

# 基于自适应脊波网络的高光谱遥感图像分类

孙锋利<sup>1,2</sup> 何明一<sup>1</sup> 高全华<sup>2</sup>

(西北工业大学电子信息学院 西安 710077)<sup>1</sup> (长安大学理学院 西安 710064)<sup>2</sup>

**摘 要** 神经网络是遥感地物自动分类的重要工具之一。利用多尺度几何分析中的脊波基函数建立了一种自适应脊波网络模型。在传统自适应粒子群算法的基础上,提出一种引入粒子密度因子的自适应粒子群优化算法作为网络训练算法。为验证其性能,利用互信息约简技术对 220 波段 AVIRIS 92AV3C 高光谱数据进行约简,并将它们作为网络输入实现对高光谱遥感地物的自动分类。仿真试验表明:引入粒子密度因子的粒子群算法与传统粒子群算法相比,不易出现早熟问题,在处理高维非线性组合优化问题时具有一定优势;由于脊波函数对高维奇异性的表征能力,相比于传统的 RBF 和 SVM 分类器,脊波神经网络分类器对具有明显边界特征的地物分类问题具有较高的精度,同时网络规模小,结构简单。

**关键词** 脊波,神经网络,粒子群优化,高光谱分类  
中图分类号 TP751.1 文献标识码 A

## Hyperspectral Image Classification Based on Adaptive Ridgelet Neural Network

SUN Feng-li<sup>1,2</sup> HE Ming-yi<sup>1</sup> GAO Quan-hua<sup>2</sup>

(School of Electronics and Information, Northwestern Polytechnic University, Xi'an 710077, China)<sup>1</sup>

(School of Science, Chang'an University, Xi'an 710064, China)<sup>2</sup>

**Abstract** Artificial neural network is an important tool in the scope of remote sense classification. A new model named adaptive ridgelet neural network was presented based on the theory of multi-scaled geometric analysis. On the bases of conventional ones, a novel adaptive PSO algorithm progressed by a so-called swarm density factor was proposed to train the ridgelet network constructed. To validate the performance of ridgelet network, a hyperspectral image classification task was carried out on the feature-selected hyperspectral data set AVIRIS 92AV3C by means of mutual information band-selection method. Numerical experiments show the novel PSO algorithm outperforms the conventional PSO for ridgelet network training especially in high-dimensional scenarios. Ridgelet neural network, compared with RBF and SVM classifier, is advantageous in accuracy referring to ground materials classification with apparent margin, and under the same circumstances, the network always works with simpler structure and smaller size.

**Keywords** Ridgelet, Neural network, Particle swarm optimization, Hyperspectral classification

## 1 引言

高光谱遥感是遥感技术与光谱技术结合的产物,是未来遥感发展的主要方向,因此,高光谱遥感地物分类技术是遥感领域的研究热点之一。高光谱遥感数据具有波段数目众多、数据量大、波谱维度高等特点<sup>[1,2]</sup>,传统的分类技术如最大似然分类器、最小距离分类器、贝叶斯分类器等均基于统计模式,因此在实现地物分类的过程中,会出现许多问题,如小样本问题、概率密度在高维情况下难以估计、分类精度低等。

神经网络是模式识别领域的重要工具之一。它具有自学习、自适应和分布存储等诸多优点,在遥感领域具有良好的应用前景,已被广泛用于遥感分类,常用的模型有 BP 神经网络<sup>[3]</sup>、RBF 神经网络<sup>[4]</sup>、小波网络<sup>[5]</sup>、SVM 网络<sup>[6]</sup>等。神经网络作为高光谱遥感分类器,网络训练的时间比较长,但对于训练好的网络来说,分类速度和精度与传统方法不相上下,对

于性能较好的网络如 RBF 和 SVM,其分类性能优于传统分类器。至于高光谱分类的神经网络的规模问题及小样本问题,可以采用高光谱特征约简技术实现光谱降维,从而保证其分类的精度。

多尺度几何分析技术是多分辨分析技术的延续和发展,因此又被称为“后小波”,是近年来信号处理领域一个非常引人注目的方向。该技术在小波的尺度和平移特性的基础上,加入了方向特性,因此对于高维信号的最优稀疏表示和奇异性检测要优于小波。在多尺度几何分析理论中,脊波理论是发展较早的一个分支,经过 D. L. Donoho 等人的不断努力,其理论发展得最为完善。借鉴小波网络搭建的思想,利用脊波重建理论,本文建立了一种新的神经网络模型——自适应脊波网络(Adaptive Ridgelet Neural Network, ARNN)作为分类器,在采用互信息技术<sup>[7]</sup>进行特征约简后,实现 220 维真实高光谱数据分类;网络训练算法没有采用传统的梯度下降算法,

到稿日期:2011-02-01 返修日期:2011-05-13 本文受国家自然科学基金(60736007),长安大学中央高校专项科研基金(CHD2010JC133)资助。  
孙锋利(1977—),男,博士生,主要研究方向为神经网络、高光谱遥感等,E-mail:sunfengli2005@yahoo.com.cn;何明一(1958—),男,教授,博士生导师,主要研究方向为智能计算、遥感成像与处理、数据压缩等;高全华(1976—),女,讲师,主要研究方向为模式识别、光束整形等。

而是在自适应粒子群算法的基础上,提出了一种引入粒子密度因子的自适应粒子群算法( $\rho$ -PSO),通过与传统的径向基函数网络分类器和支撑向量基分类器进行比较,研究了这种新的分类器在高光谱分类问题上的性能、特点及不足。

## 2 自适应脊波网络

### 2.1 脊波理论简介

脊波(Ridgelet)是小波(Wavelet)的后续,与 Curvelet、Contourlet、Bandlet、Beamlet 等被称为“后小波变换”,是 Littlewood-Paley 理论、多分辨分析技术和现代调和分析发展的产物,最早由 E. J. Candès 和 D. L. Donoho<sup>[8]</sup> 在 1998 年提出。

定义 1  $\psi: \mathbb{R}^n \rightarrow \mathbb{R}$  满足

$$K_\psi = \int \frac{|\hat{\psi}(\xi)|^2}{|\xi|^d} d\xi < \infty \quad (1)$$

式中,  $\hat{\psi}(\xi)$  为  $\psi(\cdot)$  的傅立叶变换,式(1)被称为神经激活函数的容许性条件。

定义 2 形如

$$\psi_\gamma(x) = a^{-1/2} \psi\left(\frac{u \cdot x - b}{a}\right) \quad (2)$$

称为由满足容许性条件的函数  $\psi(\cdot)$  产生的脊波函数,其中参数  $\gamma \in \Gamma$ , 参数空间  $\Gamma = \{\gamma = (a, u, b), a, b \in \mathbb{R}, a > 0, u \in S^{d-1}, \|u\| = 1\}$ ,  $S^{d-1}$  为  $d$  维空间的单位球面,  $a$  为尺度参数,  $b$  为位置参数,  $u$  为方向参数。图 1 为脊波函数的一个例子。

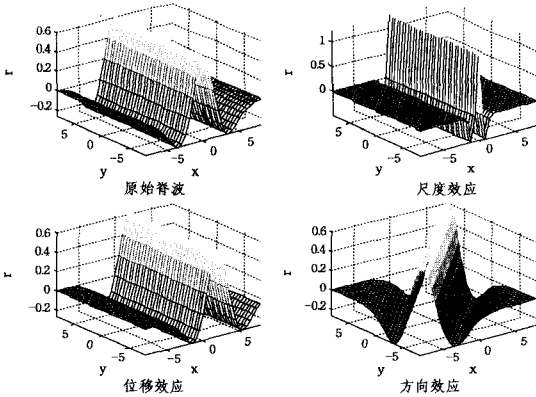


图 1 脊波函数

E. J. Candès 在式(1)、式(2)的基础上证明了如下的重构定理:

定理 1 任何  $f \in L^1 \cap L^2(\mathbb{R}^n)$  的函数可以由满足式(1)、式(2)的脊波函数重构,即

$$f = c_\psi \int \langle f(x), \frac{1}{\sqrt{a}} \psi\left(\frac{u \cdot x - b}{a}\right) \rangle \frac{1}{\sqrt{a}} \psi\left(\frac{u \cdot x - b}{a}\right) \frac{da}{a^d} du db \quad (3)$$

式中,  $c_\psi = \pi(2\pi)^{-d} K_\psi^{-1}$ 。具体证明过程详见文献[8]。

### 2.2 自适应脊波网络模型

根据重构式(3),以类似于小波神经网络的构建方法将脊波函数作为神经网络的激活函数,可以建立如图 2 所示的单隐层自适应脊波网络模型。




图 2 单隐层自适应脊波网络模型

假设有  $P$  个训练样本输入,则  $X = [x_1, x_2, \dots, x_p]$ ,  $Y = [y_1, y_2, \dots, y_p]$ ,  $\hat{Y} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_p]$ ,  $X$  为输入数据,  $Y$  为期望输出,  $\hat{Y}$  为实际输出,其中  $x_i = [x_{i1}, x_{i2}, \dots, x_{id}]^T$ ,  $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T$ ,  $\hat{y}_i = [\hat{y}_{i1}, \hat{y}_{i2}, \dots, \hat{y}_{im}]^T$ ,  $i = 1, 2, \dots, P$ 。输入和隐层间连接权值设为 1, 隐层与输出的连接权值为

$$W_{m \times N} = \begin{bmatrix} \omega_{11} & \dots & \omega_{1N} \\ \vdots & \ddots & \vdots \\ \omega_{m1} & \dots & \omega_{mN} \end{bmatrix}$$

隐层激活函数为一族脊波函数,表示为  $\psi\left(\frac{u_j \cdot x_i - b_j}{a_j}\right)$ ,  $j = 1, \dots, N$ , 其中,  $a_j, b_j \in \mathbb{R}$ ,  $a_j > 0$ ,  $u_j \in \mathbb{R}^d$ ,  $\|u_j\| = 1$ , 为公式简洁起见,用矩阵来表示方向、尺度和位置参数,即

$$U_{N \times d} = \begin{bmatrix} u_{11} & \dots & u_{1d} \\ \vdots & \ddots & \vdots \\ u_{N1} & \dots & u_{Nd} \end{bmatrix}, A_{N \times P} = \begin{bmatrix} a_1 & a_1 & \dots & a_1 \\ \vdots & \vdots & \dots & \vdots \\ a_N & a_N & \dots & a_N \end{bmatrix}, B_{N \times P} = \begin{bmatrix} b_1 & b_1 & \dots & b_1 \\ \vdots & \vdots & \dots & \vdots \\ b_N & b_N & \dots & b_N \end{bmatrix}$$

于是,网络隐层输出为

$$Z = \psi(UX, -B) \quad (4)$$

式中,  $\cdot$  和  $/$  表示矩阵元素对应相减和相除,  $Z = [Z_1, Z_2, \dots, Z_P]$ ,  $Z$  中的每个列向量元素为

$$Z_k = [\psi(x_k, u_1, a_1, b_1), \psi(x_k, u_2, a_2, b_2), \dots, \psi(x_k, u_N, a_N, b_N)]^T$$

式中,  $k = 1, 2, \dots, P$ , 脊波网络的实际输出可表示为

$$\hat{Y} = WZ \quad (5)$$

定义网络性能函数为

$$Perf = \frac{1}{2P} \sum_i^P (y_i - \hat{y}_i)^T (y_i - \hat{y}_i) \quad (6)$$

从自适应脊波网络的整个计算过程来看,网络的训练实际上是基于训练数据,寻找一族合适的脊波函数和相应的脊波系数,从而实现对输入输出映射的最佳重构。由于脊波基函数具有 3 个通道的信息表征能力,相对于小波网络来讲,脊波网络具有更强的非线性映射能力和更好的表征高维奇异性(线、面奇异)的性能。

## 3 自适应粒子群脊波网络训练算法

### 3.1 $\rho$ -PSO 算法

粒子群优化(Particle Swarm Optimization)算法是由 Eberhart 和 Kennedy 于 1995 年模拟鸟群和鱼群的行为时提出的基于群智能的随机优化算法<sup>[9]</sup>,适用于求解大规模非线性、不可微和多峰值复杂优化问题。相对于蚁群算法(ACO)、遗传算法(GA)和免疫算法(IA)等智能算法,PSO 具有算法简洁直观、参数少、优化速度快、容易实现等优点。其标准算法的速度、位置更新公式为

$$v_{ij} = \omega * v_{i(j-1)} + c_1 * r * (p_{best} - p_{ipresent}) + c_2 * r * (g_{best} - p_{ipresent}) \quad (7)$$

$$p_{ij} = p_{ipresent} + v_{ij} \quad (8)$$

式中,  $v_{ij}$ ,  $p_{ij}$  是第  $i$  个粒子第  $j$  步的速度和位置;  $\omega$  为惯性权重,通常取值为 0.1~0.9;  $c_1, c_2, r$  分别为两个学习因子和(0,1)之间的随机数,通常取  $c_1 = c_2 = 2$ ;  $p_{best}$ ,  $p_{ipresent}$  和  $g_{best}$  分别代表第  $i$  个粒子的历史最优位置,当前位置和种群的社会最优位

置。

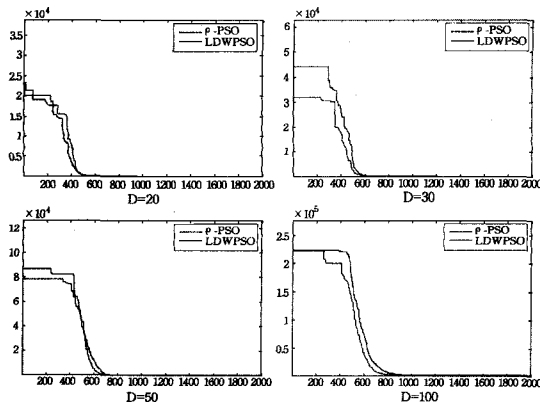
和其他优化算法一样,PSO 也具有早熟和后期震荡现象。PSO 的惯性权重  $\omega$  对算法的收敛性能具有很大的影响,惯性权重较大,则适于全局搜索,较小则具有较强的局部搜索能力。根据算法的运行状态自适应地动态确定适宜的惯性权重将会获得更好的优化性能。国内外不少学者在这方面做了改进研究<sup>[10,11]</sup>,最著名的当属 Berhart 和 Shi 的惯性权重线性递减算法(Linearly Decreasing Weight, LDW),即将惯性权重随迭代步数线性减小,与标准 PSO 算法相比,LDW 确实对优化性能具有明显的改进。但是对于许多实际中优化参数多、高度非线性的复杂优化问题,LDW 的权重递减策略并不能很好地反映实际的优化搜索动态过程,所以收敛性能并不理想。

为了更好地利用 PSO 收敛过程的动态特性来自适应地调整算法的惯性权重因子,避免算法早熟,本文在 LDW 的基础上引入粒子的密度因子,当密度因子比较大时,意味着粒子群失去多样性,为防止陷入局部极值,利用密度因子加入合适的扰动,在不丧失一定的局部搜索能力的同时使粒子跳出局部点,这一点在优化运行的后期尤为重要。根据这一思想,我们将惯性权重因子变为

$$\omega = \omega_{\max} - \text{iter} * (\omega_{\max} - \omega_{\min}) / \text{iter}_{\max} + (\rho_{\min} \leq \rho) * \rho * \omega_{\text{dis}} \quad (9)$$

$$\rho = e^{-[(\mu_f - f_{\text{best}})^2 / \sigma^2]} \quad (10)$$

式中,前两项为 LDW,第三项中  $\rho_{\min}$  为密度因子的临界值,式(10)中,  $\mu_f$  为当前粒子适应度均值,  $f_{\text{best}}$  为当前社会最佳适应度值,  $\sigma$  为扩展常数,当密度因子  $\rho$  大于  $\rho_{\min}$  时,加入扰动常数  $\omega_{\text{dis}}$ ,  $\omega_{\text{dis}} \geq \omega_{\min}$ ,适当增强算法的全局搜索能力,跳出局部极值点,从而避免早熟。图 3 是基于 Benchmark 函数库 Sphere 函数的 LDW-PSO 和本文的  $\rho$ -PSO 收敛性能比较,粒子群规模 50,运行代数 2000,学习因子  $c_1 = c_2 = 1.49445$ ,  $\rho_{\min} = 0.8$ ,扩展常数  $\sigma = 0.0001$ ,扰动  $\omega_{\text{dis}} = 0.5$ ,LDW-PSO 的权重因子  $\omega \in [0.4, 0.9]$ ,解空间维数 D 分别为 20, 30, 50 和 100 维,可以看出引入密度因子后 PSO 算法的性能有明显改善,尤其是在解空间维度较高时,优势较明显。主要是因为当解空间维数较高时,根据高维数据的特性,其数据空间基本为空,数据集中在超立方体的角落,因此在寻优时极易陷入局部解,从而使算法早熟,在加入密度因子扰动后,在一定程度上改善了这一状况。



Sphere 函数:  $f(x) = \sum_{i=1}^D x_i^2$ ,  $x_i \in (-100, 100)$ ,  $x_{\text{best}} = (0, \dots, 0)$ ,  $f_{\min} = 0$

图 3 不同解空间维数下 LDW-PSO 算法和  $\rho$ -PSO 算法的性能比较

### 3.2 脊波网络的 $\rho$ -PSO 训练算法

PSO 算法用于神经网络训练由来已久<sup>[12-15]</sup>,与传统的算法相比,PSO 的收敛速度更快,不需要进行梯度运算,尤其是在非线性或激活函数不可微的情况下;与遗传算法、免疫算法等其他自然计算相比,避免了复杂的算子设计与运算,节省了计算成本,实现也更为容易。但是由于神经网络的特点,权值参量数目较多,导致传统 PSO 在训练网络时解空间维数较高,因此算法极易陷入局部极值,出现早熟现象,网络难以达到预期的效果。

对于自适应脊波网络模型,需要优化的参数有 4 个:隐层脊波函数的方向参数  $u$ 、位置参数  $b$ 、尺度参数  $a$  和网络权值  $w$ 。参数的特点可以归纳为两个方面:(1)参数类型分为非线性参数( $u, b, a$ )和线性参数( $w$ )两类;(2)参数解空间属于高维非线性组合优化问题。如果采用传统的梯度下降法,算法的收敛速度会很慢,后期将陷入局部,因此,根据 3.1 节结果,采用本文提出的  $\rho$ -PSO 算法实现对网络的训练,可以在一定程度上缓解传统 PSO 和梯度下降法的不足。具体的算法流程可以归纳如下:

Step 1 粒子群及网络初始化。设定  $\rho$ -PSO 算法种群数量  $n$ ,对粒子群个体位置( $u_i, b_i, a_i, w_i$ )和速度进行初始化,  $i = 1, \dots, n$ ,设定学习因子  $c_1, c_2$ 、密度因子的扩展常数  $\sigma$ 、惯性权重扰动常数  $\omega_{\text{dis}}$ 、惯性权重因子最大最小值( $\omega_{\min}, \omega_{\max}$ )、最大代数、网络训练目标误差、隐层神经元。

Step 2 网络训练。根据式(4)~式(6)计算误差性能函数值,将其作为粒子的适应度值,获得个体最优值  $p_{\text{best}}$  和社会最优值  $g_{\text{best}}$ ,根据式(10)计算密度因子,从式(9)计算惯性权重,最后根据式(7)、式(8)完成粒子速度和位置的更新。

Step 3 终止判定。如果  $g_{\text{best}} <$  目标误差或者粒子群达到最大代数,则终止训练,得到最优脊波网络参数,网络训练结束。否则,转 Step 2 继续训练,直到满足终止条件。

## 4 高光谱地物分类试验

表 1 AVIRIS 92AV3C 220 波段高光谱数据地物标记类别及每类训练集/测试集像元数目

Class	Name	Pixels in training set	Pixels in testing set
C1	Alfalfa	27	27
C2	Corn-notill	717	717
C3	Corn-min	417	417
C4	Corn	117	117
C5	Grass/Pasture	249	248
C6	Grass/Trees	374	373
C7	Grass/Pasture-mowed	13	13
C8	Hay-windrowed	245	244
C9	Oats	10	10
C10	Soybeans-notill	484	484
C11	Soybeans-min	1234	1234
C12	Soybeans-clean	307	307
C13	Wheat	106	106
C14	Woods	647	647
C15	Bldg-Grass-Tree-Drivers	190	190
C16	Stone-steel towers	48	47

为了验证 PSO-ARNN 的实际性能,首次将网络应用于高光谱遥感分类领域。试验区来自美国印第安纳州西北部的 Indian Pines 地区获取的 220 波段 AVIRIS 92AV3C 高光谱数据集,单波段图像大小为  $145 \times 145$ ,参考图像中标记地物类型 16 类,共有 10366 个像元被标记,占总像元数  $145 \times 145 = 21025$  的 49.3%,未标记像元不参与分类试验,在分类结果中作掩膜处理。采用文献[15]中的互信息特征选择技术,首先对输入波段进行约简,保留 10 个波段作为脊波网络的输入,

波段选择领域宽度  $B=5$ , 领域阈值  $\eta=0.5$ , 每类标记像元的 50% 作为训练样本, 剩余的作为测试样本, 如表 1 所列。

将高光谱领域分类性能比较好的 RBF 神经网络分类器和 SVM 分类器用于同一组数据的分类试验, 便于与脊波网络进行比较, RBF 采用高斯径向基函数, 扩展系数 = 0.1; SVM 也采用高斯核函数, 扩展系数 = 0.01, 采用 one-against-one 分类器设计, 对 16 类地物类型构造 120 个分类器, 利用委员会机器实现最终分类; 自适应脊波网络隐层神经元数为

21, 网络期望误差为 0.01,  $\rho$ -PSO 为训练算法各参数取值: 粒子群大小为 49, 学习因子  $c_1=c_2=1.49445$ , 粒子速度范围为  $[-10, 10]$ , 密度因子下界为 0.8, 密度因子中的扩展常数  $\sigma=0.00001$ , 权重因子扰动常数  $\omega_{dis}=0.5$ , 最大代数为 20000。各分类器分类结果图像与总体分类精度 OA 及 kappa 系数如图 4 所示, 脊波网络的分类混淆矩阵如表 2 所列, 鉴于篇幅原因, RBF 神经网络分类器和 C-SVM 分类器分类误差矩阵未列出。

表 2  $\rho$ -PSO+ARNN 分类图混淆矩阵

	参考数据 (表中精度%)																行计	用户精度
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16		
C1	54	0	0	1	0	0	0	4	0	0	1	0	0	0	0	0	60	90
C2	0	1423	24	3	0	0	0	0	0	27	56	5	0	0	0	0	1538	92.5
C3	0	0	695	20	0	0	0	0	0	4	80	2	0	0	0	0	801	86.8
C4	0	0	0	193	0	0	0	0	0	1	0	0	0	0	0	0	194	99.5
C5	0	0	0	0	440	2	0	0	0	0	0	50	0	26	1	0	519	84.8
C6	0	0	0	1	5	740	0	0	0	0	0	0	0	0	23	0	769	96.2
C7	0	0	0	0	0	0	25	1	0	0	0	0	0	0	0	0	26	96.2
C8	0	0	0	0	0	0	1	484	0	1	0	0	0	0	1	0	487	99.4
C9	0	0	0	0	0	0	0	0	20	1	0	0	0	0	0	0	21	95.2
C10	0	0	5	3	3	1	0	0	0	832	30	8	0	0	0	0	882	94.3
C11	0	0	107	12	21	0	0	0	0	97	2259	3	1	0	5	0	2505	90.2
C12	0	1	3	0	0	0	0	0	0	4	18	540	0	0	0	0	566	95.4
C13	0	0	0	0	0	1	0	0	0	0	0	0	210	1	25	0	237	88.6
C14	0	0	0	0	0	3	0	0	0	0	0	0	0	1265	89	0	1357	93.2
C15	0	0	0	1	27	0	0	0	0	1	0	1	1	2	236	0	269	87.7
C16	0	10	0	0	1	0	0	0	0	0	25	4	0	0	0	95	135	70.4
列计	54	1434	834	234	497	747	26	489	20	968	2468	614	212	1294	380	95	10366	
生产精度	100	99.2	83.3	82.5	88.5	99.1	96.2	98.9	100	86	91.5	87.9	99.1	97.8	62.1	100	OA=91.75, ka=0.9032	

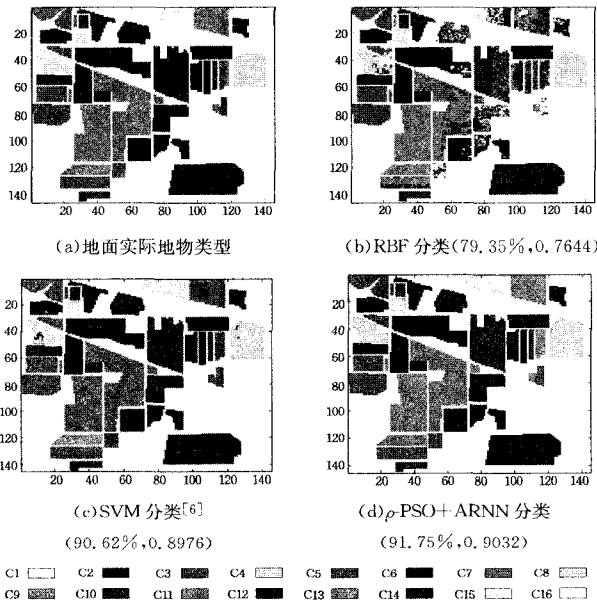


图 4 参考分类图及各分类器分类图比较

**结束语** 本文在建立一种单隐层脊波神经网络的基础上, 提出一种改进的粒子群算法— $\rho$ -PSO 算法, 并将其用于脊波网络的训练, 在 220 波段 AVIRIS 92AV3C 高光谱数据集上进行地物分类试验, 与 RBF 网络和 SVM 分类器进行比较, 实验表明:

- (1) 引入密度因子的粒子群算法对高维空间优化问题易于早熟和陷入局部极值具有一定的抑制作用, 算法的性能相比传统算法略有改善。
- (2) 改进粒子群算法训练脊波网络, 可以避免网络非线性引起的误差, 与传统随机梯度下降法相比, 网络具有较高的精度和较小的规模。
- (3) 以脊波神经网络为代表的多尺度几何分析网络用于

高光谱遥感地物分类是一种有益的尝试, 试验也表明脊波网络对于高光谱图像中的线奇异等高维奇异性(纹理特征)具有很好的检测性能。

(4) 由于脊波基函数可以实现更为广泛的函数类的稀疏表示, 因此脊波网络相比于其他神经网络具有更高的精度和更小的规模。

当然, 自适应脊波网络模型并不是唯一的多尺度几何分析网络模型, 而且从网络的信息处理模型和结构看, 它更适于函数估计问题, 因此, 研究适合于模式分类问题的脊波网络及其训练算法将是下一步研究工作的重点。

### 参考文献

- [1] 浦瑞良, 宫鹏. 高光谱遥感及其应用[M]. 北京: 高等教育出版社, 2000
- [2] 余旭初, 杨国鹏, 等. 基于简约集支持向量机的高光谱影像分类[J]. 计算机科学, 2010, 37(11): 268-270
- [3] Merényi E. The challenges in spectral image analysis: An introduction and review of ANN approaches[C] // Proc. 7th Eur. Symp. Artificial Neural Networks, ESANN. Bruges, Belgium, Apr. 1999: 21-23
- [4] 谭琨, 杜培军. 基于径向基函数神经网络的高光谱遥感图像分类[J]. 光谱学与光谱分析, 2008, 28(9): 2009-2013
- [5] Subotic N S, Gorman J D, Thelen B J. Wavelet techniques for band selection and material classification from hyperspectral data[J]. Proc. SPIE-Imaging Spectrometry, 1995, 2480(7): 426-434
- [6] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Trans. on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790
- [7] Guo Bao-feng, Gunn S R, Dampier R I, et al. Band selection for hyperspectral image classification using mutual information[J]. IEEE Geoscience and Remote Sensing Letters, 2006, 3(4): 522-526

- [8] Candès E J. Ridgelets: Theory and Applications[D]. USA; Department of Statistics, Stanford University, 1998
- [9] Kennedy J, Eberhart R C. Particle swarm optimization[C]// Proc. IEEE Int. Conf. on Neural Networks. 1995;1942-1948
- [10] Shi Y, Eberhart R C. A modified particle swarm optimizer[J]. IEEE World Congress on Computation Intelligence, 1998;69-73
- [11] 吕振肃,侯志荣. 自适应变异的粒子群优化算法[J]. 电子学报, 2004,32(3):416-420
- [12] Liu Jun, Qiu Xiaohong. A Novel Hybrid PSO-BP Algorithm for Neural Network Training[C]// International Joint Conference on Computational Sciences and Optimization. 2009;300-303
- [13] Cai X, Wunsch D C II. Engine Data Classification with Simultaneous Recurrent Network using a Hybrid PSO-EA Algorithm [J]. Proceedings of the International Joint Conference on Neural Networks, 2005,4(7):2319-2323
- [14] Al-Kazemi B, Mohan C K. Training Feedforward Neural Networks using Multi-Phase Particle Swarm Optimization[C]// Proc. Ninth International Conference on Neural Information Processing. Vol. 5, 2002;2615-2619
- [15] van den Bergh F, Engelbrecht A P. Cooperative Learning in Neural Networks using Particle Swarm Optimizers[J]. South African Computer Journal, 2000,26:84-90

(上接第 238 页)

在使用上述优化模型来对权重值进行估量时,可能存在如下问题:被积函数在区间  $X$  内不可积或可积但原函数无法用初等函数表达。针对此类问题可以使用在 3.1 节中介绍的方法进行处理。

当  $X$  为离散空间时,  $X = \{x_1, x_2, \dots, x_m\}$ 。

可建立如下优化模型:

$$\min \left( \sum_{i=1}^n \sum_{j=1}^m (\mu_i^A(x_j) - \sum_{k=1}^n \lambda_k \mu_k^A(x_j))^2 + \sum_{i=1}^n \sum_{j=1}^m (\gamma_i^A(x_j) - \sum_{k=1}^n \lambda_k \gamma_k^A(x_j))^2 \right)$$

$$s. t. \sum_{k=1}^n \lambda_k = 1$$

$$1 \geq \lambda_k \geq 0 (k=1, 2, \dots, n)$$

通过对以上优化问题的求解,可以求出各权重值  $\lambda_k (k=1, 2, \dots, n)$ 。然后将它们分别代入式(3)和式(4)中,即可以得到  $\mu_B(x)$  与  $\gamma_B(x) (x \in X)$ 。

#### 4 实际应用

考虑某一风险投资公司进行某项农业高科技项目投资的决策问题,有 4 个备选项目  $A_j (j=1, 2, 3, 4)$  可供选择。有 4 位相关领域专家  $I_i (i=1, 2, 3, 4)$  分别对这 4 个备选项目进行评估判断,各专家的评判结果如表 1 所列。

表 1

方案	$A_1$		$A_2$		$A_3$		$A_4$	
	Y	N	Y	N	Y	N	Y	N
$I_1$	0.65	0.26	0.72	0.20	0.80	0.10	0.80	0.10
$I_2$	0.61	0.10	0.54	0.31	0.65	0.25	0.74	0.22
$I_3$	0.60	0.14	0.45	0.50	0.55	0.30	0.64	0.22
$I_4$	0.58	0.20	0.70	0.20	0.85	0.10	0.60	0.28

用多值直觉模糊集来表示评估结果表 1:

$$A = \{ \langle \langle [0.65, 0.61, 0.60, 0.58], [0.26, 0.10, 0.14, 0.20] \rangle / A_1, \langle [0.72, 0.54, 0.45, 0.70], [0.20, 0.31, 0.50, 0.20] \rangle / A_2, \langle [0.80, 0.65, 0.55, 0.85], [0.10, 0.25, 0.30, 0.10] \rangle / A_3, \langle [0.80, 0.74, 0.64, 0.60], [0.10, 0.22, 0.22, 0.28] \rangle / A_4 \}$$

下面使用主观赋权加权平均法来进行信息融合。假设这 4 位专家  $I_1, I_2, I_3, I_4$  对应的权重值分别为 0.2、0.15、0.3、0.35, 则按式(1)与式(2)计算可得:

$$B = \{ \langle \langle 0.6045, 0.179 \rangle / A_1, \langle 0.605, 0.3065 \rangle / A_2, \langle 0.72, 0.1825 \rangle / A_3, \langle 0.673, 0.217 \rangle / A_4 \}$$

**结束语** 多值直觉模糊集是对直觉模糊集合理论的一种扩展,这种扩展有助于对复杂问题的描述和解决。与传统直觉模糊集相比,多值直觉模糊集能更好地反映现实世界中的不确定性。本文就多值直觉模糊集的隶属度与非隶属度的信息融合问题进行了研究,并提出了几种融合方法。

#### 参考文献

- [1] Zadeh L A F. The Concept of a Linguistic Variable and Its Application to Approximate Reasoning [J]. Information Science, 1975,8(2):199-249,8(3):301-3579(1):43-80
- [2] Atanassov K. Intuitionistic Fuzzy Sets [J]. Fuzzy Set s and Systems, 1986,20(1):87-96
- [3] Atanassov K. More on Intuitionistic Fuzzy Sets [J]. Fuzzy Sets and Systems, 1989,33(1):37-46
- [4] 雷英杰,王宝树. 直觉模糊关系及其合成运算[J]. 系统工程理论与实践, 2005,25(2):113-1181
- [5] Bustince H. Application to approximate reasoning based on interval-valued fuzzy set[J]. International Journal of Approximate Reasoning, 2000,23(2):137-2091
- [6] 雷英杰,王宝树,王毅. 基于直觉模糊推理的威胁评估方法[J]. 电子与信息学报, 2007,29(9):2077-2031
- [7] 雷英杰,王宝树,李兆渊. 基于自适应直觉模糊推理的威胁评估方法[J]. 电子与信息学报, 2007,29(12)
- [8] Hong D H, Choi C H. Multi-criteria fuzzy decision-making problems based on vague set theory [J]. Fuzzy Sets and Systems, 2000,114(1):103-113
- [9] 王毅,雷英杰,路艳丽. 基于直觉模糊集的多属性模糊决策方法[J]. 系统工程与电子, 2007,29(12):2060-2063
- [10] 徐泽水. 区间直觉模糊信息的集成方法及其在决策中的应用[J]. 控制与决策, 2007,22(2):215-219
- [11] 张善文,李晓曼,雷英杰. 多值直觉模糊集定义[J]. 计算机科学, 2008,35(1):176-177
- [12] Atanassov K, Gargov G. Interval-valued intuitionistic fuzzy set [J]. Fuzzy Set s and Systems, 1989,31(3):343-349
- [13] Xu Z S. On correlation measures of intuitionistic fuzzy sets[C]// Lecture Notes in Computer Science. Berlin: Springer Verlag, 2006:16-24
- [14] 徐泽水. 区间直觉模糊信息的集成方法及其在决策中的应用[J]. 控制与决策, 2007,22(2):215-219
- [15] 周启海,吴红玉. 知识发现与数据挖掘中平均信息测度的创新方法——组合平均[C]// 中国科协年会议论文集. 2006
- [16] 万中,梁文冬,卢宗娟. 模糊数的隶属度区间分布函数[J]. 重庆理工大学学报:自然科学版, 2011,25(1):107-112