

利用 EMAP 与多项式网络的高光谱影像分类

王扣准 黄睿

(上海大学通信与信息工程学院 上海 200072)

摘要: 高光谱影像地物分类已成为高光谱的重要应用之一,然而如何在小样本时取得优秀的分类结果已成为研究的难点与热点。最近几年,深度学习理论开始用于高光谱数据分析。本文提出了一种基于扩展多属性剖面(extended multi-attribute profile, EMAPs)和深度多项式网络(polynomial networks)的高光谱影像分类方法。首先,EMAPs 通过一系列的属性滤波器提取影像多种结构特性的形态学纹理特征,并与影像光谱特征结合构成新的特征矢量。接着利用深度多项式网络对新特征矢量进行学习,构建多层次网络结构,在迭代的过程中逐层降低训练误差,实现优秀的分类结果。高光谱影像分类实验表明,所提方法性能优于多种分类方法。

关键词: 高光谱;扩展的多属性剖面;深度学习;多项式网络;分类

中图分类号: TP751.1 **文献标识码:** A **国家标准学科分类代码:** 420.2040

Hyperspectral image classification using extended multi attribute profiles and polynomial networks

Wang Kouzhun Huang Rui

(School of Communication and Information Engineering, Shanghai University, Shanghai 200072, China)

Abstract: Hyperspectral image classification has become one of important hyperspectral applications, but how to get good classification results in the case of small sample size is still an open issue and attracts many research attentions. In recent year, deep learning has been used in the context of remote sensing image analysis. In this paper, we propose a new hyperspectral image classification method based on EMAPs (extended multi-attribute profile) and polynomial networks (PN). Firstly, EMAPs can extract multi-level structures of morphological features by a series of attribute filters, which integrate the spatial and spectral information of remote sensing data. Then, the spatio-spectral features are fed as the input to the deep PN composed of multi-layer feed forward structure. PN decreases the training error layer-by-layer in the sense to obtain good classification results. Classification experimental results on different hyperspectral image sets demonstrate that the proposed method outperforms other methods.

Keywords: hyperspectral image; extended multi-attribute profiles; deep learning; polynomial networks; classification

1 引言

高光谱遥感可获取从可见到近红外光谱范围内地物的电磁波辐射,生成的高光谱影像包含了地物丰富的光谱信息,在环境监控、目标识别等领域获得广泛应用^[1-3]。采用强分类器有利于提高遥感地物的分类识别率,因而,支持向量机和其改进算法已经被广泛应用于地物分类中^[4-6]。近年来,深度学习理论开始被应用与高光谱特征提取和分类,体现出较好的性能^[7-9]。这些方法核心思想是将网络看成逐步抽象的过程,无监督地训练每一层网络,然后将得到的输出节点当成下一层网络的输入层。用监督算法逐步训练

各网络层参数,使得网络提取出抽象的特征信息。一幅图像可以用少量的抽象特征表示,并用于识别或分类,达到令人满意的效果。

另一方面,在使用深度学习网络进行高光谱影像分类时,如何有效地利用空间信息成为一个重大的问题。最近,结合空间和光谱信息的高光谱影像分类成为研究热点。提取图像的纹理特征,然后结合光谱信息进行分类是常用的谱-空结合方法。典型的包括流形特征提取^[10]、局部 Fisher 判别分析^[11]、形态学理论等^[12]。

本文提出一种新的谱-空结合分类方法。首先,采用拓展的多属性剖面(extended multi attribute profiles,

EMAPs)提取高光谱影像纹理特征。EMAPs 从不同方向重构高光谱影像的空间和光谱信息,在分类应用中体现出较好的性能。在此基础上利用线性多项式网络^[13]构建基础分类器,实现影像地物的分类。高光谱影像分类实验表明,所提方法能更好地利用高光谱影像的光谱和纹理特征,分类性能优于多种谱-空结合方法。

2 提出方法

2.1 EMAPs

EMAPs 是对传统形态学剖面的改进与拓展。它将简单的结构元素用多种属性原则加以替换,并对这些属性原则进行级联,从而获得多种结构的属性特征,充分利用高光谱数据的空间和光谱信息。

首先,对高光谱影像进行属性滤波。然而影像数据通常达到几百维,为了降低计算量,一般要对原影像进行降维,常采用主成分分析变换。接着对若干主成分分量进行属性滤波,获得扩展的属性剖面(extend attribute profiles, EAP)如下:

$$EAP = \{AP_1, AP_2, \dots, AP_i\} \quad (1)$$

式中: AP_i ($i = 1, \dots, n$)表示对分量 i 的属性滤波, n 代表保留的主分量个数。

属性滤波操作是在给定参考阈值 λ 的前提下,评估灰度图像 f 相连成分的属性值。比如,设图像的相连成分为 C_i ,如果属性值 $AP(C_i)$ 大于阈值 λ ,则这一区域将被保留;反之, C_i 将被赋为与邻域相近的值,从而将 C_i 合并到周边子块。如果被合并到的区域灰度值较低,则这一过程称为图像的变薄变换,反之称为增厚变换, AP 定义为:

$$AP(f) := \{\varphi_n(f), \dots, \varphi_1(f), f, \gamma_1(f), \dots, \gamma_n(f)\} \quad (2)$$

式中: φ_i 与 γ_i 分别代表增厚与变薄变换。图 1 给出了 EAP 的结构示意。

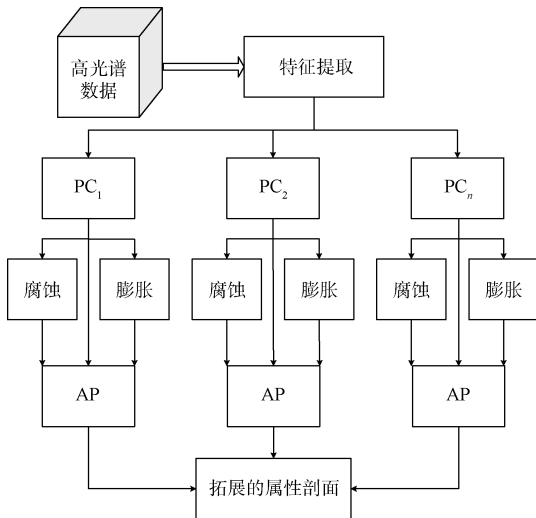


图 1 EAP 结构示意图

然而,单一的属性剖面只能从一个方面提取特征向量,不能全面有效地描述高光谱复杂的地物特征。因此,文献[6]提出 EMAPs,通过不同的属性滤波架构多层次的特征向量,然后将所有的特征串联成单一向量,有效的整合高光谱数据的空间和光谱信息。一般定义 4 种属性剖面:面积准则 a ,像素标准差准则 s ,惯性矩准则 i ,形状准则 d ,有:

$$EMAP_s = \{EAP_a', EAP_s', EAP_d', EAP_i'\} \quad (3)$$

$$EAP' = EAP \{PC_1, PC_2, \dots, PC_n\} \quad (4)$$

2.2 深度学习

深度学习网络使机器模拟人脑学习迈向了新台阶,是机器学习领域的一个重要突破,在语音和图像识别领域都具有广泛的应用。深度学习的研究始于 Hinton 教授在 2006 年提出的深度置信度网络(deep belief nets, DBN)^[14]。网络首先通过数据的非监督训练初始化第一层网络,然后通过监督的方式调整网络参数。逐层从低层网络中提取高层次特征,用于分类和识别。由于深度学习网络能够提取数据更加抽象和复杂的特征,因而在很多领域都表现出优于浅层模型的性能。除 DBN 外,研究者还提出了卷积神经网络(convolutional neural networks, CNN)^[15]、堆积自动编码器(stacked autoencoder, SAE)^[16]、深度玻尔兹曼机(deep boltzmann machines, DBM)^[17]等。

深度多项式网络是一种多层前向网络,采用学习算法 basic learner,具有比其他深度网络更好的泛化能力^[13]。对于给定的训练数据集 $\{(x_1, y_1), \dots, (x_m, y_m)\}$, $x_i \in \mathcal{R}^d$, y_i 是对应的类别标签,线性多项式可以表示为 $p \rightarrow (p(x_1), \dots, p(x_m))$,假定 x_i 是独立的,存在 $\{(p_i(x_1), \dots, p_i(x_m))\}_{i=1}^m$ 构成基特征,用以表征 m 维的空间:

$$\sum_{i=1}^m w_i p_i(x_j) = y_j, j = 1, \dots, m \quad (5)$$

因而构建第一层网络 $\{(\langle w, [1 \ x_1] \rangle), \dots, (\langle w, [1 \ x_m] \rangle)\}$: $w \in \mathcal{R}^{d+1}$,就转化为求解 $d+1$ 维正交基,这可以通过 Gram-Schmidt 和 SVD 求解 $(d+1) \times (d+1)$ 的矩阵 W 得到。获取到所有的节点构成第一层多项式网络 $\{(n_j^1(x_1), \dots, n_j^1(x_m))\}_{j=1}^m$,其中:

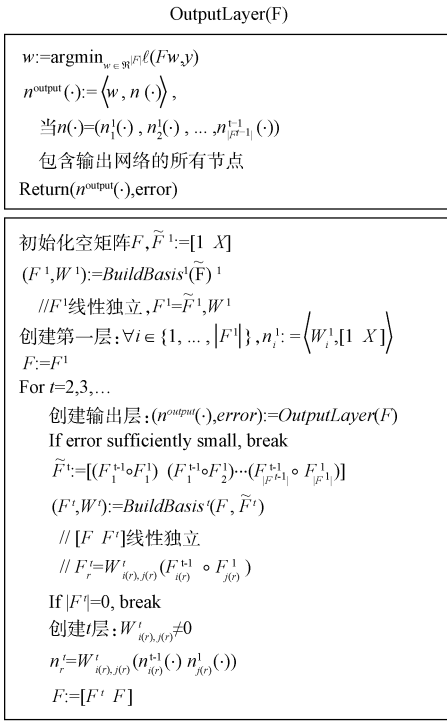
$$F_{i,j}^1 = n_j^1 \langle W_j, [1 \ X] \rangle \quad (6)$$

由于深度网络是逐层构建得到,得到第一层网络就可以依次构建多层网络。具体算法流程如图 2 所示。


3 实验

3.1 实验数据

实验数据为两个高光谱数据集: Pavia University 和 Salinas,包含了农业区、城区等代表性地物。数据集 Pavia University 由反射光学系统成像光谱仪(Reflective Optics System Imaging Spectrometer, ROSIS)获取,位于意大利 Pavia 市。图像空间分辨率为 1.3 m,光谱范围为 0.43 到 0.86 μm ,大小为 610×340 ,包含 115 个波段,9 种地物,42 776 个标记样本。为去除噪声干扰,只采用 103 个波段



BuildBasis¹(\tilde{F}^1)-example



BuildBasis¹(F, \tilde{F}^1)-example




图 2 Basis Learner 算法流程

用于实验。数据集 Salinas 由机载可见近红成像光谱仪 (airborne visible infra-red imaging spectrometer, AVIRIS) 获取, 位于美国印第安纳州的西北方。图像空间分辨率为 3.7 m, 光谱范围为 0.4~2.5 μm , 大小为 512×217, 包含 224 个光谱波段, 16 种地物, 54 129 个标记样本。为去除噪声干扰, 只采用 204 个波段用于实验。图 3 给出了两个数据集的伪彩色图和标记样本分布情况。

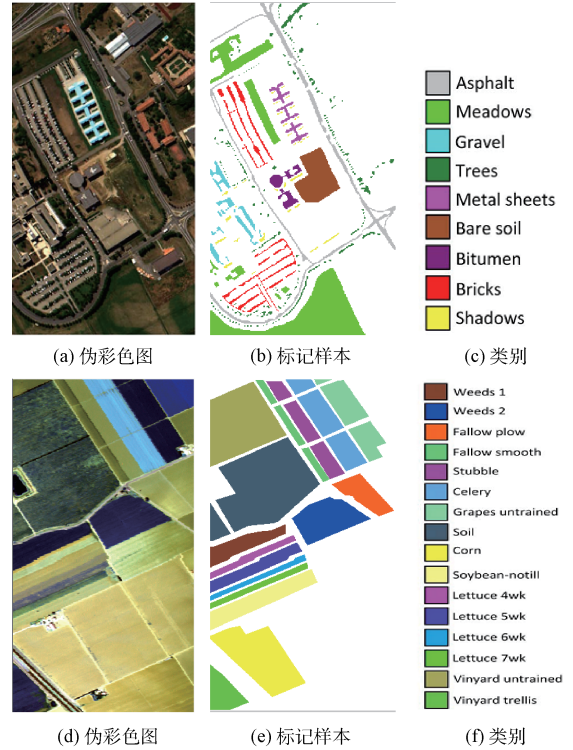


图 3 Pavia University 和 Salinas 数据集

3.2 实验参数设定


3.2.1 EMAPs 参数设定

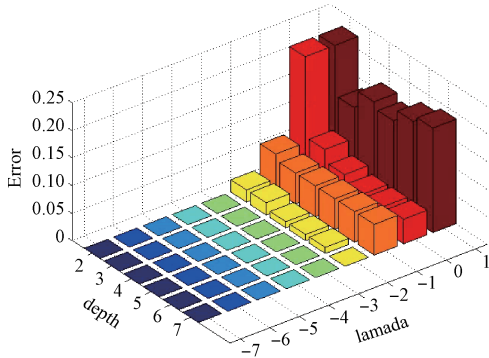
为降低计算量, 在提取 EMAPs 特征前一般先对高光谱影像采用主成分分析降维。本文保留 4 个主成份分量, 相应的累积特征值比率超过 99%。

对保留的主成分影像提取形态学属性剖面。在本文中, 采用文献[8]的参数值设定。提取 4 个属性剖面, 具体参数设置如下:

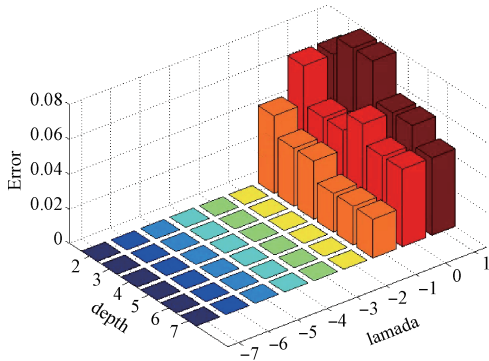
- 1) 面积准则: $\lambda_a = [100 \ 500 \ 1000 \ 5000]$;
- 2) 像素标准差准则: $\lambda_s = [20 \ 30 \ 40 \ 50]$;
- 3) 惯性矩准则: $\lambda_i = [0.2 \ 0.3 \ 0.4 \ 0.5]$;
- 4) 形状准则: $\lambda_d = [10 \ 25 \ 50 \ 100]$ 。

不同参数取值对网络性能的影响如图 4 所示。






(b) width=10 OA=90.8



(c) width=15 OA=94.75



(d) width=20 OA=94.48

图 4 不同参数取值对网络性能的影响

3.2.2 Basis Learner

采用 Pavia University 数据分析网络参数对分类结果的影响。每类地物随机选取 10 个样本构成训练集,选取 100 个样本用于交叉验证。

Basis Learner 参数主要包括网络宽度,网络深度和正则化参数。由于 Basis Learner 至少包含构造层和输出层,因而网络至少有两层。设 3 个参数的取值分别为:宽度 $width \in \{5, 10, 15, 20\}$, 深度 $depth \in \{2, 3, 4, 5, 6, 7\}$, $\lambda \in \{10^{-7}, 10^{-6}, \dots, 10^1\}$; 且每层的网络宽度相同。采用整体精度 (overall accuracy, OA) 为评价指标。图 4 给出了不同参数取值对网络性能的影响,其中横坐标 lamada 为 10 的指数。可以看到,随着网络深度和网络宽度的增加,验证误差逐渐减小,OA 逐渐增大。但当宽度大于 15 时,分类精度有所降低。因而在本文中,设定网络宽度为 15,网络深度设定为 7 层;同时,当 $\lambda < 10^{-3}$ 时,网络误差较小,故设 λ 为 10^{-3} 。

3.3 实验比对

在本文中,主要和 4 种方法对比。SVM 方法是基于纯光谱数据分类,使用 RBF (Gaussian radial basis function) 内核,5 倍交叉验证获取 SVM 模型参数;SVMCK^[4] 方法是基于 SVM 的改进分类器,复合空间核和光谱核,其中空间核是 5×5 大小的加窗函数平均值,空间核和光谱核权重系数固定在 0.5,EMAP_SVMCK 方法结合原始光谱数据和 EMAP 特征分类;同样的,GCK^[5] 是 MLR (multinomial logistic regression) 分类器结合空间核与光谱核的算法,详细的参数设置请见文献[5];EMAP_SP^[18] 方法是 EMAP 与稀疏表示的结合算法,正则化参数 $\lambda = 10^{-5}$ 。性能评价指标包括 OA, Kappa 系数和平均精度 (average accuracy, AA)。

对于 Pavia University 数据集,每类随机选取 10 个样本构成训练集,剩下的样本用于测试。实验结果如表 1 所示。从中可以得出,纯光谱分类时分类的精度很低,其中 OA 为 67.5%,说明在小样本情况下,单纯依靠光谱特征无法获得满意精度。当使用 EMAP 属性特征辅助分类时,分类精度都得到大幅度的提高,其中本文所提算法性能最优,OA 达到 94.75%,体现了多项式网络的强学习性能。图 5

表 1 五种方法用于 Pavia University 数据集的分类性能比较

Class	Train	Test	SVM	EMAP_SVMCK	EMAP_GCK	EMAP_SP	EMAP_PN
Alfalfa	10	6 631	90.98	81.37	72.74	92.78	93.98
Bare soil	10	18 649	85.28	83.87	93.89	88.43	95.74
Bitumen	10	2 099	46.38	90.62	83.97	96.16	87.57
Bricks	10	3 064	67.12	95.8	95.3	93.86	91.75
Gravel	10	1 345	87.22	95.95	99.39	99.76	96.62
Meadows	10	5 029	38.93	85.33	93.97	88.77	95.41
Metal sheets	10	1 330	45.97	99.77	91.66	99.66	99.77
Metal sheets	10	3 862	69.96	93.05	85.32	94.53	92.74
Shadows	10	947	99.84	99.74	92.64	98.43	98.73
	OA		67.50	88.71	89.57	90.87	94.75
	Kappa		59.56	85.45	86.39	93.6	93.08
	AA		70.19	91.72	89.87	88.36	94.53

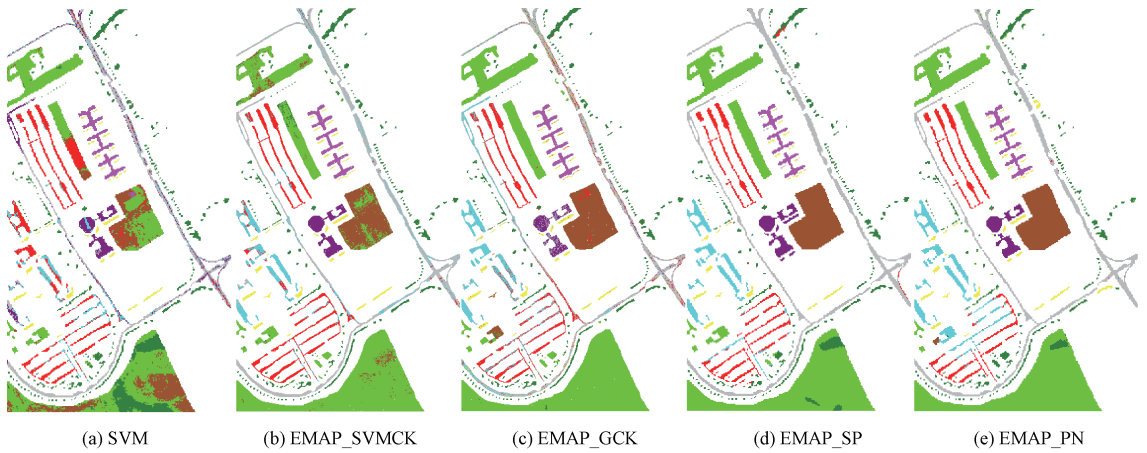


图5 五种方法对 Pavia University 数据集的分类结果

是5种方法的分类结果图,当分类精度提高时,误分类的地物减少,图像上的噪点较少。可以看到,所提方法性取得最好分类效果。

对于 Salinas 数据集,每类随机选取 10 个样本构成训练集,

剩下的样本用于测试。实验结果如表 2 所示。由于 Salinas 数据集各类地物特征较为明显,因此纯光谱分类也取得较好的分类结果。但在结合 EMAP 特征后,分类精度仍得到明显提升。其中,以本文所提方法 EMAP_PN 分类性能最佳。

表2 五种方法用于 Salinas 数据集的分类性能比较

Class	Train	Test	SVM	EMAP_SVMCK	EMAP_GCK	EMAP_SP	EMAP_PN
Weeds_1	10	1 999	97.48	99.52	99.99	99.46	98.85
Weeds_2	10	3 716	98.9	99.22	99.49	99.87	99.33
Fallow	10	1 966	85.75	96.61	99.83	99.88	99.78
Fallow_r	10	1 384	97.21	99.32	98.74	95.71	99.28
Fallow_s	10	2 668	97.54	98.08	99.09	95.64	98.03
Stubble	10	3 949	99.96	99.81	99.55	99.85	97.85
Celery	10	3 569	96.91	99.49	99.63	99.98	98.8
Grapes_u	10	11 261	69.95	68.97	67.13	79.19	76.69
Corn_s	10	6 193	98.98	98.59	99.61	99.89	99.71
Lettuce_4wk	10	3 268	79.11	91.35	93.26	89.88	91.32
Lettuce_5wk	10	1 058	81.93	95.31	95.27	99.91	94.64
Lettuce_6wk	10	1 917	90.17	99.78	99.87	98.01	99.67
Lettuce_7wk	10	908	91.99	97.85	98.36	96.59	98.45
Woods	10	1 060	86.68	93.24	96.32	95.76	94.19
Vinyard_u	10	7 258	52.49	65.14	78.72	85.33	81
Vinyard_v	10	1 797	91.49	97.97	96.68	93.27	96.71
OA			83.04	87.46	89.34	91.31	91.42
Kappa			81.18	86.06	88.17	90.28	90.46
AA			88.53	93.77	95.1	96.06	95.40

4 结 论

本文提出了一种新的谱-空结合高光谱影像分类方法。方法结合形态学特征提取算子 EMAPs 和强分类器深度多项式网络,使得高光谱影像的空间和光谱信息获得充分利用和学习。高光谱影像地物分类实验表明,所提算法能取

得更好的分类性能。在以后的工作中,我们将致力于研究方法中各参数的自动确定算法,提高方法的运行效率。

参考文献

- [1] FENG D CH, QIN H Y, ZENG Y. Study on straw incineration monitoring based on the combination of remote sensing image [J]. Instrumentation, 2014.

- 1(3): 25-41.
- [2] 赵春晖, 李晓慧, 王玉磊. 高光谱图像异常目标检测研究进展[J]. 电子测量与仪器学报, 2014, 28(8): 803-811.
- [3] 雷斌, 丁赤飏. 一种基于SAR图像视觉特征的改进像素掩蔽方法[J]. 电子测量技术, 2014, 37(11): 37-41.
- [4] GUSTAVO C V, LUIS G C, JORDI M M, et al. Composite kernels for hyperspectral image classification [J]. IEEE Geosci. Remote Sens. Lett., 2006, 3(1):93-97.
- [5] LI J, MARPU P R, PLAZA A, et al. Generalized composite kernel framework for hyperspectral image classification [J]. IEEE Transactions on Geoscience Remote Sensing Letters, 2013, 51(9): 4816-4829.
- [6] 谭熊, 余旭初, 秦进春, 等. 高光谱影像的多核SVM分类[J]. 仪器仪表学报, 2014, 35(2): 405-411.
- [7] CHEN X, XIANG S, LIU C L, et al. Vehicle detection in satellite images by hybrid deep convolutional neural networks [J]. Geoscience and Remote Sensing Letters, 2014, 11(10):1797-1801.
- [8] CHEN Y, LIN Z, ZHAO X, et al. Deep learning-based classification of hyperspectral data [C]. Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6):2094-2107.
- [9] CIRESAN D C, MEIER U, MASCI J, et al. Flexible, High performance convolutional neural networks for image classification [C]. IJCAI Proceedings International Joint Conference on Artificial Intelligence, Barcelona, 2011:1237.
- [10] BACHMANN C M, AINSWORTH T L, FUSINA R A. Exploiting manifold geometry in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3):441-454.
- [11] LI W, PRASAD S, FOWLER J E, et al. Locality preserving discriminant analysis in kernel-induced feature spaces for hyperspectral image classification[J]. IEEE Geoscience Remote Sensing Letters, 2011, 8(5): 894-898.
- [12] MURA M D, BENEDIKTSSON J A, WASKE B, et al. Extended profiles with morphological attribute filters for the analysis of hyperspectral data [J]. International Journal of Remote Sensing, 2010, 31(22):5975-5991.
- [13] ROI L, SHAI S S, OHAD S. An algorithm for training polynomial networks [J]. ArXiv, 2014:1304.
- [14] HINTON G E, OSINDERO S, TEH Y. A fast learning algorithm for deep belief nets [J]. Neural Computer, 2006, 18(7):1527-1554.
- [15] FUKUSHIMA K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position [J]. Biological Cybernetics, 1980, 36(4):193-202.
- [16] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders [J]. Journal of Machine Learning Research, 2010, 11 (12): 3371-3408.
- [17] SALAKHUTDINOV R and HINTON G E. Deep Boltzmann machines [C]. Proceedings of International Conference on Artificial Intelligence and Statistics, Clearwater Beach, FL, USA, 2009: 448-455.
- [18] SONG B Q, LI J, MURA M D. Remotely sensed image classification using sparse representations of morphological attribute profiles [J]. IEEE Transactions on Geoscience Remote Sensing, 2014, 52(8):5122-5135.

作者简介

王扣准, 1989年生, 硕士生, 从事高光谱遥感影像处理等领域的研究工作。

黄睿, 1976年生, 副教授, 从事模式识别、图像处理、遥感信息智能处理等领域的研究工作。

E-mail: huangr@shu.edu.cn