

用于 Landsat ETM+和 ERS-2 SAR 图像融合对城区 地物特征分类的 BP-ANN/GA 混合算法

曹广真 金亚秋

(复旦大学波散射和遥感信息国家教育部重点实验室 上海 200433)

摘要 该文建立了反向传播人工神经网络 (Back Propagation Artificial Neural Network, BP-ANN)和遗传算法 (Genetic Algorithm, GA)的 BP-ANN/GA 混合算法。利用 GA 算法的全局优化能力优化 BP-ANN 的初始权值,克服了传统 BP-ANN 收敛速度慢,容易陷入局部最小的缺点。BP-ANN/GA 混合算法对 Landsat ETM+4, 5, 7 三波段红外图像和 ERS-2 SAR 雷达图像的融合数据进行了城市多类地物特征分类。结果表明:BP-ANN/GA 算法不仅提高多源遥感图像自动分类的速度,而且提高了各类特征分类的精度。该文对上海浦东地区的 Landsat ETM+和 ERS-2 SAR 数据作了融合分类试验与验证。

关键词 图像融合, BP-ANN/GA, 地表分类

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2006)07-1153-07

A Hybrid BP-ANN/GA Algorithm for Classification of Urban Terrain Surfaces Using Fused Images of Landsat ETM+ and ERS-2 SAR

Cao Guang-zhen Jin Ya-qiu

(The Key Laboratory of Ministry of Education for Wave Scattering and Remote Sensing Information, Fudan University, Shanghai 200433, China)

Abstract A hybrid algorithm of the BP-ANN/GA (Back Propagation Artificial Neural Network and Genetic Algorithm) is developed to optimize the initial weights and make fast convergence of the BP-ANN. This algorithm is applied to classification of urban terrain surfaces with fused data of Landsat ETM+ and ERS-2 SAR. An example of the Shanghai Pudong area using both the Landsat ETM+ and ERS-2 SAR image data well demonstrates the classification speed and accuracy of the algorithm.

Key words Data fusion, BP-ANN/GA, Surface classification

1 引言

不同的空间遥感系统(如可见光、红外、微波等)获取的数据对于地物几何结构、各通道光谱以及空间分辨率等方面都十分不同,使单一的传感器提供的地物信息总存在其固有的局限性。多源信息融合将多源数据信息合成,产生比单源信息更精确、更可靠的估计和判决,为地物特征分类提供了新手段。

目前遥感图像分类处理中常用的方法,如最小距离法和最大似然法^[1],都是基于遥感数据的统计特征,依赖于先验概率的选取。人工神经网络(ANN), (主要是比较成熟的 BP-ANN)^[2-4],由于数据对特征空间分布预先不一定需要假设某种参数化密度分布,一定程度上克服了上述缺陷。但

BP-ANN 网络采用梯度下降法训练权值,收敛速度慢,而且容易陷入局部最小。遗传算法(GA)是一种全局搜索自适应的优化算法,可以弥补梯度下降法的不足。

因此,本文建立了一种 BP-ANN/GA 混合算法,实现两者的优势互补。对图像进行降低噪声和几何配准等预处理后,首先从 Landsat ETM+4, 5, 7 三波段红外图像中选择样本作为 BP-ANN 网络的输入对网络进行训练,在分析其训练误差和收敛速度的基础上,选择 GA 算法初始化网络的连接权重,构建 BP-ANN/GA 网络,网络分类的速度和精度同时得到提高。然后为利用雷达图像对起伏地物散射特征明显的优势,综合利用红外和雷达图像的信息对城市地物分类。对同一区域的 Landsat ETM+4, 5, 7 三波段红外图像和 ERS-2 SAR 雷达图像进行了主成分分析融合处理,从其中的第 1, 第 2, 第 3 主成分图像中选择样本输入 BP-ANN/GA 网络进行训练,得到比较理想的分类结果,尤其体现在建筑物和道路分类效果的提高。

2004-11-15 收到, 2005-04-25 改回
国家重点基础研究项目(2001CB309401), 国家自然科学基金
(60170009)和上海光科技项目(036105012)资助课题

2 数据预处理

本文选取上海市浦东世纪公园附近有大片陆地、河流和建筑物的区域, 红外数据是 2002 年 11 月 27 日的 Landsat ETM+ 的第 4, 5, 7 波段, 空间分辨率 30m。雷达数据是 2002 年 4 月 9 日的 ERS-2 SAR, 其频率为 5.3GHz, VV 极化, 空间分辨率为 12.5m。

由于雷达波与随机地表面之间的相互作用, 斑点是雷达图像所固有的一种特征。城市地区建筑物、道路等不同材料、不同高度和方位的人工地物的存在, 使得雷达波与地物之间的散射作用更加复杂, 也使雷达图像的斑点特征更加突出。为减少雷达图像中斑点噪声对数据处理的影响, 根据雷达图像噪声呈乘性的统计特征, 首先采用 3×3 的窗口对其进行 Gamma 自适应滤波处理^[5], 减少斑点噪声的同时, 保留了雷达图像的细节信息。然后运用多项式法将 Landsat ETM+4, 5, 7 三波段红外图像分别与其进行空间坐标配准^[6], 运用立方卷积法进行灰度重采样^[6], 最后截取了 400×400 像素的子区作为研究对象, 结果见图 1, 图 2。

为了满足 BP-ANN 的 Sigmoid 激活函数的条件, 对数据做如下归一化处理:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

其中 x^* 为处理后的数据, x 为处理前的数据, x_{\min} , x_{\max} 分别为样本的最小值和最大值。




图1 配准后 Landsat ETM+4 图像 图2 原始 ERS-2 SAR 图像
Fig.1 The registered Landsat ETM+ band 4 image Fig.2 The original ERS-2 SAR image

3 人工神经网络训练

3.1 输入红外遥感图像 BP-ANN 的训练

BP-ANN 是人工神经网络一阶近似的数学模型, 被广泛用于解决各类非线性问题, 具体的网络模型和学习规则可参见文献[7]。在应用于遥感图像监督分类时, 首先把遥感图像的提取特征作为网络的输入信号, 网络按一定规则训练后, 在输出端即可对输出信号进行分类。本文用一个输入层、隐层和输出层组成 3 层 BP-ANN。输入层节点个数和输出层节点个数分别与所选用的遥感图像的波段数和样本的待分类数数目相同, 分别为 3 和 5; 根据实际实验中网络的收敛速

度和分类精度, 隐层节点数目最后确定为 12 个。隐层和输出层的输出均采用具有非线性放大增益的 S 型(Sigmoid)激活函数:

$$f(x) = 1/(1 + e^{-x}) \quad (2)$$

令 5 种待分地物: 水、草地、建筑物、道路和裸露地所对应的目标输出分别为(1 0 0 0 0), (0 1 0 0 0), (0 0 1 0 0), (0 0 0 1 0)和(0 0 0 0 1)。如果在输出层没有得到期望的输出, 则计算输出层目标输出与实际输出的误差平方和作为误差变化值:

$$E = \frac{1}{2} \sum_{k=1}^5 (t_k - r_k)^2 \quad (3)$$

其中 t_k 是第 k 层输出层的目标输出, r_k 是其实际输出。

然后转向反向传播, 通过网络将误差信号沿原来的连接通路反传回来修改各层神经元的权值直到达到期望目标。

本文首先从 Landsat ETM+ 的第 4, 5, 7 波段中将待分的每一类地物选择 4 个样本作为 BP-ANN 的输入对其进行训练, 所得训练误差曲线见图 3, 网络实际输出和目标输出见表 1。




图3 输入 Landsat ETM+4, 5, 7 三波段红外图像 BP-ANN 的训练误差曲线
Fig.3 The error of the BP-ANN with the Landsat ETM+4, 5, 7 training data

由图 3 可知, 当网络训练 4×10^4 次后, 实际输出与目标输出之间误差的最大值为 36.6402, 最小值是 0.1964, 存在一定的误分。从表 1 可知, 网络对水体和裸露地的训练精度较高, 而对建筑物、道路、草地的训练精度较低, 尤其是建筑物的训练结果最差, 目标输出为(0 0 1 0 0), 而样本 3 的网络实际输出仅为(0.0149 0.0098 0.5947 0.0329 0.0107), 相差较大。

为了提高网络的训练速度和精度, 克服 BP-ANN 训练中随机初始化权重的缺点, 本文运用 GA 初始化网络权重, 缩小其搜索范围, 通过“适者生存”的机制优化权重, 构建 BP-ANN/GA 算法。

3.2 输入红外遥感图像 BP-ANN/GA 的训练

GA 算法是模拟生物在自然环境中的遗传和进化过程而形成的一种自适应全局优化概率搜索算法^[8,9]。采用遗传算法优化 BP-ANN 初始权重, 实际上是将整个网络训练分成两部分: 首先采用 GA 算法优化网络的初始权重; 然后将优化结果输入 BP-ANN 完成网络训练。

表 1 输入 Landsat ETM+4, 5, 7 三波段红外图像 BP-ANN 的实际输出和目标输出

Tab.1 The real and desired outputs of the BP-ANN with the Landsat ETM+4, 5, 7 training data

地物	实际输出				目标输出
	样本 1	样本 2	样本 3	样本 4	
水体	0.9410	0.9646	0.9298	0.9751	1
	0.0155	0.0167	0.0166	0.0181	0
	0.1779	0.1521	0.1688	0.1395	0
	0.0187	0.0214	0.0143	0.0433	0
	0.0005	0.0003	0.0007	0.0001	0
草地	0.0131	0.0304	0.0005	0.0137	0
	0.9839	0.8678	0.6423	0.9543	1
	0.0001	0.0009	0.0049	0.0002	0
	0.0535	0.1546	0.0005	0.1663	0
	0.0000	0.0000	0.0388	0.0000	0
建筑物	0.0195	0.0247	0.0149	0.0035	0
	0.0075	0.0062	0.0098	0.0060	0
	0.6579	0.6975	0.5947	0.7564	1
	0.0386	0.0405	0.0329	0.0279	0
	0.0100	0.0100	0.0107	0.0326	0
道路	0.0281	0.0177	0.0241	0.0548	0
	0.1652	0.0248	0.0807	0.1583	0
	0.0427	0.3407	0.1039	0.0489	0
	0.9140	0.8979	0.9238	0.8041	1
	0.0000	0.0000	0.0000	0.0000	0
裸露地	0.0000	0.0000	0.0000	0.0000	0
	0.1160	0.0410	0.1797	0.0833	0
	0.1134	0.3122	0.0625	0.1549	0
	0.0000	0.0000	0.0000	0.0000	0
	0.9974	0.9912	0.9627	0.9631	1

根据BP-ANN的连接权重一般是实数的特点, 本文对染色体采用实数编码, 不同于一般的二进制编码^[8]。对应BP-ANN的 96 个连接权重, GA的每一个个体的染色体均有 96 个基因, 所设定的种群规模为 60, 初始种群取(0, 1)之间的随机数。终止进化代数 200 代。适应度函数定义为

$$f(t, p) = \frac{\max_err(t) - err(t, p)}{\max_err(t) - \min_err(t)} \quad (4)$$

其中 $f(t, p)$ 表示第 t 代第 p 个个体的适应度; $\max_err(t)$ 和 $\min_err(t)$ 分别表示第 t 代所有个体的最大和最小网络输出误差; $err(t, p)$ 代表第 t 代第 p 个个体的网络输出误差。采用与适应度成正比的概率进行选择操作, 浮点数线性交叉, 高斯变异, 交叉概率和变异概率分别取 0.6 和 0.05。

将以上 GA 算法最后一次迭代所得的具有最小网络输出误差的个体作为 BP-ANN 的初始权值, 代入 BP-ANN 进行训练, 网络的输入仍然选择 Landsat ETM+4, 5, 7 三波段红外图像。所得训练误差曲线见图 4, 网络实际输出和目标输出见表 2。

由图 4 可知, 将相同的数据输入BP-ANN/GA网络进行训练, 训练 4×10^4 次后, 实际输出与目标输出之间误差的最小值是 0.0155, 最大值为 14.0632, 比输入BP-ANN网络得到的误差小很多; 同时图 5 BP-ANN/GA和BP-ANN输入Landsat ETM+4, 5, 7 三波段红外图像的训练误差曲线对比图也显示, BP-ANN/GA 网络的收敛速度比 BP-ANN 网络的快。BP-ANN/GA迭代 3424 次收敛, 而BP-ANN需迭代 10610 次。另外, 对于给定的训练误差 0.25, BP-ANN/GA需要时间为 445.125s(431.01s BP-ANN训练, 14.049s GA优化权重), 而BP-ANN需要 542.86s。

由表 2 可知, 网络对 5 类地物的训练精度都有了很大的提高, 网络实际输出比较接近目标输出, 上述训练结果最差的建筑物的实际输出变为(0.0148 0.0001 0.8610 0.0089 0.0081), 与目标输出(0 0 1 0 0)比较接近。所以 BP-ANN/GA 网络同时提高了分类的速度和精度。




图 4 输入 Landsat ETM+4, 5, 7 三波段红外图像 BP-ANN/GA 的训练误差曲线

Fig.4 The error of the BP-ANN/GA with the Landsat ETM +4, 5, 7 training data




图 5 输入 Landsat ETM+4, 5, 7 三波段红外图像 BP-ANN/GA 与 BP-ANN 的训练误差对比图

Fig.5 The error comparison between BP-ANN/GA and BP-ANN with the Landsat ETM +4, 5, 7 training data

3.3 输入红外和雷达融合图像 BP-ANN/GA 的训练

为充分发挥Landsat ETM+4, 5, 7 三波段红外图像的光谱分辨率高和ERS-2 SAR雷达图像的空间分辨率高的优势, 克服红外图像的“同物异谱, 异物同谱”现象和ERS-2 SAR图像中水、平坦草地和道路的后向散射相近的不足, 对两种数据进行主成分分析^[10]融合处理。

主成分分析是一种获取互不相关特征向量的正交线性变换, 能够在信息损失尽可能少的情况下降低数据的维数。首先求多波段遥感数据协方差矩阵的特征值, 并将其按由大到小的顺序进行排列, 然后求与各特征值对应的特征向量, 构造一变换矩阵。对原始图像数据进行变换后, 得到各主成

表2 输入 Landsat ETM+4, 5, 7 三波段红外图像 BP-ANN/GA 的实际输出和目标输出
Tab.2 The real and desired outputs of the BP-ANN/GA with Landsat ETM+4, 5, 7 training data

地物	实际输出				目标输出
	样本 1	样本 2	样本 3	样本 4	
水体	0.9806	0.9885	0.9796	0.9885	1
	0.0100	0.0147	0.0115	0.0161	0
	0.0583	0.0362	0.0489	0.0289	0
	0.0000	0.0000	0.0000	0.0000	0
	0.0001	0.0000	0.0001	0.0000	0
草地	0.0045	0.0079	0.0016	0.0015	0
	1.0000	0.9915	0.8944	0.9995	1
	0.0000	0.0000	0.0000	0.0000	0
	0.0027	0.0177	0.0002	0.0631	0
	0.0000	0.0000	0.0372	0.0000	0
建筑物	0.0186	0.0240	0.0148	0.0032	0
	0.0001	0.0001	0.0001	0.0000	0
	0.9291	0.9566	0.8610	0.9678	1
	0.0087	0.0071	0.0089	0.0501	0
	0.0072	0.0069	0.0081	0.0329	0
道路	0.0004	0.0004	0.0003	0.0026	0
	0.0504	0.0007	0.0093	0.0375	0
	0.0002	0.0887	0.0019	0.0005	0
	0.9009	0.9798	0.8430	0.9387	1
	0.0000	0.0000	0.0000	0.0000	0
裸露地	0.0002	0.0003	0.0005	0.0003	0
	0.0271	0.0022	0.0739	0.0109	0
	0.0030	0.1009	0.0007	0.0101	0
	0.0000	0.0001	0.0000	0.0002	0
	0.9971	0.9898	0.9623	0.9645	1

分图像。

本文首先将 Landsat ETM+4, 5, 7 三个红外波段和 ERS-2 SAR 雷达图像组成多波段图像, 对其进行主成分变换, 得到 4 个主成分融合图像。4 个主成分融合图像的方差分别占总方差的 93.65%, 4.58%, 1.62% 和 0.15%。图 6 显示了其中含信息量较多的前 3 个主成分, 其中第 1, 第 2 主成分集中了研究区道路、水体和建筑物的绝大部分的信息(图 6 (a), 6(b)), 第 3 主成分主要包括相对比较平坦的地物, 如水、草地以及较宽的道路(图 6 (c))。选择 3 个主成分图像中待分的每一类地物的 4 个样本作为 BP-ANN/GA 网络的输入对网络进行训练, 所得训练误差曲线见图 7, 网络实际输出和目标输出见表 3。

对比图 7 和图 4 可以看出, 当将红外和雷达图像的融合图像输入 BP-ANN/GA 网络时, 网络的训练误差进一步降低, 最大值为 11.0149, 最小值为 0.0154。由表 3 可知, 5 类地物的实际输出和目标输出相近, 训练精度进一步提高, 得到更为理想的结果。

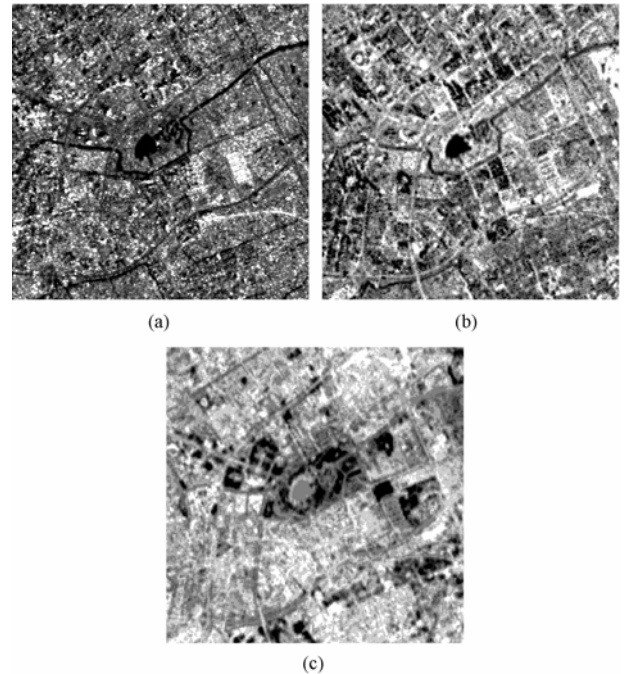


图 6 红外和雷达图像的主成分分析融合图像

(a) 第 1 主成分 (b) 第 2 主成分 (c) 第 3 主成分

Fig.6 The fusion images with the principal component analysis (PCA) of the Landsat ETM+4, 5, 7 and SAR images




图 7 输入红外和雷达融合数据 BP-ANN/GA 网络的误差曲线

Fig.7 The error of the BP-ANN/GA with the fusion of Landsat ETM+4, 5, 7 and SAR training data

4 遥感图像分类

分别固定训练所得的 BP-ANN, BP-ANN/GA 网络的训练权值, 将红外、红外与雷达的融合图像作为网络的输入进行分类处理, 所得的结果见图 8, 图 9 和图 10。

3 幅图中的颜色具有相同的标识: 深蓝色代表水, 浅绿色代表草地, 桔黄色代表建筑物, 黄色代表裸露地, 咖啡色代表道路。对比图 8, 图 9 可以看出, 对于同样的输入(Landsat

表3 输入红外和雷达融合图像 BP-ANN/GA 网络的实际输出和目标输出

Tab.3 The real and desired outputs of the BP-ANN/GA with the fusion of Landsat ETM+4, 5, 7 and SAR training data

地物	实际输出				目标输出
	样本 1	样本 2	样本 3	样本 4	
水体	0.9925	0.9391	1.0000	1.0000	1
	0.0000	0.0000	0.0000	0.0000	0
	0.0000	0.0000	0.0172	0.0266	0
	0.0591	0.0877	0.0000	0.0000	0
	0.0000	0.0000	0.0000	0.0000	0
草地	0.0003	0.0005	0.0006	0.0005	0
	0.9830	0.9678	0.9396	0.9848	1
	0.0000	0.0000	0.0000	0.0000	0
	0.0010	0.0440	0.1198	0.0055	0
	0.0144	0.0024	0.0020	0.0038	0
建筑物	0.0076	0.0194	0.0024	0.0013	0
	0.0000	0.0000	0.0000	0.0000	0
	0.9980	0.9338	0.9817	0.9832	1
	0.0011	0.0002	0.0014	0.0017	0
	0.0057	0.0015	0.0255	0.0440	0
道路	0.0004	0.0597	0.0034	0.0054	0
	0.0001	0.0015	0.0062	0.0732	0
	0.0000	0.0000	0.0000	0.0000	0
	0.9974	0.9981	0.9986	0.9155	1
	0.0163	0.0000	0.0004	0.0001	0
裸露地	0.0000	0.0000	0.0000	0.0000	0
	0.0001	0.0001	0.0001	0.0000	0
	0.0075	0.0124	0.0128	0.0614	0
	0.0240	0.0926	0.0180	0.0076	0
	0.9967	0.9962	0.9582	0.9606	1

ETM+4, 5, 7 三波段红外像), 不同的网络结构, 分得的草地和裸露地的信息基本相同, 虽然对水的信息提取的都不充分, 但 BP-ANN/GA 分得的较 BP-ANN 理想, 道路的信息也

比用 BP-ANN 分得的显著, 表现出较好的连续性。从图 9 的右上角可以看出, 一些较小的道路也呈现出来, 只是图像右边的两个比较明显的本应是建筑物的矩形区域, 却被误分为道路, 这主要是 Landsat ETM+4, 5, 7 三波段红外图像具有“同物异谱, 异物同谱”的特点, 而道路和建筑物的材料相同或相近所致。

对比图 9, 图 10 可以看出, 对于同样的网络结构, 不同的输入数据, 两者提取的 5 类地物的信息差别较大。利用红外和雷达的融合图像分类的结果比较符合实际地物的分布, 与图 11 该区的交通图中水体、道路、建筑物的分布基本一致, 尤其表现在建筑物和道路分类效果的提高。主要由于 Landsat ETM+4, 5, 7 三波段红外图像和 ERS-2 SAR 雷达图像融合后, 雷达图像中建筑物和道路的散射特性的差异消除了红外图像中两者“同物异谱, 异物同谱”的现象, 并充分利用了雷达图像空间分辨率高的特点。草地和裸露地的分类结果和仅用红外的分类结果以及交通图之间均有一定的差别, 可能是由于融合所用的 ERS-2 SAR 雷达图像和 Landsat ETM+4, 5, 7 三波段红外图像时相不太相近, 而草地分布又有季节性的原因。另外, 仍然有部分分得的道路呈现一定的面积, 而不是理想的线性特征, 可能由于这些地物在 Landsat ETM+4, 5, 7 三波段红外图像上与道路“异物同谱”, 而在 ERS-2 SAR 雷达图像上与道路的散射特性比较接近的缘故所致。

为了定量比较各方法分类的效果, 根据目视解译、其它图片资料和野外考察的结果, 选取 466 个较均匀分布的像元(其中最少的一类 60 个像元)作为样本数据, 建立混淆矩阵, 计算了两种不同的分类精度: 总体分类精度和 Kappa 系数。其中总体精度仅考虑混淆矩阵对角线上的像元, 而 Kappa 分析既考虑到了对角线上被正确分类的像元, 同时也考虑到了不在对角线上各种漏分和错分误差^[6]; 而且分别统计了各自分类所需的时间, 结果见表 4。

由此可见, 基于 BP-ANN/GA 混合算法和 Landsat ETM+4, 5, 7 三波段与 SAR 的融合图像, 可以得到比较好的城市复杂地物的分类精度和分类速度。

表4 不同分类方法的分类精度

Tab.4 The classification accuracy with different classification algorithms

分类方法	BP-ANN	BP-ANN/GA	
	Landsat ETM+4, 5, 7 三波段图像	Landsat ETM+4, 5, 7 三波段图像	Landsat ETM+4, 5, 7 三波段和 SAR 的融合图像
总体分类精度	71.46%	72.75%	89.91%
Kappa 系数	0.6339	0.6596	0.8698
分类时间(s)	4620.2	3830.3	3623.8




图8 ETM+4, 5, 7 BP-ANN 分类结果
Fig.8 BP-ANN classification of the Landsat ETM+4, 5, 7 images




图10 ETM+4, 5, 7 与 SAR 融合图像 BP-ANN/GA 分类结果
Fig.10 BP-ANN/GA classification of the fusion of Landsat ETM+4, 5, 7 and SAR images




图9 ETM+4, 5, 7 BP-ANN/GA 分类结果
Fig.9 BP-ANN/GA classification of the Landsat ETM+4, 5, 7 images



图11 研究区交通图
Fig.11 The tourist map of the studying area

5 结束语

本文建立了 BP-ANN/GA 混合算法, 应用于 Landsat ETM+4, 5, 7 三波段红外图像与 ERS-2 SAR 雷达图像的融合分类, 对城市复杂地物分布特征作了自动分类研究。

(1)BP-ANN/GA 算法, 通过 GA 初始化 BP-ANN 的连接权重, 缩小其搜索区间, 可以发挥其全局寻优的优势, 克服 BP-ANN 采用梯度下降法训练权值, 收敛速度慢, 容易陷入局部最小的缺点, 为遥感图像的分类提供可靠的工具。

(2)利用不同波段范围、不同成像机制的红外和雷达遥感

图像融合对城区地物进行分类, 可以使多源遥感图像提供的信息互补, 充分利用各自在空间分辨率和波谱分辨率方面的优势, 克服单一数据源的不足与局限, 有助于更好的对城市复杂地物目标进行分类。

参考文献

[1] 边肇祺. 模式识别 (第二版)[M]. 北京: 清华大学出版社, 2000.01: 46 - 159.
[2] Yoshida T, Omatu S. Neural network approach to land cover mapping [J]. *IEEE Trans. on Geosci. Remote Sens.* 1994, 32(5):

- 1103 – 1109.
- [3] Hansen J V, McDonald J B. Some experimental evidence on the performance of GA-designed neural networks [J]. *Journal of Experimental & Theoretical Artificial Intelligence*, 2001, 13(3): 307 – 321.
- [4] 李祚泳. 用B-P神经网络实现多波段遥感图像的监督分类[J]. *红外与毫米波学报*, 1998, 17(2): 153 – 156.
- [5] Lopbs A, Nezry E, Touzi R, Laur H. Structure detection and statistical adaptive speckle filtering in SAR images [J]. *International Journal of Remote Sensing*, 1993, 14(9): 1735 – 1758.
- [6] 赵应时. 遥感应用分析原理与方法[M]. 北京: 科学出版社, 2003. 06: 176 – 208.
- [7] 丛爽. MATLAB 工具箱的神经网络理论与应用(第二版) [M]. 合肥: 中国科学技术大学出版社, 2003.05: 55 – 87.
- [8] 周明, 孙树栋. 遗传算法原理及应用(第一版) [M]. 北京: 国防工业出版社, 1999.06: 1 – 64.
- [9] Jin Y Q, Wang Y. A genetic algorithm to retrieve multi-parameters of land surface roughness and soil moisture [J]. *International Journal of Remote Sensing*, 2001, 22(16): 3093 – 3099.
- [10] Gonzalez R C, Woods R E. Digital image processing (second edition) [M], New York: Prentice-Hall, 2003: 675 – 683.
- 曹广真: 女, 1976年生, 博士生, 研究方向为可见光、红外和雷达遥感信息的融合原理与应用.
- 金亚秋: 男, 1946年生, 教授, 博士生导师, 研究方向为电磁散射与辐射传输理论、空间遥感信息技术、计算电磁学等.