp\left(-\frac{\|x_i - x_j\|^2}{2h^2}\right), \quad (19)$$

$$\frac{\partial \mathbf{K}_{ij}}{\partial h} = \mathbf{k}(x_i, x_j) \frac{\|x_i - x_j\|^2}{h^3}. \quad (20)$$

对噪声参数 σ 进行求导:

$$\begin{aligned} \frac{\partial \tau}{\partial \sigma} &= \frac{1}{2} \operatorname{tr} \left[(\mathbf{H}^{-1} - \boldsymbol{\rho}^T \boldsymbol{\rho}) \frac{\partial \boldsymbol{\rho}}{\partial \sigma} \right] = \\ &= \sigma \operatorname{tr} (\mathbf{H}^{-1} - \boldsymbol{\rho}^T \boldsymbol{\rho}). \end{aligned} \quad (21)$$

式(17)~式(21)为各参数求导公式, 后续可利用共轭梯度法优化得到模型中的参数值。

3 高斯过程回归模型的改进

高斯过程回归模型中对超参数的求解是利用极大似然法, 而每次梯度计算都需要对协方差矩阵 $\mathbf{K} + \mathbf{E}\sigma^2$ 进行求逆, 计算量为 $O(n^3) \times$ 计算梯度次数, 若训练数据集比较大时, 高斯过程回归的计算量庞大, 这严重制约了高斯过程回归模型的应用。为此, 本文从两个方面来降低高斯过程回归模型参数求解的计算量。

3.1 子集的最大方差近似法

在降低高斯过程回归计算量的方法中, 通过特定的方法选取训练子集是最有效最直接的方法。本文以最大方差为指标选取测试样本的子集。方差是评价随机变量与其数学期望的偏离, 那么测试样本的方差为:

$$S^2 = \frac{1}{M} [(x_1 - \bar{x})^2 + \dots + (x_M - \bar{x})^2], \quad (22)$$

其中 \bar{x} 为测试样本的均值。

方差平和为:

$$S_2^2 = \max \left[\frac{1}{\operatorname{Num}} \sum_{i=1}^{\operatorname{Num}} (x_i - \bar{x})^2 \right]. \quad (23)$$

基于最大方差的子集选择流程:

Step1: 获取测试样本和子集的大小;

Step2: 计算测试样本 X_* 的均值;

Step3: 计算每个样本数据与测试样本均值差的平方;

Step4: 对差值平方进行排序, 选择最大的 Num 个样本, 返回所选定的子集。

3.2 平方根矩阵分解法更新模型

在实际的图像分类过程中, 不断会有新的标记样本加入, 若采用更新后的测试样本子集对模型进行训练, 这不仅会增加计算量还会降低模型更新的效率。本文为了提高训练模型的效率, 降低计算量, 采用平方根矩阵分解法对新标记样本进行模型预测结果。

根据公式(13)和公式(15)对协方差矩阵 $\mathbf{K} + \mathbf{E}\sigma^2$ 进行求逆的运算复杂度为 $O(\operatorname{Num}^3)$, 随着新样本的加入, 若需要重新利用更新后的样本子集进行模型重新训练, 计算量也是比较大的, 而平方根矩阵分解法是把一个对称正定矩阵表示成一个下三角矩阵及其转置的乘积。该方法实现简单, 分解快速, 可利用数学运算的优势实现快速模型更新。设下三角矩阵为 \mathbf{L} , 可将协方差矩阵 $\mathbf{H} = \mathbf{K} + \mathbf{E}\sigma^2$ 进行分解:

$$\mathbf{H} = \mathbf{K} + \mathbf{E}\sigma^2 = \mathbf{L}^T \mathbf{L}, \quad (24)$$

对公式(17)中的中间项 $\boldsymbol{\rho} = \mathbf{H}^{-1} \mathbf{y}$ 进行求解, 可得:

$$\boldsymbol{\rho} = \mathbf{H}^{-1} \mathbf{y} = (\mathbf{L}^T \mathbf{L})^{-1} \mathbf{y} = \mathbf{L}^{-1} (\mathbf{L}^T)^{-1} \mathbf{y}. \quad (25)$$

假设当前训练模型的子集为 $D_{\operatorname{Num}} = \{X_{\operatorname{Num}}, y_{\operatorname{Num}}\}$, 当有 m' 个新标记样本加入到训练子集后新训练集合为 $D_{\operatorname{New}} = \{X_{\operatorname{Num}}, X_{m'}, y_{\operatorname{Num}}, \dots, y_{m'}\}$, $X' = \{X_{\operatorname{Num}}, \dots, X_{m'}\}$, $y' = \{y_{\operatorname{Num}}, \dots, y_{m'}\}$, \mathbf{k}_* 表示新训练集合 X' 同 x_* 的协方差矩阵, 根据公式(13)新加入的标记样本的预测输出为:

$$\bar{y}_* = \boldsymbol{\eta}_* = \mathbf{k}_*^T \boldsymbol{\rho} = \mathbf{k}_*^T \mathbf{Q}^{-1} \mathbf{y}, \quad (26)$$

$$\begin{aligned} \mathbf{Q} &= \mathbf{k}(X', X') + \mathbf{E}\sigma^2 = \begin{bmatrix} \mathbf{H} & \mathbf{P} \\ \mathbf{P}^T & \tilde{\boldsymbol{\omega}} + \mathbf{E}\sigma^2 \end{bmatrix} \\ \mathbf{P} &= \mathbf{k}(X_{\operatorname{Num}}, X_{m'}) \\ \tilde{\boldsymbol{\omega}} &= \mathbf{k}(X_{m'}, X_{m'}). \end{aligned} \quad (27)$$

根据公式(25), 若想得到新加入标记样本的

预测输出就需要对公式(27)的中间项 Q 求逆,而每次求逆计算复杂度很大,在这里文章利用平方根矩阵分解法对 Q 分解。设 Q 的平方根矩阵分解形式为 $Q=L_Q^T L_Q$,那么对 Q 的分解如下:

$$Q = L_Q^T L_Q = \begin{bmatrix} \mathbf{R} & \mathbf{S} \\ 0 & \mathbf{c} \end{bmatrix}^T \begin{bmatrix} \mathbf{R} & \mathbf{S} \\ 0 & \mathbf{c} \end{bmatrix} = \begin{bmatrix} \mathbf{R}^T \mathbf{R} & \mathbf{R}^T \mathbf{S} \\ \mathbf{S}^T \mathbf{R} & \mathbf{S}^T \mathbf{S} + \mathbf{c}^T \mathbf{c} \end{bmatrix}. \quad (28)$$

结合式(27)和式(28),可得:

$$\mathbf{H} = \mathbf{R}^T \mathbf{R}, \quad (29)$$

$$\mathbf{P} = \mathbf{R}^T \mathbf{S}, \quad (30)$$

$$\tilde{\omega} + \mathbf{E}\sigma^2 = \mathbf{S}^T \mathbf{S} + \mathbf{c}^T \mathbf{c}. \quad (31)$$

结合式(24)和式(29)可得:

$$\mathbf{H} = \mathbf{K} + \mathbf{E}\sigma^2 = \mathbf{L}^T \mathbf{L} = \mathbf{R}^T \mathbf{R}. \quad (32)$$

根据平方根矩阵分解的唯一性,可以得出 $\mathbf{L} = \mathbf{R}$,由此式(30)和式(31)转化:

$$\mathbf{S} = (\mathbf{R}^T)^{-1} \mathbf{P}, \quad (33)$$

$$\mathbf{c}^T \mathbf{c} = \tilde{\omega} + \mathbf{E}\sigma^2 - \mathbf{S}^T \mathbf{S}. \quad (34)$$

根据新标记样本加入数量 m' 不同,可得:

$$\mathbf{c} = \begin{cases} \text{chol}(\tilde{\omega} + \mathbf{E}\sigma^2 - \mathbf{S}^T \mathbf{S}), & m' > 1 \\ \sqrt{\tilde{\omega} + \mathbf{E}\sigma^2 - \mathbf{S}^T \mathbf{S}}, & m' = 1 \end{cases}. \quad (35)$$

通过以上分解过程可知,式(27) Q 的分解 L_Q 可根据式(24) H 的分解间接获得。由此可根据式(26)获得新加入标记样本的预测输出值。这样利用平方根矩阵分解间接得到新标记样本的预测输出,规避了直接对矩阵 Q 求逆,将 $(Num + m') \times (Num + m')$ 的矩阵分解降低为 $m' \times m'$ 的矩阵分解外加式(33)和式(34)的矩阵乘操作。

4 融合光谱信息的高斯过程回归

基于高斯过程回归的分类其实就是把二分类问题当成回归问题,二分类中类别值 $y_i \in \{1, -1\}$ 。利用高斯过程回归对高光谱图像分类的流程为:

Step1:将二分类中类别值 $y_i \in \{1, -1\}$ 作为测试样本子集的回归响应;

Step2:若有新标记样本加入测试子集,根据式(11)得到新样本的回归数值 η_* ;

Step3:根据回归数值 μ_* 按照式(33)判断样本类别 y_* ;

$$y_* = \text{sign}(\eta_*) = \begin{cases} 1, & \eta_* > 0 \\ -1, & \eta_* < 0 \end{cases}. \quad (36)$$

虽然基于高斯过程回归的分类简单,但模型分类过程中只用到了图像的光谱信息,其实并没有将像素邻域的空间关系考虑进去。而高光谱图像的采集过程中,某像素点周围往往集中体现的是同类地物,这在空间信息上呈现出一定的连续性,如果在分类过程中将像素的邻域空间信息加以利用,可以有效消除“麻点”,降低噪声对分类结果的影响。

4.1 融合空谱关联信息

在第 i 个位置上的像元 $p_i(u_i, v_i)$ 对应的回归数值修正为 $\bar{\eta}_i$:

$$\bar{\eta}_i = \eta_i + \lambda \sum_{j \in \Omega(p_i)} \Delta(y_j, y_i) = \sum_{j=1}^M \rho_i k(x_i, x_j) + \lambda \sum_{j \in \Omega(p_i)} \Delta(y_j, y_i), \quad (37)$$

其中: $\Omega(p_i)$ 为像素 $p_i(u_i, v_i)$ 为中心大小为 $s \times s$ 的近邻空间, (u_i, v_i) 为像元 p_i 在高光谱图像中的行列。近邻空间 $\Omega(p_i)$ 定义为:

$$\Omega(p_i) = \{p_u(u_i, v_i) \mid u_i \in [u_i - r, u_i + r], v_i \in [v_i - r, v_i + r]\}, \quad (38)$$

其中: $r = \frac{s-1}{2}$, $p_u(u_i, v_i)$ 为近邻空间 $\Omega(p_i)$ 第 t 位置像元,而近邻空间 $\Omega(p_i)$ 周围有 s^2 个。在式(39)中 $\Delta(y_j, y_i)$ 的计算如下:

$$\Delta(y_j, y_i) = \begin{cases} 1 & y_j = y_i \\ -1 & y_j \neq y_i \end{cases}. \quad (39)$$

而对于式(37)中的权值 λ ,其是用来权衡邻域位置其他像元与中心一致性的,当邻域像元与中心像元地物一致性大时,权值 λ 就大,对回归数值修正 $\bar{\eta}_i$ 的反馈施加正影响,反之亦然。因不同邻域位置对中心像元的约束不一,这里将式(37)改进为:

$$\bar{\eta}_i = \sum_{j=1}^M \rho_i k(x_i, x_j) + \lambda_{ij} \sum_{j \in \Omega(p_i)} \Delta(y_j, y_i). \quad (40)$$

利用式(40)中的 λ_{ij} 来度量邻域中 p_j 对中心像元 p_i 的空间约束大小。根据高光谱图像地物分布空间一致规律,本文利用中心像元 $p_i(u_i, v_i)$ 与近邻空间 $\Omega(p_i)$ 中像元的距离来度量邻域内像元的数据间相似性,设像素 p_i, p_j 间的空谱关联距离为 d_{ss} :

$$d_{ss_{ij}} = \min\{d(p_i, \Omega(p_j)), d(p_j, \Omega(p_i))\}, \quad (41)$$

其中: $d(p_i, \Omega(p_j))$ 表示像元 p_i 到像元 p_j 近邻空间 $\Omega(p_j)$ 的距离:

$$d(p_i, \Omega(p_j)) = \frac{\sum_{t=1}^{s^2} \omega_{jt} \ || p_i - p_{jt} \ ||}{\sum_{t=1}^{s^2} \omega_{jt}},$$

$$p_{jt} \in \Omega(p_j), \quad (42)$$

其中: ω_{jt} 为近邻空间 $\Omega(p_j)$ 中像元 p_{jt} 所占 $s \times s$ 近邻空间的权重,利用高斯径向基核函数计算如下:

$$\omega_{jt} = \exp\{-|| p_j - p_{jt} ||^2 / 2h^2\}. \quad (43)$$

这里设水平尺度参数 $h=0.1$ 。从式(41)和式(42)可以看出,空谱关联距离将像元的空间邻近信息融入距离计算中,这种相似性度量更能贴近光谱图像的地物一致性,有效弥补欧式距离仅通过单像元计算相似性度量的弊端。由于空谱关联距离为 d_{ssij} 为正数,距离越小对应的 λ_{ij} 越大,所以设 $\lambda_{ij} = 1/d_{ssij}$ 。

4.2 OAO 多类别分类算法

针对分类任务中含有多于两类的情况,可以区分二分类问题为基础构造多分类任务算法。常用的多分类算法有“一对一”(One Against One, OAO)、“多对一”(One Against All, OAA)等。假设分类个数为 G ,以下给出一对一和多对一多类别分类算法。

OAO 多类别分类算法思想是将每两个类别构造成二分类的模式。对于类别个数为 G 的 OAO 多类别分类算法中共需 $G(G-1)/2$ 个分类器 $\{C_{ij} | i, j \in 1, 2, \dots, G; i \neq j\}$ 。二分类器 C_{ij} 都需要从所有类别中选择类别组合 $\{i, j\}$ 以此作为正负样本。若二类别 C_{ij} 判定 x_* 属于正样本则将类别 i 的计数 $V_i + 1$, 否则 x_* 属于负样本。则将类别 i 的计数 $V_j + 1$ 。经多次分类,测试样本类别 y_* :

$$y_* = \operatorname{argmax}_{i=1,2,\dots,G} V_i. \quad (44)$$

4.3 OAA 多类别分类算法

OAA 多类别分类算法思想是将每个类别构造成二分类的模式。对于类别个数为 G 的 OAO 多类别分类算法中共需 G 个分类器 $\{C_i | i \in 1, 2, \dots, G\}$ 。 C_i 将样本 i 作为正样本,其他类别为负样本。样本 x_* 经分类器 C_i 判定后输出结果为 $\eta(x_* | C_i)$, 经多次分类,测试样本的类别 y_* :

$$y_* = \operatorname{argmax}_{i=1,2,\dots,G} \eta(x_* | C_i). \quad (45)$$

由于篇幅限制,这里仅给出关联空谱信息的改进高斯过程回归的 OAA 分类流程(Associated Space Spectrum Improved Gaussian Process Regression-OAA, AS²IGPR-OAA):

设分类高光谱图像 X_P , 训练集合 D_T , 类别数为 $G, g=1$ 。

Step1: 设类别个数 $g=1$;

Step2: 根据式(22), 式(23)最大方差近似法选取训练子集 D'_T ;

Step3: 根据式(15)在训练子集 D'_T 上优化得到二分类高斯回归模型中的参数 φ ;

Step4: $g++$, 若 $g \leq G$, 执行 Step2, 否则设 $i=0$, 执行 Step5;

Step5: $i++$, 取高光谱图像 X_P 中的像元 $x_i, g=1$;

Step6: 根据式(12)计算每个测试样本 x_i 的回归输出 $\eta(x_i), g++$;

Step7: 若 $g \leq G$, 执行 Step7, 否则执行 Step8;

Step8: 根据式(45)得到像元 x_i 对应的初始类别 y_i , 判断高光谱图像 X_P 是否取尽所有像元, 若是 $i=0$; 执行 Step9, 否则执行 Step5;

Step9: $i++$, 取像元 x_i 对应的初始类别 $y_i, g=1$;

Step10: 根据式(41)~式(43)得到关联空谱信息的权值 λ_{ij} ;

Step11: 根据式(37)得到修正后的像元 x_i 的预测值 $\bar{\eta}_i$;

Step11: 若 $g \leq G$, 执行 Step9, 否则执行 Step12;

Step12: 判断高光谱图像 X_P 中像元 x_i 对应的初始类别 y_i 是否修正完, 若是执行下一步, 否则执行 Step9;

Step13: 根据式(45)得到所有像元对应的类别 \bar{y}_i 。

5 实验仿真与结果分析

为了验证本文分类算法的有效性和优越性, 在 Indian Pines 和 Pavia University 两组高光谱数据集上仿真实验。Indian Pines 高光谱遥感图像由 AVIRIS 传感器收集, 空间分辨率为 20 m, 大小为 145 pixel \times 145 pixel, 包含 220 个波段, 地

物样本 10 366 个,其中样本数据集相似度极高,区域内样本分布不均衡。Pavia University 高光谱遥感图像由 ROSIS 传感器收集,空间分辨率为 1.3 m,大小为 340 pixel \times 610 pixel,包含 115 个波段,地物样本 42 776 个,其中 12 个波段受水吸影响,只使用 103 个波段进行仿真实验。

从每类地物中随机选择固定比例的像元作为训练集,将 10 次重复试验平均值作为各算法的分类精度。硬件环境为 Intel(R) Core(TM) i7-7700U@3.6 GHz, RAM: 8 GB, 软件环境为: Matlab R2014a。使用总体分类精度(Overall Accuracy, OA)、平均分类精度(Average Accuracy, AA)和 Kappa 系数等指标为评价标准。

5.1 算法有效性实验

为了验证本文算法的有效性,将原高斯过程回归-OAA 方法(GPR-OAA)、高斯过程回归-OAO 方法(GPR-OAO)、本文改进算法-OAA 方法(AS²IGPR-OAA)、本文改进算法-OAO 方法(AS²IGPR-OAO)以及文献[20]、文献[21]进行高光谱分类。高斯回归过程采用含噪模式,其中包含三个未知参数 $\varphi=[\delta_f, h, \sigma]$ 利用式(15)极大似然法求得。文献[21]中的 SVM 分类器也使用高斯径向基核函数,其参数经五折交叉验证获得。两幅高光谱图像中,在每个类别中选 100 个样本组成训练集,其余为测试集。表 1 为各算法在 Indian Pines 高光谱图像上分类对比结果。

表 1 各算法在 Indian Pines 高光谱图像上的分类对比

Tab.1 Classification and comparison of algorithms on Indian Pineshyperspectral imagery

	GPR-OAA	GPR-OAO	AS ² IGPR-OAA	AS ² IGPR-OAO	文献[20]	文献[21]
C ₁	57.98	70.14	71.58	77.12	75.94	64.92
C ₂	71.99	73.11	81.02	79.08	84.87	75.82
C ₃	90.91	93.21	95.09	95.58	91.76	87.29
C ₄	85.06	82.98	95.02	90.14	87.96	80.17
C ₅	79.13	78.09	92.16	88.11	91.17	81.56
C ₆	95.26	95.11	98.94	98.57	97.24	93.81
C ₇	89.07	88.81	97.37	96.41	95.05	85.68
C ₈	93.98	93.05	96.98	94.83	95.76	92.26
C ₉	99.02	98.75	99.58	99.18	98.84	97.57
C ₁₀	80.42	73.78	94.13	88.29	90.34	79.64
OA	78.13	81.16	88.12	87.26	85.93	79.49
AA	84.28	84.71	92.19	90.73	90.89	83.87
Kappa	0.752	0.806	0.852	0.849	0.843	0.758

从上表数据我们可知,改进后的高斯过程回归分类方法(AS²IGPR-OAA, AS²IGPR-OAO)整体上比原高斯过程回归分类方法(GPR-OAA, GPR-OAO)有很大提升,10 个类别的分类精度上都处于绝对优势,总体分类精度、平均分类精度和 Kappa 系数等评价指标也是优于未改进前的方法,说明将空谱关联信息融合到高斯过程回归模型后,有效消除“麻点”噪声对分类结果的影响,增大了中心像元地物一致的正影响,最终提高了分

类精度;本文改进后的高斯过程回归多分类方法中,OAA 多类别分类方法要明显优于 OAO 多类别分类方法,10 个类别的分类中 9 个类别取得了较为明显的分类精度优势;AS²IGPR-OAA 在 10 个类别中有 7 个的分类精度优于文献[20],[21],同时 AS²IGPR-OAA 评价指标 OA=88.12%, AA=91.29%, Kappa=0.852 相比文献[20],[21]分别至少提高了 2.55%,1.43%和 1.07%。各算法对 Indian Pines 高光谱图像分类结果如下:

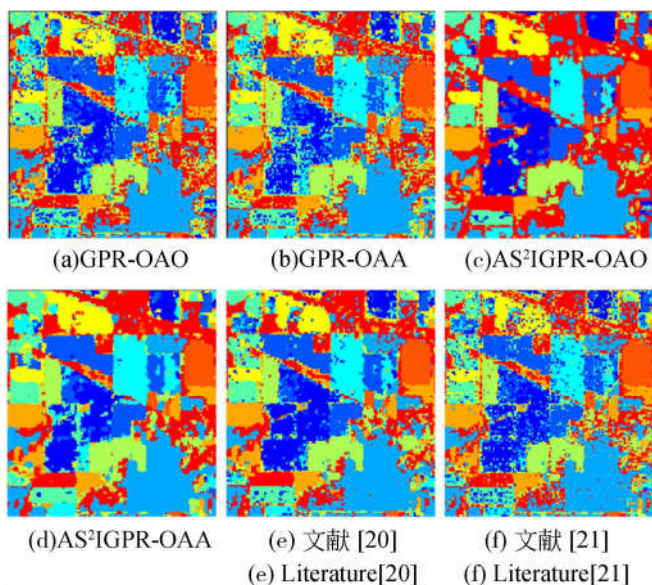


图 1 各算法对 Indian Pines 高光谱图像分类结果
Fig. 1 Classification results of Indian Pines hyperspectral image by each algorithm

通过各算法对 Indian Pines 高光谱图像的分类结果可以看出,改进后的分类方法(AS²IGPR-OAA, AS²IGPR-OAO)与不融合空谱信息的高斯过程回归分类方法(GPR-OAA, GPR-OAO)、文献[21]相比,分类结果中都含有较多的噪点,分类区域边缘不够清晰。AS²IGPR-OAA 分类结果较文献[20]更为准确,特别对于光谱特性较为相似的区域,空谱联合信息的加入反馈修正分类结果,使相似地物信息被有效的甄别。各算法在 Pavia University 高光谱图像上的分类对比如下表 2 所示。

从表 2 数据可知,改进后的高斯过程回归分类方法(AS²IGPR-OAA, AS²IGPR-OAO)的分类精确率也是整体上优于原高斯过程回归分类方法(GPR-OAA, GPR-OAO),说明将空谱关联信息的融入一定程度上抑制了噪声对分类的负影响,

表 2 各算法在 Pavia University 高光谱图像分类对比

Tab. 2 Classification and comparison of algorithms on Pavia University hyperspectral imagery

	GPR-OAA	GPR-OAO	AS ² IGPR-OAA	AS ² IGPR-OAO	文献[20]	文献[21]
C ₁	75.14	79.83	84.81	86.21	85.39	73.66
C ₂	86.92	85.67	92.53	90.07	88.76	84.73
C ₃	86.57	84.96	92.44	91.16	87.92	83.19
C ₄	94.91	96.12	97.39	96.64	97.42	93.84
C ₅	99.28	99.48	99.82	99.65	99.58	99.17
C ₆	87.89	90.11	95.28	94.63	94.84	87.44
C ₇	95.64	93.05	98.78	96.76	97.21	94.38
C ₈	82.99	85.01	91.37	90.85	89.95	83.92
C ₉	99.16	99.74	99.89	99.77	99.56	99.45
OA	86.36	86.79	92.39	91.12	90.32	84.22
AA	89.83	90.44	94.70	93.97	93.39	88.86
Kappa	0.798	0.832	0.913	0.889	0.897	0.786

分类精度得到了较大改善;同时 AS²IGPR-OAA 在 9 个类别中有 7 个的分类精度高于文献[20],其中评价指标 OA=92.39%, AA=94.7%, Kappa=0.903 相比文献[20],[21]分别至少提高了 2.3%, 1.4% 和 1.78%。各算法对 Pavia University 高光谱图像的分类如下图 2,结果与表 2 数据是相符的。

5.2 模型改进性能分析

高斯过程回归模型中对超参数的求解是采用极大似然法,理论上高斯过程回归的计算量是庞大,严重影响了高斯过程模型的应用。本文从最大方差选取测试子集和平方根矩阵分解法对新标记样本进行模型预测结果。为了评估模型改进后的性能,将 Indian Pines 和 Pavia University 两组




图 2 各算法对 Pavia University 高光谱图像分类结果
Fig.2 Classification results of Pavia University-hyperspectral image by each algorithm

高光谱样本数据分为三部分:训练集合 D_T 、候选集合 D_H 和测试集合 D_M 。在两组数据上采用大小不一的样本对模型进行训练。每类别选取 40, 80, 120, 160, 200 个样本作为训练集, 剩余样本被等分成候选集和测试集。对于含有 10 个类别的 Indian Pines 高光谱样本数据, 训练集合样本就达

2 000 个, 若从候选集中随机选择一定量的样本加入训练集, 模板重新训练的计算成本很大。下图 3 为每类别不同样本训练数下各算法分类标准对比。

图 3 中(a), 图 3(c), 图 3(e)为各算法在 Indian Pines 高光谱数据集上的分类对比结果, 如图 3 (b), 图 3(d), 图 3(f)为各算法在 Pavia University 高光谱数据集上的分类标准对比结果, 改进后的高斯过程回归分类方法的总体分类精度、平均分类精度和 Kappa 系数等分类指标整体上优于原高斯过程回归分类方法。为了验证在训练样本中新添加样本对分类算法分类精度和运算时间的影响, 文章从 Indian Pines 候选集合 D_H 中每次

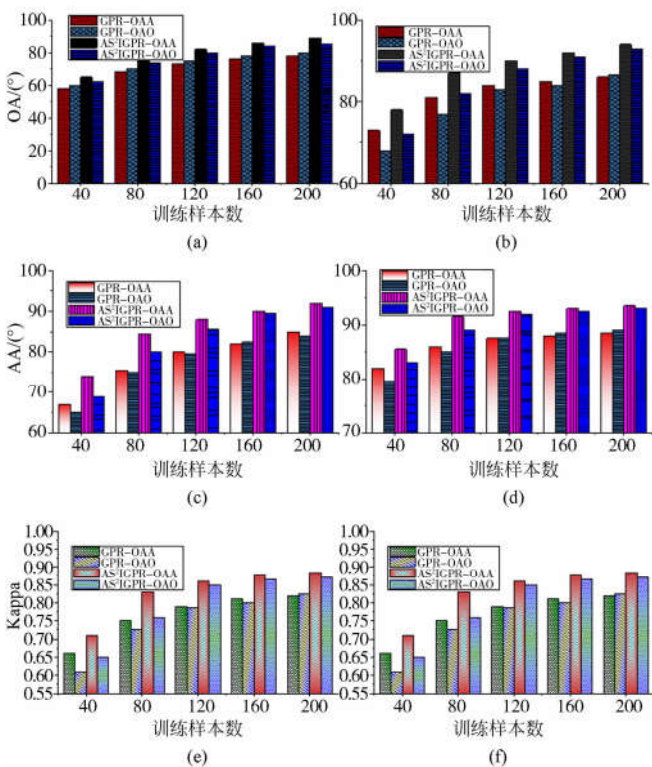


图 3 不同样本数下各算法分类结果

Fig.3 Classification results of algorithms under different sample numbers

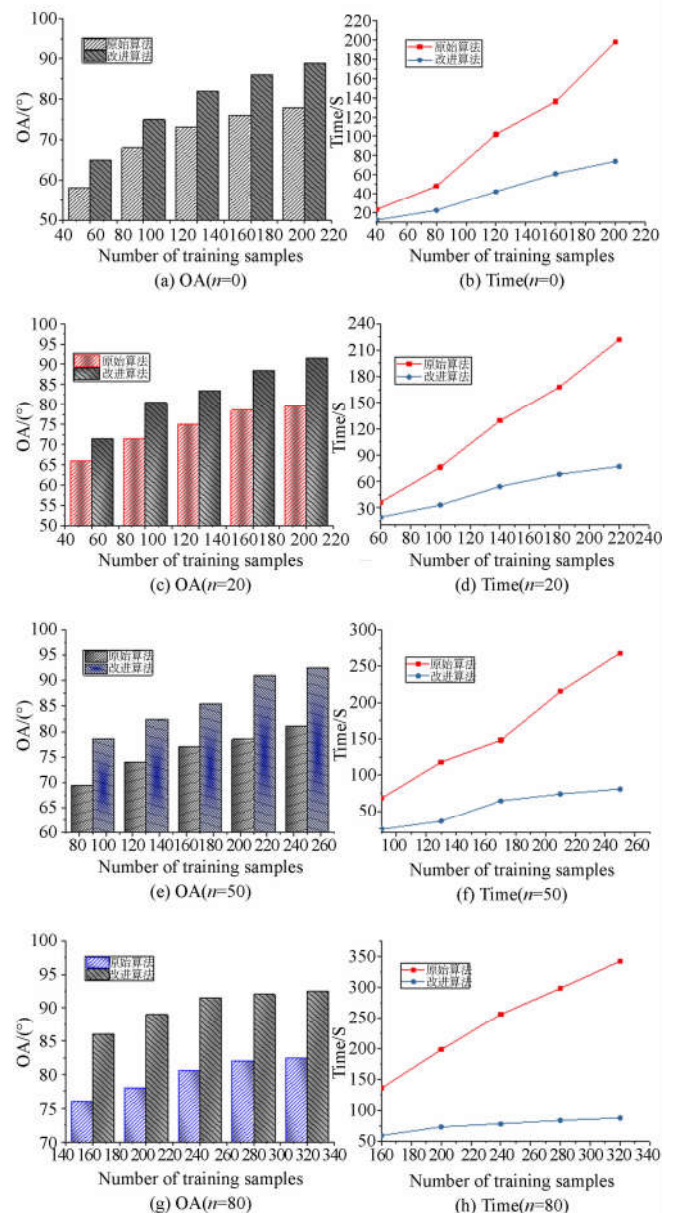


图 4 算法改进前后在 Indian Pines 数据集上的评估结果

Fig.4 Evaluation results on the Indian Pines dataset before and after algorithm improvement

随机选择 $n=20, 50, 80$ 的样本添加到训练集合 D_T 中。选择 $AS^2IGPR-OAA$ 代表改进算法, $GPR-OAA$ 代表原始算法对比分析两类算法的总体分类正确率和运行时间如下图 4 所示。

图 4(a), 图 4(c), 图 4(e), 图 4(g) 为样本添加数 $n=0, 20, 50, 80$ 情况下两种代表算法在 Indian Pines 高光谱图像数据集上的总体分类正确率(OA), 随着样本添加数的不断增加, 模型改进前后算法对高光谱图像的分类总体正确率是不断提高的, 但当样本数达到 250 左右, 两种代表算法的正确率提升的幅度有所放缓, 分类精度趋于平稳; 图 4(b), 图 4(d), 图 4(f), 图 4(h) 为样本添加数 $n=0, 20, 50, 80$ 情况下两种代表算法在 Indian Pines 高光谱图像数据集上的运行时间, 随着样本添加数的不断增大, 原始模型算法需要重新采用更新后的训练样本对模型进行训练, 运算时间大幅增加, 而改进后的模型算法通过最大方差

近似法选取子集, 并采用平方根矩阵分解法对新添加样本进行模型预测结果, 大大缩减了运行时间。

6 结 论

本文提出了一种基于改进高斯过程回归的高光谱空谱联合分类算法, 算法首先通过缩小训练样本集合和平方根矩阵分解法更新模型两个方面对高斯过程回归计算量较大的弊端进行了改进, 重新定义邻域像元空-谱关联距离, 将融入空间邻近信息的空-谱关联距离作为权值来度量邻域像元的相似性, 加大同类地物的归类概率, 整体上提高了图像的分类精度。仿真结果表明, 本文改进的模型算法不仅有效提高了分类精度还大幅度缩减了运行时间。

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]. 遥感学报, 2016, 20(2): 236-256. DU P J, XIA J S, XUE ZH H, *et al.*. Review of hyperspectral remote sensing image classification [J]. *Journal of Remote Sensing*, 2016, 20(2): 236-256. (in Chinese)
- [2] 黄鸿, 陈美利, 段宇乐, 等. 空-谱协同流形重构的高光谱影像分类[J]. 光学 精密工程, 2018, 26(7): 1827-1836. HUANG H, CHEN M L, DUAN Y L, *et al.*. Hyper-spectral image classification using spatial-spectral manifold reconstruction[J]. *Opt. Precision Eng.*, 2018, 26(7): 1827-1836. (in Chinese)
- [3] 王庆超, 付光远, 汪洪桥, 等. 多核融合多尺度特征的高光谱影像地物分类[J]. 光学 精密工程, 2018, 26(4): 980-988. WANG Q CH, FU G Y, WANG H Q, *et al.*. Fusion of multi-scale feature using multiple kernel learning for hyperspectral image land cover classification[J]. *Opt. Precision Eng.*, 2018, 26(4): 980-988. (in Chinese)
- [4] 张春森, 郑艺惟, 黄小兵, 等. 高光谱影像光谱-空间多特征加权概率融合分类[J]. 测绘学报, 2015, 44(8): 909-918. ZHANG CH S, ZHENG Y W, HUANG X B, *et al.*. Hyperspectral image classification based on the weighted probabilistic fusion of multiple spectral-spatial features [J]. *Acta Geodaetica Et Cartographica Sinica*, 2015, 44(8): 909-918. (in Chinese)
- [5] 孙乐, 吴泽彬, 冯灿, 等. 一种新的两分类器融合的空谱联合高光谱分类方法[J]. 电子学报, 2015, 43(11): 2210-2217. SUN L, WU Z B, FENG C, *et al.*. A novel two-classifier fusion method for spectral-spatial hyperspectral classification[J]. *Acta Electronica Sinica*, 2015, 43(11): 2210-2217. (in Chinese)
- [6] 王彩玲, 王洪伟, 胡炳樑, 等. 基于邻域分割的空谱联合稀疏表示高光谱图像分类技术研究[J]. 光谱学与光谱分析, 2016, 36(9): 2919-2924. WANG C L, WANG H W, HU B L, *et al.*. A novel spatial-spectral sparse representation for hyperspectral image classification based on neighborhood segmentation[J]. *Spectroscopy and Spectral Analysis*, 2016, 36(9): 2919-2924. (in Chinese)
- [7] 张成坤, 韩敏. 基于边缘保持滤波的高光谱影像光谱-空间联合分类[J]. 自动化学报, 2018, 44(2): 280-288.

- ZHANG CH K, HAN M. Spectral-spatial joint classification of hyperspectral image with edge-preserving filtering [J]. *Acta Automatica Sinica*, 2018, 44(2): 280-288. (in Chinese)
- [8] 侯榜煊,姚敏立,贾维敏,等. 面向高光谱图像分类的空谱判别分析[J]. *光学精密工程*, 2018, 26(2): 450-460.
- HOU B H, YAO M L, JIA W M, *et al.*. Spatial-spectral discriminant analysis for hyperspectral image classification[J]. *Opt. Precision Eng.*, 2018, 26(2): 450-460. (in Chinese)
- [9] 吕飞,韩敏. 基于深度极限学习机的高光谱遥感影像分类研究[J]. *大连理工大学学报*, 2018, 58(2): 166-173.
- LV F, HAN M. Hyperspectral remote sensing image classification based on deep extreme learning machine [J]. *Journal of Dalian University of Technology*, 2018, 58(2): 166-173. (in Chinese)
- [10] 张康,黑保琴,周壮,等. 变异系数降维的 CNN 高光谱遥感图像分类[J]. *遥感学报*, 2018, 22(1): 87-96.
- ZHANG K, HEI B Q, ZHOU ZH, *et al.*. CNN with coefficient of variation-based dimensionality reduction for hyperspectral remote sensing images classification [J]. *Journal of Remote Sensing*, 2018, 22(1): 87-96. (in Chinese)
- [11] 赵振凯,杨明. 结合分水岭分割的合成核 SVM 高光谱分类[J]. *数据采集与处理*, 2018, 33(1): 132-143.
- ZHAO ZH K, YANG M. Combining watershed segmentation with composite-kernels for hyperspectral image classification[J]. *Journal of Data Acquisition and Processing*, 2018, 33(1): 132-143. (in Chinese)
- [12] 宋相法,曹志伟,郑逢斌,等. 基于随机子空间核极端学习机集成的高光谱遥感图像分类[J]. *计算机科学*, 2016, 43(3): 301-304.
- SONG X F, CAO Z W, ZHENG F B, *et al.*. Classification of hyperspectral remote sensing image based on random subspace and kernel extreme learning machine ensemble[J]. *Computer Science*, 2016, 43(3): 301-304. (in Chinese)
- [13] LIU Y, LI J, PLAZA A. Spectrometer-driven spectral partitioning for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(2): 668-680.
- [14] YOUNES O, THOMAS N. A Path Connection Availability Model for MANETs with Random Waypoint Mobility [M] *Computer Performance Engineering*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013: 111-126.
- [15] BARRETT J E, COOLEN A C C. Covariate dimension reduction for survival data via the Gaussian process latent variable model[J]. *Statistics in Medicine*, 2016, 35(8): 1340-1353.
- [16] SRIJITH P K, SHEVADE S. *Gaussian Process Multi-Task Learning using Joint Feature Selection*[M] *Machine Learning and Knowledge Discovery in Databases*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014: 98-113.
- [17] VERRELST J, ALONSO L, RIVERA CAICEDO J P, *et al.*. Gaussian process retrieval of chlorophyll content from imaging spectroscopy data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2): 867-874.
- [18] LAZARO-GREDILLA M, TITSIAS M K, VERRELST J, *et al.*. Retrieval of biophysical parameters with heteroscedastic Gaussian processes[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(4): 838-842.
- [19] MURPHY R J, CHLINGARYAN A, MELKUMYAN A. Gaussian processes for estimating wavelength position of the ferric iron crystal field feature at ~ 900 nm from hyperspectral imagery acquired in the short-wave infrared (1002-1355 nm)[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(4): 1907-1920.
- [20] 黄鸿,郑新磊. 高光谱影像空-谱协同嵌入的地物分类算法[J]. *测绘学报*, 2016, 45(8): 964-972.
- HUANG H, ZHENG X L. Hyperspectral image land cover classification algorithm based on spatial-spectral coordination embedding [J]. *Acta Geodaetica Et Cartographica Sinica*, 2016, 45(8):

964-972. (in Chinese)

- [21] LI C H, KUO B C, LIN C T, *et al.*. A spatial-contextual support vector machine for remotely

sensed image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3): 784-799.

作者简介:



陈 静(1981—),女,汉族,山东滕州人,讲师,2008年于辽宁工程技术大学获得硕士学位。主要研究方向:遥感图像处理与地理信息系统应用。E-mail: chenjing981@sina.com



张 静(1982—),女,汉族,辽宁阜新人,讲师,2008年于辽宁工程技术大学获得硕士学位,2016年于长安大学获得博士学位。主要研究方向:测量数据处理与遥感技术。E-mail: zhangjingfly_82@sina.com