

# 基于判别信息的复合核极限学习机算法

马斯宇, 刘德山, 闫德勤, 丁一民

(辽宁师范大学计算机与信息技术学院, 辽宁 大连 116081)

✉MasiyuV@163.com; deshanliu@yeah.net; yandeqin@163.com; 18340817981@163.com



**摘要:** 高光谱图像包含光谱和空间信息, 这增加了其在分类与识别方面的难度。特征学习作为高光谱图像分类技术之一, 能较好地提取图像中包含的特征。针对经典极限学习机算法难以较好地提取光谱特征, 引入特征学习技术, 提出了一种基于判别信息的复合核极限学习机(CKELM-L)方法。CKELM-L通过最大化类间矩阵与最小化类内矩阵, 使投影后的低维数据同类越近而异类越远。实验结果表明, 所提方法保留了更好的光谱特征, 计算复杂度低且实现了出色的可分离性。

**关键词:** 极限学习机; 高光谱图像分类; 线性判别分析; 特征学习

**中图分类号:** TP391 **文献标识码:** A

## Composite Kernel Extreme Learning Machine Algorithm based on Discriminant Information

MA Siyu, LIU Deshan, YAN Deqin, DING Yimin

(School of Computer and Information Technology, Liaoning Normal University, Dalian 116081, China)

✉MasiyuV@163.com; deshanliu@yeah.net; yandeqin@163.com; 18340817981@163.com

**Abstract:** Hyperspectral images contain spectral and spatial information, which increases the difficulty of classification and recognition. Feature learning, as one of the hyperspectral image classification techniques, can better extract features contained in the image. Aiming at the difficulty of classical extreme learning machine algorithms in extracting spectral features, this paper introduced feature learning technology, and proposes a composite kernel extreme learning machine (CKELM-L) method based on discriminant information. CKELM-L maximizes the between-class matrix and minimizes the intra-class matrix, so that the projected low-dimensional data is closer to the same class and farther away from the different class. Experimental results show that the proposed method retains better spectral features, low computational complexity and achieves excellent separability.

**Keywords:** extreme learning machine; hyperspectral image classification; linear discriminant analysis; feature learning

### 1 引言(Introduction)

高光谱图像(Hyperspectral Image, HSI)包含大量数据和冗余信息, 并且波段间具有高度相关性<sup>[1]</sup>。因此, 在不丢失有用信息的前提下, 高光谱图像的特征学习<sup>[2]</sup>可以获得更准确、可靠的信息。

HUANG等人提出了一种基于单隐层前馈神经网络的求解

方法——极限学习机(Extreme Learning Machine, ELM)<sup>[3]</sup>, 与传统的神经网络相比, 其学习速度较快, 泛化性能较好。但ELM及其改进算法并未充分考虑HSI分布信息中的判别特征和数据中的局部几何结构。引入特征学习技术<sup>[4]</sup>可以解决上述问题。线性判别分析(Linear Discriminant Analysis, LDA)<sup>[5-6]</sup>是一种有效的特征学习技术, 主要用于图像分类和

特征缩减<sup>[7]</sup>。本文提出一种基于判别信息的复合核极限学习机(CKELM-L)。对于数据样本分类问题, CKELM-L可以考虑到数据样本中的局部几何结构和图像分布信息中的判别特征, 通过最大化类间距离和最小化类内距离, 优化极限学习机的输出权重, 增强KELM在有限的高光谱图像训练样本下的分类性能, 从而在一定程度上提高ELM的学习速度、泛化性能及辨识精度。

## 2 KELM算法(KELM algorithm)

ELM是一种训练单隐层前馈神经网络的算法, 通过随机生成输入层和隐藏层之间的输入权值和偏差, 利用最小二乘法直接求出隐藏层与输出层关联的输出权值矩阵。

对于利用  $N$  个训练样本来区分  $m$  个类别的传统分类问题, 第  $i$  个训练样本可以表示为  $(x_i, t_i)$ , 其中  $x_i$  是一个  $n \times 1$  的输入向量;  $t_i$  是对应的  $m \times 1$  的输出向量, 即  $X = (x_1, x_2, \dots, x_N) \in R^{D \times N}$ ,  $t_i = (t_{i1}, t_{i2}, \dots, t_{im})^T \in R^m$ , 那么具有  $L$  个隐藏层节点的隐藏层输出为:

$$f(x_i) = \sum_{j=1}^L \beta_j G(a_j, b_j, x_i) = t_i, \quad i=1, 2, \dots, N \quad (1)$$

其中,  $a_j$  和  $b_j$  分别表示第  $j$  个隐藏层节点的权重和偏差,  $G$  表示神经网络的激活函数,  $\beta_j$  表示将第  $j$  个隐藏层节点连接到输出层节点的权重向量。则:

$$H\beta = T \quad (2)$$

其中,  $H$  为隐藏层输出矩阵,  $\beta$  为输出权值矩阵,  $T$  为期望输出矩阵。

在式(2)中, 只有  $\beta$  是未知的, 因此采用最小二乘算法来获取解, 可以描述如下:

$$\beta = H^\dagger T = \begin{cases} H^T (HH^T)^{-1} T, & N \leq L \\ (HH^T)^{-1} H^\dagger T, & N > L \end{cases} \quad (3)$$

其中,  $H^\dagger$  表示隐藏层输出矩阵  $H$  的 Moore-Penrose 广义逆。

为了提高传统ELM的泛化性能, HUANG从优化的角度训练ELM<sup>[8]</sup>, 将  $\|H\beta - T\|^2$  和  $\|\beta\|^2$  同步最小化, 因此等式优化约束的ELM可以表示为:

$$\begin{aligned} \min & \frac{1}{2} \|\beta\|^2 + C \frac{1}{2} \sum_{i=1}^N \|\xi_i\|^2 \\ \text{s.t.} & h(x_i)\beta = t_i^T - \xi_i^T, \quad i=1, 2, \dots, N \end{aligned} \quad (4)$$

其中,  $\xi_i = [\xi_{i1}, \xi_{i2}, \dots, \xi_{im}]$  表示  $m$  个输出节点相对于训练样本  $x_i$  的训练误差向量;  $C$  表示惩罚因子, 是在训练误差最小化和普遍性最大化之间的权衡。根据 Karush-Kuhn-Tucker(KKT)定理, 式(3)可描述如下:

$$\beta = H^\dagger T = \begin{cases} H^T \left( \frac{I}{C} + HH^T \right)^{-1} T, & N \leq L \\ \left( \frac{I}{C} + HH^T \right)^{-1} H^\dagger T, & N > L \end{cases} \quad (5)$$

由式(5)可得ELM的输出函数为:

$$f(x) = h(x)\beta = h(x)H^T \left( \frac{I}{C} + HH^T \right)^{-1} T \quad (6)$$

在ELM算法中, 隐藏层节点的权重和偏差是已知的。如果隐藏层节点的权重和偏差未知, 则可以采用如下方法定义ELM的内核矩阵。

与支持向量机(Support Vector Machines, SVM)<sup>[9]</sup>相似, 可以使用内核将式(6)中的传统ELM推广到具有内核的ELM。具体地说, 可以用以下核函数代替  $h(x)H^T$  和  $HH^T$  的计算中涉及的内积运算:  $h(x_i) \cdot h(x_j) = K(x_i, x_j)$ 。替换后, 使用输出函数获得内核ELM(KELM)。

$$f(x) = K_x \left( \frac{I}{C} + K \right)^{-1} T \quad (7)$$

其中, 内核  $K = [K(x_i, x_j)]_{i,j=1}^N$  且  $K_x = [K(x, x_1), \dots, K(x, x_N)]$ 。

## 3 CKELM-L算法(CKELM-L algorithm)

在分类中, 当空间的维数增大, 训练集的大小固定时, 经常会遇到维数灾难(又称维数诅咒)<sup>[10]</sup>。特征学习可以很好地解决这一问题。LDA<sup>[11]</sup>是特征学习中常用的一种提取特征方法。LDA使用每个类的平均向量和协方差矩阵来形成类内、类间散布矩阵。基于Fisher准则, 在低维空间中寻找类间离差与类内平均离差之比最大的特征。因此, 本文提出一种基于判别信息的复合核极限学习机(CKELM-L)。

### 3.1 CKELM-L算法

首先采用线性判别分析方法对数据样本进行处理, 提取具有判别信息的特征数据。  $X_i = \{x_1^{(i)}, \dots, x_{N_i}^{(i)}\} \subset R^d$  是第  $i$  类样本的集合,  $N_i$  是第  $i$  类样本的个数,  $i=1, \dots, L$  和  $N = N_1 + \dots + N_L$  是所有训练样本的数量。基于Fisher准则, 投影到的  $d$  维低维空间的样本矩阵为  $W$ , 其中  $W$  是由向量  $(w_1, w_2, \dots, w_d)$  组成的, 该样本矩阵即为具有判别信息特征数据的样本矩阵, 则  $W$  可被表示为:

$$W = \arg \max_w \{J(w)\} = \arg \max_w \left\{ \frac{w^T S_b w}{w^T S_w w} \right\} \quad (8)$$

其中, 类间散布矩阵  $S_b^{LDA}$  和类内散布矩阵  $S_w^{LDA}$  将被定义为:

$$S_b^{LDA} = \sum_{i=1}^L \frac{N_i}{N} (m_i - m)(m_i - m)^T \quad (9)$$

$$S_w^{LDA} = \sum_{i=1}^L \sum_{j=1}^{N_i} \frac{1}{N} (x_j^{(i)} - m_i)(x_j^{(i)} - m_i)^T \quad (10)$$

其中,  $m_i$  表示样本均值,  $m_i = \frac{1}{N_i} \sum_{j=1}^{N_i} x_j^{(i)}$ ;  $m$  表示样本总平均值,  $m = \frac{1}{N} \sum_{i=1}^L \sum_{j=1}^{N_i} x_j^{(i)}$ 。

式(8)中的最大化准则可以写为如下的最大化问题:

$$W = \arg \max_w \{ \text{tr}((w^T S_w w)^{-1} w^T S_b w) \} \quad (11)$$

式(11)可以被证明等于:

$$W = \arg \max_w \{ \text{tr}(w^T S w)^{-1} w^T S_b w \} \quad (12)$$

其中,  $S = S_b - (1 - \delta) S_w$  是信息差矩阵, 参数  $\delta$  具有调节类内判别信息和类间判别信息的作用。



结果。

### 4.2.1 Indian Pines数据集实验结果

在实验中，根据文献[20]，对16类真实数据选取10%作为训练样本总计1,031个，其余9,218个数据作为测试样本。不同分类算法对Indian Pines数据集的分类结果如表1所示，图4给出了在Indian Pines数据集上分类结果图对比。

表1 Indian Pines数据集相关算法分类结果

Tab.1 Classification results of related algorithms in Indian Pines dataset

评价 指标	类别	算法							
		ELM	KELM	SVM	HiFi	ELMCK	KELMCK	SVMCK	CKELM-L
CA	1	0	63.41	70.73	<b>100</b>	90.24	97.56	95.12	97.56
	2	76.50	79.69	75.41	70.81	96.42	95.95	94.24	<b>98.91</b>
	3	46.32	74.43	72.42	94.44	97.99	95.45	95.58	<b>99.46</b>
	4	19.72	43.66	47.42	98.16	84.98	98.59	98.12	<b>99.53</b>
	5	87.33	89.17	91.47	92.87	93.09	91.47	93.09	<b>94.47</b>
	6	96.65	96.19	93.15	95.77	98.17	98.33	99.24	<b>100</b>
	7	0	56.00	60.00	<b>100</b>	88.00	<b>100</b>	<b>100</b>	92.00
	8	97.44	98.37	97.44	99.78	<b>100</b>	<b>100</b>	<b>100</b>	99.53
	9	5.56	22.22	22.22	<b>100</b>	5.56	83.33	44.44	83.33
	10	57.78	78.03	75.97	81.83	92.79	<b>97.48</b>	95.31	97.25
	11	80.76	83.11	80.94	85.67	98.10	98.55	94.98	<b>99.05</b>
	12	66.60	70.54	68.67	96.68	97.00	96.06	93.81	<b>98.12</b>
	13	98.91	98.37	95.65	98.92	98.37	98.37	97.85	<b>99.46</b>
	14	95.25	94.73	92.71	94.78	98.51	95.87	95.17	<b>100</b>
	15	53.89	60.81	55.91	94.54	94.52	93.66	92.51	<b>100</b>
	16	75.90	86.75	93.98	98.63	93.98	89.16	<b>100</b>	98.80
OA		73.94	81.24	79.93	88.59	97.62	94.58	96.27	<b>98.91</b>
AA		59.91	74.72	74.63	93.93	89.23	95.61	93.09	<b>97.34</b>
kappa		69.81	78.50	76.98	87.05	97.28	97.27	95.74	<b>98.75</b>

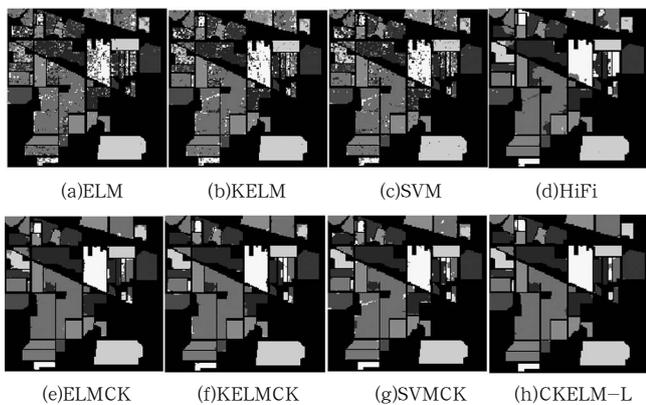


图4 Indian Pines数据集上不同方法分类结果图对比

Fig.4 Comparison of classification results of different methods in Indian Pines dataset

表1首先给出了在Indian Pines数据集上固定训练样本个数后不同算法的类内分类准确性(CA)，同时给出了总体准确性(OA)、平均准确性(AA)和kappa系数。通过比较7种算法的OA、AA和kappa系数可以很清楚地看到，本文所提算法具有最优的分类效果，根据CA可以看出，在16类数据样本中本文所提算法有10类的准确率要高于其他算法。与传统分类算法KELM相比总体准确性提高17.67%，与带有传统CK方法的KELMCK相比总体准确性提高1.33%，与目前较新颖的算法HiFi算法相比总体准确性提高10.32%。

### 4.2.2 University of Pavia数据集实验结果

在实验中，对9类真实数据选取1%作为训练样本总计432个，其余42,344个数据作为测试样本。不同分类算法对University of Pavia数据集的分类结果如表2所示，图5给出了在University of Pavia数据集上分类结果图对比。

表2 University of Pavia数据集相关算法分类结果

Tab.2 Classification results of related algorithms in University of Pavia dataset

评价 指标	类别	算法							
		ELM	KELM	SVM	HiFi	ELMCK	KELMCK	SVMCK	CKELM-L
CA	1	83.56	82.36	81.76	71.37	95.78	83.52	92.99	<b>99.15</b>
	2	96.72	96.78	94.44	86.41	99.76	99.39	98.22	<b>99.87</b>
	3	27.96	64.05	62.80	76.14	<b>91.29</b>	87.05	85.80	87.87
	4	80.55	83.38	80.65	89.32	87.14	79.39	88.89	<b>95.35</b>
	5	99.92	99.77	99.85	98.04	100	95.19	<b>100</b>	<b>100</b>
	6	43.03	60.89	72.56	86.76	96.34	96.75	95.08	<b>99.06</b>
	7	3.57	68.92	69.83	95.42	92.63	91.79	93.01	<b>99.77</b>
	8	54.29	76.43	77.91	81.73	78.68	74.38	83.81	<b>98.44</b>
	9	53.15	90.82	98.29	<b>99.89</b>	68.09	23.37	72.89	96.16
OA		76.35	85.69	86.31	86.94	92.99	90.99	93.95	<b>98.35</b>
AA		60.31	80.38	82.01	87.23	89.97	81.20	90.08	<b>97.30</b>
kappa		67.34	80.76	81.57	83.09	90.64	87.97	91.94	<b>97.81</b>

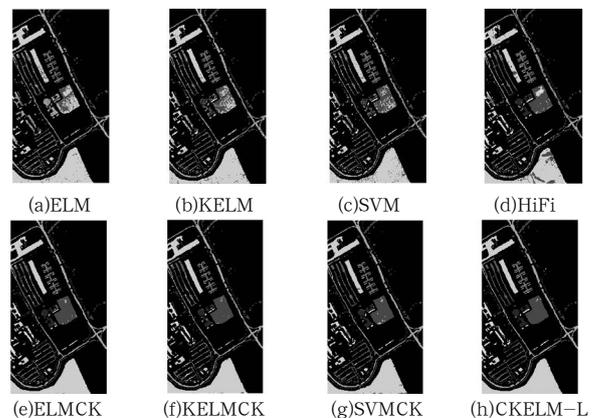


图5 University of Pavia数据集上不同方法分类结果图对比

Fig.5 Comparison of classification results of different methods in University of Pavia dataset

表2首先给出了在University of Pavia数据集上固定训练样本个数后不同算法的类内分类准确性(CA), 也给出了总体准确性(OA)、平均准确性(AA)和kappa系数。通过比较7种算法的OA、AA和kappa系数可以很清楚地看到, 本文所提算法具有最优的分类效果, 根据CA可以看出, 在9类数据样本中本文所提算法有7类的准确率要高于其他算法。与传统分类算法KELM相比总体准确性提高12.66%, 与带有传统CK方法的KELMCK相比总体准确性提高7.36%, 与目前较新颖的算法HiFi算法相比总体准确性提高11.41%。

### 4.2.3 Salinas Scene数据集实验结果

在实验中, 对16类真实数据选取5%作为训练样本总计2,713个, 其余51,416个数据作为测试样本。不同分类算法对Salinas Scene数据集的分类结果如表3所示, 图6给出了在Salinas Scene数据集上分类结果图对比。

表3 Salinas Scene数据集相关算法分类结果

Tab.3 Classification results of related algorithms in Salinas Scene dataset

评价指标	类别	算法							
		ELM	KELM	SVM	HiFi	ELMCK	KELMCK	SVMCK	CKELM-L
		(单位: %)							
CA	1	99.58	99.79	99.42	98.64	<b>100</b>	<b>100</b>	99.95	<b>100</b>
	2	99.94	99.89	99.80	99.54	<b>100</b>	99.94	99.92	<b>100</b>
	3	95.47	99.36	99.57	99.80	<b>100</b>	99.89	99.79	<b>100</b>
	4	99.17	99.47	<b>99.92</b>	99.05	98.11	99.47	99.17	99.85
	5	99.02	98.47	98.55	98.98	<b>99.96</b>	99.45	99.10	99.53
	6	99.81	99.81	99.84	99.14	<b>100</b>	99.71	99.97	<b>100</b>
	7	99.65	99.71	99.71	98.82	<b>100</b>	99.68	99.74	99.94
	8	88.61	89.39	89.04	82.37	94.88	<b>99.45</b>	98.09	99.30
	9	99.97	99.93	99.88	99.90	<b>100</b>	99.97	<b>100</b>	<b>100</b>
	10	95.05	95.92	95.76	88.43	99.17	99.90	98.09	<b>99.94</b>
	11	95.96	99.01	98.32	97.23	<b>100</b>	99.80	99.80	<b>100</b>
	12	99.13	<b>100</b>	99.89	<b>100</b>	<b>100</b>	<b>100</b>	99.78	<b>100</b>
	13	98.16	98.97	99.08	98.21	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>
	14	94.00	97.64	97.34	93.14	99.41	99.41	96.85	<b>99.80</b>
	15	60.66	70.38	71.99	75.30	86.43	99.46	99.12	<b>99.99</b>
	16	98.31	97.44	97.67	97.65	<b>99.01</b>	94.61	96.74	98.95
OA		91.35	93.19	93.07	92.74	97.13	99.29	99.20	<b>99.81</b>
AA		95.16	96.57	96.61	95.39	98.56	99.42	99.16	<b>99.83</b>
kappa		90.34	92.41	92.28	91.93	96.81	99.21	99.10	<b>99.79</b>

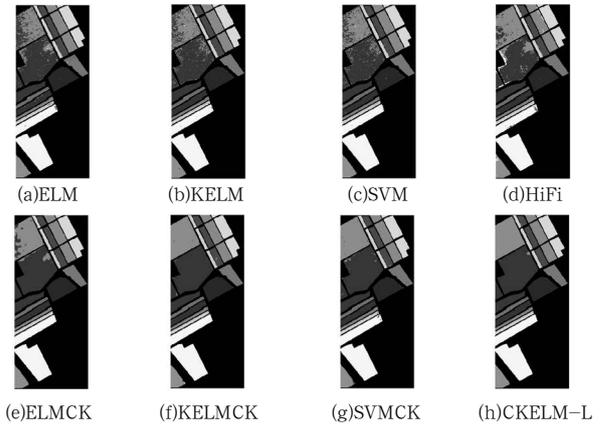


图6 Salinas Scene数据集上不同方法分类结果图对比

Fig.6 Comparison of classification results of different methods in Salinas Scene dataset

表3首先给出了在Salinas Scene数据集上固定训练样本个数后不同算法的类内分类准确性(CA), 同时给出总体准确性(OA)、平均准确性(AA)和kappa系数。通过比较7种算法的OA、AA和kappa系数可以很清楚地看到, 本文所提算法具有最优的分类效果。根据CA可以看出, 在16类数据样本中本文所提算法有11类的准确率要高于其他算法。与传统分类算法KELM相比总体准确性提高6.62%, 与带有传统CK方法的KELMCK相比总体准确性提高0.52%, 与目前较新颖的算法HiFi算法相比总体准确性提高7.07%。

## 5 结论(Conclusion)

本文提出了一种基于判别信息的复合核极限学习机(CKELM-L)的HSI分类模型。该模型采用线性判别分析(LDA)算法对HSI进行提取特征。利用空间特征和提取的光谱特征, 采用CKELM对HSI数据集进行分类, 可以大大提高分类性能。通过在三个真实可用的HSI数据集上的实验和比较, 证实了该模型与其他算法相比具有较好的分类效果, 表明图像分布信息中潜在的判别特征有利于HSI分类任务。然而, 本文所提算法仍存在一些不足, 对数据进行分类时, 由于数据含有噪声点等干扰信息, 使得提出的算法在HSI数据的某些类别中不能较好地分类。在未来的工作中, 将引入各种平滑噪声和消除干扰信息的方法, 对HSI进行更好的分类。

## 参考文献(References)

[1] CAI Y, LIU X, CAI Z. BS-Nets: An End-to-End framework for band selection of hyperspectral image[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 58(3):1969-1984.

[2] 任越美. 高光谱图像特征提取与分类方法研究[D]. 西安: 西北工业大学, 2017.

[3] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: A new learning scheme of feedforward neural networks[C]// EE Engineers. 2004 IEEE International Joint

- Conference on Neural Networks (IEEE Cat. No. 04CH37541). Budapest, Hungary: IEEE, 2004:985–990.
- [4] 李思. 复杂光照下图像特征提取技术研究[D]. 西安: 长安大学, 2018.
- [5] JOY A A, HASAN M A M, HOSSAIN M A. A comparison of supervised and unsupervised dimension reduction methods for hyperspectral image classification[C]// BHUIYAN M A M. 2019 International Conference on Electrical, Computer and Communication Engineering (ECCE). Cox's Bazar: IEEE, 2019:1–6.
- [6] ZHENG X, YUAN Y, LU X. Dimensionality reduction by spatial-spectral preservation in selected bands[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(9):5185–5197.
- [7] 阿茹罕, 何芳, 王标标. 加权空-谱主成分分析的高光谱图像分类[J]. 国土资源遥感, 2019, 31(2):17–23.
- [8] HUANG G B. An insight into extreme learning machines: Random neurons, random features and kernels[J]. Cognitive Computation, 2014, 6(3):376–390.
- [9] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8):1778–1790.
- [10] CAO F, YANG Z, REN J, et al. Sparse representation-based augmented multinomial logistic extreme learning machine with weighted composite features for spectral-spatial classification of hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(11):6263–6279.
- [11] FUKUNAGA K. Introduction to statistical pattern recognition[M]. New York: Elsevier, 2013:256–483.
- [12] CAO F, YANG Z, REN J, et al. Local block multilayer sparse extreme learning machine for effective feature extraction and classification of hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(8):5580–5594.
- [13] ZHOU L, MA L. Extreme learning machine-based heterogeneous domain adaptation for classification of hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(11):1781–1785.
- [14] MOU L, BRUZZONE L, ZHU X X. Learning spectral-spatial-temporal features via a Recurrent Convolutional Neural Network for change detection in multispectral imagery[J]. IEEE Transactions on Geoscience & Remote Sensing, 2018, 57(2):924–935.
- [15] MEI X, PAN E, MA Y, et al. Spectral-spatial attention networks for hyperspectral image classification[J]. Remote Sensing, 2019, 11(8):963–981.
- [16] SHU L, MCISAAC K, OSINSKI G R. Learning spatial-spectral features for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(9):5138–5147.
- [17] BAZI Y, ALAJLAN N, MELGANI F, et al. Differential evolution extreme learning machine for the classification of hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2013, 11(6):1066–1070.
- [18] ZHOU Y, PENG J, CHEN C L P. Extreme learning machine with composite kernels for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 8(6):2351–2360.
- [19] MARCONCINI M, CAMPS-VALLS G, BRUZZONE L. A composite semisupervised SVM for classification of hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2009, 6(2):234–238.
- [20] RICHARDS J A, JIA X. Remote sensing digital image analysis[M]. Berlin: Springer, 1999:146–303.
- [21] TU B, ZHANG X, KANG X, et al. Hyperspectral image classification via fusing correlation coefficient and joint sparse representation[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(3):340–344.
- [22] CAMPS-VALLS G, GOMEZ-CHOVA L, MUNOZ-MARI J, et al. Composite kernels for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2006, 3(1):93–97.
- [23] PAN B, SHI Z, XU X. Hierarchical guidance filtering-based ensemble classification for hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7):4177–4189.

### 作者简介:

- 马斯宇(1995–), 女, 硕士生. 研究领域: 模式识别, 机器学习.  
刘德山(1970–), 男, 硕士, 教授. 研究领域: 机器学习, 智能信息处理, 模式识别.  
闫德勤(1962–), 男, 博士, 教授. 研究领域: 模式识别, 机器学习.  
丁一民(1997–), 男, 硕士生. 研究领域: 模式识别, 机器学习.